UTJECAJ FLEKSIBILNOSTI RADNE SNAGE NA GOSPODARSKI RAZVOJ ZEMALJA EU

Blažević Dević, Ivona

Doctoral thesis / Disertacija

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Economics in Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:145:359978

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

EFOS REPOSITORY - Repository of the Faculty of Economics in Osijek

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Poslijediplomski doktorski studij “Management“

Ivona Blažević Dević

UTJECAJ FLEKSIBILNOSTI RADNE SNAGE NA GOSPODARSKI RAZVOJ ZEMALJA EU

DOKTORSKA DISERTACIJA

Osijek, 2023.

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Poslijediplomski doktorski studij “Management“

Ivona Blažević Dević

UTJECAJ FLEKSIBILNOSTI RADNE SNAGE NA GOSPODARSKI RAZVOJ ZEMALJA EU

DOKTORSKA DISERTACIJA

Mentor: prof. dr. sc. Željko Požega

Osijek, 2023.

University Josip Juraj Strossmayer in Osijek
Faculty of Economics in Osijeku
Postgraduate doctoral study “Management“

Ivona Blažević Dević

THE EFFECT OF WORKFORCE FLEXIBILITY ON THE ECONOMIC DEVELOPMENT OF EU COUNTRIES

DOCTORAL THESIS

Supervisor: Željko Požega, PhD, Full Professor

Osijek, 2023

IZJAVA

O AKADEMSKOJ ČESTITOSTI, PRAVU PRIJENOSA INTELEKTUALNOG VLASNIŠTVA, SUGLASNOSTI ZA OBJAVU U INSTITUCIJSKIM REPOZITORIJIMA I ISTOVJETNOSTI DIGITALNE I TISKANE VERZIJE RADA

1. Kojom izjavljujem i svojim potpisom potvrđujem da je doktorski rad isključivo rezultat osobnoga rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu. Potvrđujem poštivanje nepovredivosti autorstva te točno citiranje radova drugih autora i referiranje na njih.
2. Kojom izjavljujem da je Ekonomski fakultet u Osijeku, bez naknade u vremenski i teritorijalno neograničenom opsegu, nositelj svih prava intelektualnoga vlasništva u odnosu na navedeni rad pod licencom *Creative Commons Imenovanje – Nekomercijalno – Dijeli pod istim uvjetima 3.0 Hrvatska.* (cc) BY-NC-SA
3. Kojom izjavljujem da sam suglasna da se trajno pohrani i objavi moj rad u institucijskom digitalnom repozitoriju Ekonomskoga fakulteta u Osijeku, repozitoriju Sveučilišta Josipa Jurja Strossmayera u Osijeku te javno dostupnom repozitoriju Nacionalne i sveučilišne knjižnice u Zagrebu (u skladu s odredbama Zakona o znanstvenoj djelatnosti i visokom obrazovanju, NN br. 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).
4. izjavljujem da sam autorica predanog rada i da je sadržaj predane elektroničke datoteke u potpunosti istovjetan sa dovršenom tiskanom verzijom rada predanom u svrhu obrane istog.

Ime i prezime studentice: Ivona Blažević Dević
Matični broj: 311
OIB: 86644637991
e-mail za kontakt: ivona.blazevic1@gmail.com
Naziv studija: Ekonomski fakultet u Osijeku, Poslijediplomski doktorski studij „Management"
Naslov rada: UTJECAJ FLEKSIBILNOSTI RADNE SNAGE NA GOSPODARSKI RAZVOJ ZEMALJA EU
Mentor rada: prof. dr. sc. Željko Požega

U Osijeku, 2. 2. 2023. godine

Potpis Ivona Blažević Dević

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku **Doktorska disertacija**
Ekonomski fakultet u Osijeku

Znanstveno područje: Društvene znanosti
Znanstveno polje: Ekonomija

UTJECAJ FLEKSIBILNOSTI RADNE SNAGE NA GOSPODARSKI RAZVOJ ZEMALJA EU

Ivona Blažević Dević

Disertacija je izrađena u: Osijeku

Mentor: prof. dr. sc. Željko Požega

Kratki sažetak doktorske disertacije:
Temeljna svrha ovog rada je proučiti i sustavno elaborirati osnovne teorijske postavke socio-ekonomskih trendova i zakonskog okvira tržišta rada EU-a. Cilj je disertacije analizirati relevantna obilježja tržišta radne snage EU-a te raspon fleksibilnosti radne snage na tržištu rada zemalja EU-a. Korištenjem nelinearnih regresijskih modela te neparametrijskih metoda precizno su se identificirale razlike u fleksibilnosti pojedinih tržišta rada što daje dubinski uvid u konkretno stanje na analiziranim tržištima u razdoblju od 2008. do 2018. godine.

Broj stranica: 382
Broj slika: 7
Broj tablica: 207
Broj literaturnih navoda: 285
Jezik izvornika: hrvatski jezik
Ključne riječi: tržište rada EU-a, fleksibilnost radne snage, gospodarski razvoj EU-a, fleksigurnost

Datum obrane: 2. veljače 2023.

Stručno povjerenstvo za obranu: izv. prof. dr. sc. Ivan Kristek, izv. prof. dr. sc. Ivana Bestvina Bukvić, izv. prof. dr. sc. Jelena Legčević

Disertacija je pohranjena u: Nacionalnoj i sveučilišnoj knjižnici Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; Gradskoj i sveučilišnoj knjižnici Osijek, Europska avenija 24, Osijek; Sveučilištu Josipa Jurja Strossmayera u Osijeku, Trg sv. Trojstva 3, Osijek; Ekonomskom fakultetu u Osijeku, Trg Lj. Gaja 7, Osijek

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek **PhD thesis**
Faculty of Economics in Osijek

Scientific Area: Social Sciences
Scientific Field: Economics

THE EFFECT OF WORKFORCE FLEXIBILITY ON THE ECONOMIC DEVELOPMENT OF EU COUNTRIES

Ivona Blažević Dević

Thesis performed at: Osijek

Supervisor/s: Full Professor Željko Požega, PhD

Short abstract:
The main purpose of this paper is to examine and systematically elaborate the main theoretical tenets of socio-economic trends and the legislative framework of the EU labour market. The aim of this dissertation is to analyse relevant features of the EU labour market and the range of workforce flexibility on the EU labour market. By using nonlinear regression models and nonparametric methods precise differences in market flexibility were identified, which offers a deeper insight into the specific situation in analyzed markets from 2008 to 2018.

Number of pages: 382
Number of figures: 7
Number of tables: 207
Number of references: 285
Original in: Croatian language
Key words: the EU labour market, workforce flexibility, the EU economic development, flexicurity

Date of the thesis defense: February 2nd, 2023

Reviewers: Ivan Kristek, PhD, Associate professor, Ivana Bestvina Bukvić, PhD, Associate professor, Jelena Legčević, PhD, Associate professor

Thesis deposited in: National and University Library in Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; City and University Library of Osijek, Europska avenija 24, Osijek; Josip Juraj Strossmayer University of Osijek, Trg sv. Trojstva 3, Osijek; Faculty of Economics in Osijek, Trg Lj. Gaja 7, Osijek

SAŽETAK

Europska unija je široko područje koje uključuje veliki broj zemalja s različitim politikama i odredbama koje je potrebno uskladiti i prilagoditi glavnim direktivama EU-a o tržištu rada koje za cilj imaju postizanje veće fleksibilnosti i efikasnosti europskog tržišta rada. Fleksibilnost tržišta rada utječe na zaposlenost i gospodarski rast. Moderno tržište rada Europske unije svojim sudionicima nastoji pružiti što veću sigurnost - sigurnost radnog mjesta kao i sigurnost u pronalaženju novog radnog mjesta.

S ciljem ublažavanja dugotrajne nezaposlenosti i poboljšanja položaja stanovništva bez posla uvode se brojne mjere kojima se nastoji utjecati na povećanje zaposlenosti, kao što su pomoć mladima koji ulaze na tržište rada, pomoć kod mobilnosti zaposlenika, unaprjeđenje vještina.

Iako je tržište povezanije nego ikad, a sloboda kretanja ljudi je omogućena skoro pa u svim segmentima, Europska unija se i dalje bori s neujednačenom i, u pojedinim državama članicama, relativno visokom stopom nezaposlenosti.

Sukladno dosadašnjim istraživanjima, a s ciljem rješavanja problema neusklađenosti ponude i potražnje na tržištu rada EU-a, kao i pitanja obrazovanja, mobilnosti, odredbi zakonske zaštite i sigurnosti u okviru sustava radnih odnosa, potrebno je sustavno istražiti i analizirati koordinaciju politika zapošljavanja na razni EU-a kao i provođenje mjera aktivnih politika tržišta rada. Između ostaloga, potrebno je konceptualno sagledati i intenciju u osiguranju pune mobilnosti i provođenja strategije cjeloživotnog učenja, kao i implementaciju fleksibilnijih ugovornih aranžmana i osiguranje modernijeg sustava socijalne sigurnosti, što će neosporno doprinijeti prosperitetu gospodarstava zemalja Europske unije.

Rad je koncipiran u devet poglavlja koja neformalno čine dvije odvojene cjeline, odnosno teorijski i istraživački dio. U prvom dijelu rada identificirane su temeljne odrednice tržišta rada Europske unije i socio-ekonomski trendovi i politike na tržištu rada EU-a. Ocijenjena je važnost fleksibilnosti tržišta rada koja za cilj ima transformaciju istog, u vidu povećanja inkluzije osoba na tržište rada, te je objašnjena nužnost infiltriranja fleksigurnosti kao složenog koncepta koji sažima efekte fleksibilnosti i sigurnosti na tržištu rada. Drugi, istraživački dio rada, se odnosi na analizu utjecaja fleksibilnosti radne snage na gospodarski razvoj država EU-a.

Važnost teme doktorske disertacije očituje se u postizanju minucioznog razumijevanja koncepta fleksibilnosti radne snage i njegovog utjecaja na gospodarski razvoj u promatranim

zemljama. Značaju teme uvelike doprinosi i analiza provedena na uzorku od dvadeset i osam zemalja, što ovo istraživanje čini izrazito relevantnim za daljnje razvijanje spoznaja u području gospodarskog razvoja i tržišta rada Europske unije.

Istraživanje u disertaciji provedeno je na EU-LFS-ovom službenom skupu podataka dobivenih na temelju projekta RPP 35/2020-LFS kojeg je odobrila Europska komisija i Eurostat te preuzetih s platforme S-CIRCABC. U sklopu projekta su dobiveni podaci za analizu na uzorku od 1 978 417 ispitanika u razdoblju od 2008. godine do 2018. godine. U analizu su uključene zaposlene i nezaposlene osobe starije od 15 godina i mlađe od 64 godine koje žive u kućanstvima na razini svih članica EU-a. Podaci su analizirani i obrađeni statističkom metodom.

Kao okosnica rada nameće se glavno istraživačko pitanje na koje će se u disertaciji odgovoriti: utječe li fleksibilnost tržišta radne snage u promatranim državama na osiguravanje višeg stupnja razvijenosti zemlje. Ono kauzalno implicira svrhu provedenog istraživanja u disertaciji kojom se nastoje utvrditi relevantna obilježja svakog pojedinog tržišta radne snage EU-a te raspon fleksibilnosti radne snage na tržištu rada navedenih zemalja.

U istraživačkom dijelu doktorske disertacije korištena je linearna korelacijska analiza te je izračunat koeficijent korelacije, koeficijent determinacije te pridružena statistička značajnost. Također, korištena je regresijska analiza – model višestruke regresije i to: višestruka linearna regresija te višestruka nelinearna regresija, pri čemu se odredila značajnost modela, koeficijent determinacije, pravac regresije i pripadajući ponderi prediktorskih varijabli. Nadalje, korišten je test značajnosti razlike između proporcija te je primijenjen χ^2-test za ispitivanje povezanosti dvaju nominalnih varijabli. Razina značajnosti je postavljena na α=0,05. Za statističku analizu koristili su se statistički programi SPSS i Statistica.

Na temelju opsežno provedene analize podataka odabranih zemalja članica Europske unije, uočena je značajnost implementacije koncepta fleksibilnosti u vidu procesa rada, radnopravnog statusa, radnog vremena i organizacije rada na tržištima rada Europske unije u smanjenju nezaposlenosti i segmentacije tržišta. Istraživanje je pokazalo kako veća fleksibilnost tržišta rada implicira povećanje dinamike tržište rada i rast bruto domaćeg proizvoda po stanovniku u sljedećim državama: Austrija, Belgija, Bugarska, Cipar, Francuska, Hrvatska, Litva, Nizozemska, Poljska, Rumunjska, Španjolska i Švedska.

Ključne riječi: tržište rada EU-a, fleksibilnost radne snage, gospodarski razvoj EU-a, fleksigurnost

ABSTRACT

The European Union is a wide area that includes a large number of countries with different policies and regulations that need to be adjusted and coordinated with the main EU directives on labour law aimed at improving the flexibility and efficiency of the European labour market. The flexibility of the labour market affects economic growth and consequently employment and unemployment rates. The modern EU labour market tries to offer its participants more security, in keeping their workplace, as well as finding a new one. With the aim of alleviating long-term unemployment and improving the life quality of the unemployed, as well as increasing employment; numerous measures, such as helping the youth enter the labour market, advancing employee mobility and improving skills, have been introduced.
Although the market has never been more connected and the freedom of movement now exists in almost all segments, the European Union still fights uneven, and in certain member states, relatively high unemployment rate.

In accordance with previous research, with the aim of solving the problem of imbalance between supply and demand in the EU labour market, as well as education, mobility, level of legal protection and safety in terms of employment, it is necessary to systematically research and analyse the coordination of employment policies on the EU level as well as the enforcement of active labour market policies. Among others, there is a need for a conceptual view on the intention of securing full mobility and implementing lifelong learning strategy, flexible contractual arrangements and a more modern system of social security which would undoubtedly contribute to the economic prosperity of the EU member states.

The paper consists of nine chapters which form two separate units, i.e. the theoretical and the research part. The first part identifies the basic EU labour market determinants, socio-economic trends and policies. It provides an evaluation of the labour market's flexibility, aimed at transforming it by including more people, and it explains the need of infiltrating flexicurity as a complex concept which integrates the effects of flexibility and security. The second, research part, refers to the analysis of the effect of workforce flexibility on the economic development of the EU member states.

The significance of this dissertation is in achieving detailed understanding of workforce flexibility concept and its impact on the economic development in the observed countries. The

analysis conducted on the sample of 28 countries also contributes to its significance and makes the thesis highly relevant for further developments in the field of economic growth and the EU labour market.

The research was conducted on EU LFS official dataset which was obtained on the account of RPP 35/2020-LFS project, approved by the European Commission and Eurostat. The data for the sample analysis was obtained under the project and was based on the sample of 1.978.417 subjects in the period from 2008 to 2018. The analysis included employed and unemployed people, between the age of 15 and 64, living in households in all member states, Iceland, Norway and Switzerland. Statistical method was used to analyse and process data.

The backbone of this paper is the main research question: Does the labour market flexibility affect the countries' level of development? It implicates the purpose of the conducted research which tries to determine the relevant features of EU members' labour market, as well as its workforce flexibility.

In the research part of the Ph.D. dissertation, linear correlation analysis was used, the correlation coefficient, the coefficient of determination and statistical significance were calculated. Regression analysis, the model of multiple regression, was also used: multiple linear regression and multiple nonlinear regression, which determined the significance of the model, the coefficient of determination, regression line and weights assigned for predictor variables. Furthermore, a difference in proportions test was used and a Chi- squared (χ^2) test was used to examine the relationship between two nominal variables. The statistical significance level was set at α=0,05. SPSS and Statistica were used for statistical analysis.

Extensive analysis shows how the implementation of the concept of flexibility into the workflow, employment status, working time and work organization in the EU labour market contributed to reducing unemployment and market segmentation. The research has shown that greater labor market flexibility implies an increase in labor market dynamics and gross domestic product per capita growth in the following countries: Austria, Belgium, Bulgaria, Cyprus, France, Croatia, Lithuania, the Netherlands, Poland, Romania, Spain and Sweden.

Keywords: the EU labour market, workforce flexibility, the EU economic development, flexicurity

PREDGOVOR

Koncept fleksibilnosti tržišta rada prvi puta se spominje u Lisabonskoj strategiji donesenoj 2000. godine u kojoj se, uz fleksibilnost, ističe i značaj cjeloživotnog obrazovanja te sigurnosti u radnom i socijalnom pravu na tržištu rada. Europska unija danas nastoji kroz regionalnu politiku i, konkretno, kroz kohezijski fond pružiti potporu zemljama članicama u stvaranju novih radnih mjesta, gospodarskom rastu, održivom razvoju i općenito poboljšanju kvalitete života građana. Od samih početaka i stvaranja Europske zajednice, šest početnih država članica već je imalo viziju utvrđenu Ugovorom o osnivanju, kako će Zajednica težiti smanjenju razlika između nivoa razvijenosti različitih regija. Tragom navedenog, EU i danas iznova postavlja ciljeve, razvija mjere i osigurava resurse i aktivnosti za regulaciju tržišta rada i smanjenje diskriminacije.

Iz takvih konstatacija nastala je ideja za ovu doktorsku disertaciju koja će ujedno poslužiti i kao podloga za daljnja istraživanja o tržištu rada Europske unije, njegovoj fleksibilnosti te, u novije vrijeme, o značaju fleksigurnosti. Danas, kada su tržišta povezanija nego ikada, prije uslijed suvremenih globalizacijskih procesa, izučavati tržite rada pojedine zemlje bez šireg konteksta zapravo nije moguće te će se u ovoj disertaciji promatrati stanje tržišta rada i problematika istog na razini svih država članica Europske unije kako bi se kreirala cjelokupna slika o silnicama koje djeluju na tržište rada.

Ova doktorska disertacija i hipoteze koje će se u empirijskome dijelu potvrditi ili odbaciti naravno neće detektirati svaki problem vezan uz tržište rada i fleksibilnost istog, ali će se u okviru navedenog nedvojbeno pokušati dati osnovne preporuke i pružiti polazište za daljnja istraživanja. Radi se o kompleksnoj problematici te je namjera ove disertacije učiniti mali pomak u njenom rješavanju.

Upisavši smjer Međunarodno poslovanje na preddiplomskom studiju Ekonomskog fakulteta Sveučilišta u Rijeci te nakon istog smjer Gospodarstvo Europske unije na diplomskoj razini, moja specijalizacija išla je u makroekonomskom pravcu. Zaposlivši se na Veleučilištu u Slavonskom Brodu, danas sveučilištu, predavala sam na kolegijima Vanjskotrgovinsko poslovanje i Globalna ekonomija te je odabir teme doktorske disertacije bio logičan slijed u mojoj težnji za usavršavanjem u ovoj domeni.

Na putu ka mom cilju našlo se mnogo osoba koje su dale svoj doprinos i kojima bih ovim putem htjela zahvaliti.

Prvenstveno bih htjela zahvaliti svom mentoru, prof. dr. sc. Željku Požegi, na svim sugestijama, savjetima, pomoći pri svakoj fazi izrade ovoga rada te odgovorima na sva moja nebrojena

pitanja. Zahvaljujem mu i što je uvijek našao vremena za razgovor o ovoj disertaciji, imao razumijevanja i vjere u mene.

Predsjedniku povjerenstva, izv. prof. dr. sc. Ivanu Kristeku, izvanrednom profesoru i članici povjerenstva, izv. prof. dr. sc. Ivani Bestvini Bukvić, izvanrednoj profesorici, zahvalna sam na iznimnoj suradnji i vrlo važnim, meni relevantnim, komentarima koji su dali završni pečat ovoj disertaciji.

Zahvaljujem, također, svim kolegama sa Sveučilišta u Slavonskom Brodu koji su nesebično znali odvojiti vrijeme za mene te mi dati konstruktivne savjete za izradu disertacije. Naposljetku, posebno zahvaljujem svojoj obitelji i prijateljima, kojima sam ponekad uskratila svoje prisustvo prilikom izrade ove disertacije, jer su razumjeli cilj i svrhu njena nastajanja.

Ivona Blažević Dević, mag. oec.

U Slavonskom Brodu 5. siječnja 2023.

Ovaj rad posvećujem:

roditeljima Ivi i Kati koji su me svojim primjerom uvijek vodili kroz život,

sestri Anđeli za neizmjernu vjeru u moj uspjeh,

suprugu Anti za ljubav i bezuvjetnu podršku te

kćeri Ani za njeno uzornije sutra.

SADRŽAJ

1. UVOD ... 1

2. METODOLOŠKI OKVIR ISTRAŽIVANJA ... 3

2.1. Istraživačka pitanja i postavljene hipoteze ... 3

2.2. Svrha i cilj istraživanja ... 5

2.3. Primijenjene znanstvene metode ... 6

2.4. Struktura rada i očekivani znanstveni doprinos ... 8

2.5. Problemi i ograničenja u istraživanju ... 10

3. PRIKAZ DOSADAŠNJIH ISTRAŽIVANJA ... 12

4. TRŽIŠTE RADA EU-a ... 24

4.1. Kretanje radne snage na tržištu rada EU-a ... 27

4.1.1. Odnos intelektualnog kapitala i razvoja globalnog gospodarstva ... 29

4.1.2. Migracije i mobilnost na području Europske unije ... 30

4.2. Obrazovanje kao preduvjet konkurentnosti na tržištu rada ... 36

4.2.1. Pravo na obrazovanje, strukovno osposobljavanje i profesionalno usmjeravanje 40

4.2.2. Cjeloživotno obrazovanje ... 41

4.3. Ponuda poslova na tržištu rada EU-a ... 43

4.3.1. Kohezijska politika Europske unije ... 44

4.3.1.1. Europska strategija zapošljavanja ... 45

4.3.1.2. Socijalna agenda ... 50

4.3.1.3. Europski socijalni fond ... 57

4.3.2. Novi oblici rada u digitalnoj ekonomiji EU-a ... 61

5. SOCIO-EKONOMSKI TRENDOVI I POLITIKE NA TRŽIŠTU RADA EU-a ... 65

5.1. Makroekonomski indikatori i socijalna politika EU-a ... 65

5.2. Institucije i zakonodavni okvir tržišta rada EU-a ... 70

5.2.1. Institucije, agencije i partneri na tržištu rada EU-a ... 72

5.2.2. Zakon o radu Europske unije ... 74

5.2.2.1. Direktive o radnim uvjetima i o radnom vremenu ... 75

5.2.2.2. Direktive o nestandardnim oblicima zaposlenja ... 76

5.3. Aktivne politike tržišta rada EU-a ... 79

5.4. Zapošljavanje i socijalna uključenost ... 84

5.5. Nezaposlenost kao socijalni rizik na tržištu rada EU-a 96
5.5.1. Stope nezaposlenosti 97
5.5.2. Uzroci i vrste nezaposlenosti 101
5.5.3. Dugotrajna nezaposlenost ..... **Pogreška! Knjižna oznaka nije definirana.**
5.5.4. Diskriminacija na tržištu rada 107
5.5.4.1. Oblici diskriminacije na tržištu rada 108
5.5.4.2. Teorije diskriminacije na tržištu rada i pokazatelji diskriminacije 109
5.5.4.3. Segmentacija tržišta rada 110
5.6. Sigurnost u radnom i relevantnom socijalnom pravu na tržištu rada EU-a .. 110
6. FLEKSIBILNOST TRŽIŠTA RADA EU-a 117
6.1. Politike i direktive EU-a o fleksibilnosti tržišta rada 118
6.2. Vrste fleksibilnosti tržišta rada EU-a 122
6.2.1. Fleksibilnost procesa rada 123
6.2.1.1. Podugovaranje 123
6.2.1.2. Ugovori s nultim radnim vremenom 124
6.2.1.3. Samozapošljavanje 125
6.2.2. Fleksibilnost radnopravnog statusa 126
6.2.2.1. Rad na određeno vrijeme 127
6.2.2.2. Privremeno zapošljavanje 128
6.2.2.3. Neformalna zaposlenost 130
6.2.2.4. Prekidi karijera 131
6.2.2.5. Fleksibilno umirovljenje 132
6.2.3. Fleksibilnost radnog vremena 132
6.2.3.1. Rad s nepunim radnim vremenom 133
6.2.3.2. Prekovremeni rad 135
6.2.3.3. Rad nedjeljom 136
6.2.3.4. Dijeljenje radnog mjesta 138
6.2.3.5. Skraćeni (sažeti) radni tjedan 139
6.2.3.6. Smjenski rad 140
6.2.3.7. Godišnje radno vrijeme 140
6.2.4. Fleksibilnost organizacije rada 141
6.2.4.1. Fleksibilna mjesta rada 141
6.2.4.2. Rad na izdvojenome mjestu rada 142

6.2.4.3. Izmještanje radnika (posting of workers) *143*

6.3. Fleksigurnost kao ravnoteža fleksibilnosti i sigurnosti na tržištu rada EU-a 144

7. ANALIZA UTJECAJA FLEKSIBILNOSTI RADNE SNAGE NA GOSPODARSKI RAZVOJ ZEMALJA EU-a 148

7.1. Definiranje varijabli korištenih u radu i metodologija njihova izračuna 148

7.2. Analiza uzorka istraživanja 158

7.3. Statistička obrada i analiza podataka istraživanja 159

7.3.1. Utjecaj fleksibilnosti tržišta radne snage na stupanj razvijenosti zemalja 159

7.3.2. Zapošljavanje na nepuno radno vrijeme i privremeno zapošljavanje u korelaciji sa stopom zaposlenosti 187

7.3.3. Učinak povećanja rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće na smanjenje stope nezaposlenosti 221

7.3.4. Značaj razine obrazovanja u okviru zaposlenosti na određeno radno vrijeme i zaposlenosti na nepuno radno vrijeme 245

7.3.5. Vremensko trajanje nezaposlenosti u korelaciji s dobnom strukturom radnika. 290

7.3.6. Vremensko trajanje nezaposlenosti u korelaciji s motivacijom radnika za traženjem novog posla 308

8. RASPRAVA 339

8.1. Teorijski aspekti fleksibilnosti tržišta rada EU-a 339

8.2. Istraživački problem i emprijsko potvrđivanje i/ili odbacivanje postavljenih hipoteza 340

8.3. Sinteza postignutih saznanja u doktorskoj disertaciji 343

8.4. Prediktivni model utjecaja fleksibilnosti tržišta rada na gospodarski razvoj zemalja EU-a 345

9. ZAKLJUČAK 347

10. LITERATURA 357

POPIS TABLICA

POPIS SLIKA

POPIS GRAFIKONA

POPIS KRATICA I SIMBOLA

1. UVOD

Tržište rada je već duži niz godina predmet istraživanja i analize ekonomista diljem svijeta. Kroz dostupnu literaturu može se uočiti njihovo nastojanje u promicanju faktora koji utječu na dinamiku i promjene koje se događaju na tržištu rada.

Tržište rada ne sačinjava samo ponuda poslova te potražnja za istima, poslodavci te zaposlene i nezaposlene osobe kao jedni od glavnih aktera na tržištu rada uz agencije za zapošljavanje i sindikate, nego i obrazovni sustav pojedine zemlje koji može biti generator konkurentnosti na tržištu rada. Jednako tako, dodatan impuls dinamici tržišta rada daje i kretanje radne snage i promjena radnog mjesta koji sa sobom donose tranzit intelektualnog kapitala koji je kamen temeljac razvoja globalnog gospodarstva.

U poslijediplomskom doktorskom radu „Utjecaj fleksibilnosti radne snage na gospodarski razvoj zemalja EU-a“ istražuje se koliko su tržišta zemalja Europske unije (EU) fleksibilna, odnosno, s druge strane, koliko je dominantan čimbenik sigurnosti na tržištima rada koji, prema istraživanjima, odmaže konkurentnosti, a time i gospodarskom razvoju zemalja.

Nastavno na prethodno navedeno, u radu se također analizira problematika u vidu korelacije između fleksibilnosti radnog vremena i fleksibilnosti organizacije rada te gospodarskog razvoja zemalja Europske unije te se izvode zaključci pojedinačno za svaku zemlju i ukupno, na razini EU-a, o utjecaju istih na stopu zaposlenosti, odnosno, stopu nezaposlenosti.

Radom se želi sagledati i istražiti povezanost između fleksibilnih oblika rada i razine obrazovanja osoba ispitanih u uzorku te njihove dobne strukture i, na temelju toga, formirati zaključke o značaju i utjecaju navedenih kategorija na primjenu fleksibilnih oblika rada.

Konceptu fleksibilnosti se u zadnje vrijeme posvećuje sve više pozornosti, naročito nakon stanja do kojeg je dovela kriza u 2020. godini uzrokovana pandemijom te su poduzeća morala stjecajem okolnosti postati fleksibilnija u aspektu oblika rada. No to područje zasigurno još nije dovoljno istraženo te se ovim radom želi istražiti i analizirati utjecaj integriranja fleksibilnih oblika rada na gospodarski razvoj zemalja EU-a. Radom se ujedno pruža sveobuhvatan prikaz stanja u svim zemljama članicama Europske unije u razdoblju od 2008. do 2018. godine.

Korištenjem nelinearnih regresijskih modela, produbile su se spoznaje o kompleksnim interakcijama na tržištu rada s posebnim osvrtom na učinke modela fleksibilnosti koji je izražajniji u pojedinim zemljama EU-a.

Također, korištenjem neparametrijskih metoda precizno su se identificirale razlike u fleksibilnosti pojedinih tržišta rada, što daje dubinski uvid u konkretno stanje na tržištu rada EU-a u razdoblju od 2008. do 2018. godine.

Uvažavajući navedeno, kroz postavljene hipoteze analizom se došlo do sljedećih zaključaka;

H1. Čak 72 % tržišta rada Europske unije primjenjuje koncept fleksibilnosti u potpunosti (43 %) ili djelomično (29 %), što posljedično pozitivno utječe na gospodarski razvoj tih zemalja (validirano na temelju BDP-a po stanovniku).

H1.1. U 75 % analiziranih država povećanje udjela privremenog zapošljavanja i zapošljavanja na nepuno radno vrijeme ima u potpunosti (68 %) ili djelomično (7 %) pozitivan utjecaj na stopu zaposlenosti-

H1.2. S porastom udjela rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće u analiziranim zemljama Europske unije smanjuje se stopa nezaposlenosti u potpunosti (39 %) ili djelomično (14 %).

H2. U 100 % analiziranih država proporcija zaposlenosti na određeno radno vrijeme i proporcija zaposlenosti na nepuno radno vrijeme razlikuje se kod osoba različitih razina obrazovanja, s tim da je potvrđeno kako su visokoobrazovane osobe daleko manje zaposlene na određeno vrijeme i na nepuno radno vrijeme (analizirano od 2008. do 2018. godine).

$H3_1$ U 100 % analiziranih država vremensko razdoblje trajanja nezaposlenosti u izravnoj je korelaciji s dobnom strukturom radnika, s tim da je manji udio nezaposlenih zapažen kod osoba u dobi od 15 do 24 godine te od 55 do 64 godine.

$H3_2$ U 96 % analiziranih država (u svim državama, osim Bugarske) vremensko razdoblje trajanja nezaposlenosti u izravnoj je korelaciji s motivacijom radnika za traženjem novog posla, s tim da treba naglasiti kako su zaključci dobiveni kroz analizu podataka sljedeći - motivacija radnika za traženjem novog posla najveća je u prvih mjesec dana od nastanka nezaposlenosti te se u tom periodu i najviše koriste različite metode za pronalaženje posla.

2. METODOLOŠKI OKVIR ISTRAŽIVANJA

Metodološki okvir istraživanja je važan segment disertacije u kojem se istraživanje precizira predmetno, vremenski i područno. U ovom će se poglavlju navesti istraživačka pitanja, postaviti hipoteze te opisati uzorak i varijable. Jednako tako, precizirat će se cilj koji se želi istraživanjem postići i svrha istraživanja u disertaciji. U metodološkom dijelu također će se navesti i detaljno opisati primijenjene znanstvene metode, generirati struktura rada te apostrofirati očekivani znanstveni doprinos. Zaključno, u ovom poglavlju identificirat će se problemi istraživanja te ograničenja istog.

2.1. Istraživačka pitanja i postavljene hipoteze

Istraživački problem, koji se odnosi na utvrđivanje utjecaja fleksibilnosti radne snage na gospodarski razvoj zemalja Europske unije, detaljno će se pokušati razraditi kroz više osnovnih istraživačkih pitanja na koja će se u disertaciji pokušati odgovoriti, a to su:

1) je li tržište radne snage u državama EU-a fleksibilno na način da osigurava viši stupanj razvijenosti zemlje
2) utječe li pozitivno na stopu zaposlenosti povećanje udjela privremenog zapošljavanja i zapošljavanja na nepuno radno vrijeme
3) je li stopa nezaposlenosti manja u onim zemljama koje imaju veći udio fleksibilnih oblika rada - rad u smjenama, večernji i noćni rad, rad subotom i nedjeljom te rad od kuće
4) utječe li razina obrazovanja na spremnost osoba na zapošljavanje na određeno radno vrijeme i na rad na nepuno radno vrijeme
5) je li vremensko razdoblje trajanja nezaposlenosti u korelaciji s dobnom strukturom radnika i njihovom motivacijom za traženjem novog posla.

U skladu s dosadašnjim teorijskim znanjem i empirijskim istraživanjima, hipoteze koje će istraživanjem biti prihvaćene ili odbačene su:

H1.

Fleksibilnost tržišta radne snage pozitivno je korelirana sa stupnjem razvijenosti zemlje.

H1.1.

Povećanje udjela privremenog zapošljavanja i zapošljavanja na nepuno radno vrijeme ima pozitivan utjecaj na stopu zaposlenosti.

H1.2.

S porastom udjela rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće smanjuje se stopa nezaposlenosti.

Obrazloženje:

Za svaku zemlju EU-a bit će generiran statistički značajan model:

a) linearne povezanosti kriterijske varijable stope zaposlenosti s prediktorskim varijablama: privremeno zapošljavanje i zapošljavanje na nepuno radno vrijeme
b) nelinearne povezanosti kriterijske varijable stope zaposlenosti s prediktorskim varijablama: privremeno zapošljavanje i zapošljavanje na nepuno radno vrijeme

Također, za svaku zemlju EU-a bit će generiran statistički značajan model:

a) linearne povezanosti kriterijske varijable stope nezaposlenosti s prediktorskom varijablom SENSSH[1]
b) nelinearne povezanosti kriterijske varijable stope nezaposlenosti s prediktorskom varijablom SENSSH

Statistička obrada i analiza hipoteza H1.1 i H1.2 polučit će zaključke o utjecaju fleksibilnih oblika rada analiziranih u hipotezama na stopu zaposlenosti, odnosno stopu nezaposlenosti kao najčešće korištenih pokazatelja prosperiteta tržišta rada i važnih mjera koje projiciraju stanje gospodarstva, što posljedično utječe na stupanj razvijenosti zemalja koji je predmet analize u hipotezi H1.

H2.

Proporcija zaposlenosti na određeno radno vrijeme i proporcija zaposlenosti na nepuno radno vrijeme razlikuje se kod osoba različitih razina obrazovanja.

Obrazloženje:

Bit će identificirano postojanje statistički značajne razlike između proporcije visokoobrazovanih osoba zaposlenih na ugovor o radu na određeno vrijeme te proporcija srednjeobrazovanih i niskoobrazovanih osoba zaposlenih na ugovor o radu na određeno vrijeme. Također, bit će identificirano postojanje statistički značajne razlike između proporcije visokoobrazovanih osoba zaposlenih na nepuno radno vrijeme te proporcija srednjeobrazovanih i niskoobrazovanih osoba zaposlenih na nepuno radno vrijeme.

[1] SENSSH = ukupan broj osoba koje rade u nekom od sljedećih oblika rada: u smjenama/večernji rad/noćni rad/rad subotom/rad nedjeljom/rad od kuće

H3.

Vremensko razdoblje trajanja nezaposlenosti u izravnoj je korelaciji s dobnom strukturom radnika i njihovom motivacijom za traženjem novog posla.

Obrazloženje:

U hipotezi H3 analizira se nominalna varijabla vremensko razdoblje trajanja nezaposlenosti u odnosu na dvije nominalne varijable: dobna struktura radnika i motivacija radnika za traženjem novog posla. Stoga je analiza, zbog validnosti obrade podataka i donošenja zaključaka na temelju rezultata iste, podijeljena u dva dijela označena s $H3_1$ i $H3_2$ i to kako slijedi:

a) za svaku zemlju EU-a bit će identificirana statistički značajna povezanost između varijabli dobna struktura radnika i vremensko trajanje nezaposlenosti ($H3_1$). Također,
b) bit će identificirana statistički značajna povezanost između nominalnih varijabli vremensko trajanje nezaposlenosti i motivacija radnika za traženjem novog posla ($H3_2$).

2.2. Svrha i cilj istraživanja

Važan aspekt politike Europske Unije je postizanje visoke razine zaposlenosti, što je preduvjet za ostvarivanje zadovoljavajućeg životnog standarda u zemljama članicama Europske unije. Cilj Europske unije je postizanje što veće fleksibilnosti, slobode kretanja radnika i socijalna sigurnost. U cilju postizanja veće zaposlenosti, veće socijalne sigurnosti te boljeg obrazovanja, provode se mjere koje imaju za cilj stvoriti fleksibilna i sigurna tržišta rada s osnove mogućnosti zapošljavanja/pronalaska novog zaposlenja, smanjenja segmentacije na tržištu rada i smanjenja nepovoljnog položaja rizičnih skupina u zemlji te promoviranja regionalne, kvalifikacijske i sektorske mobilnosti. Pritom, tržište rada uključuje osobe koje su u potrazi za poslom, poslodavce, radnike koji su zaposleni, zadovoljni ili su u potrazi za novim poslom i boljim uvjetima rada.

Ovim radom želi se istražiti je li tržište radne snage u državama EU-a fleksibilno na način da osigurava viši stupanj razvijenosti zemlje. U fokusu istraživanja su glavni uzroci nezaposlenosti te čimbenici koji utječu na njihovo vremensko trajanje. Analizom se, također, želi utvrditi utječe li razina obrazovanja i u kojoj mjeri na spremnost osoba na privremeni rad i na rad na nepuno radno vrijeme te koje metode za pronalaženje posla osobe najčešće koriste za traženje novog zaposlenja.

Temeljna svrha ovog rada je proučiti i sustavno elaborirati osnovne teorijske postavke socio-ekonomskih trendova i zakonskog okvira tržišta rada EU-a.

Cilj je disertacije analizirati relevantna obilježja tržišta radne snage EU-a te raspon fleksibilnosti radne snage na tržištu rada zemalja EU-a. Sekundarni cilj rada je identificirati uzroke i kretanje zaposlenosti i nezaposlenosti na tržištu rada EU-a, utjecaj razine obrazovanja na zapošljavanje te evaluirati učinkovitost mjera aktivnih politika tržišta rada u suzbijanju nezaposlenosti. U sklopu ovog cilja ocijenit će se i utjecaj dobne strukture osoba koje traže posao na vremensko razdoblje trajanja nezaposlenosti te učinak korištenja određenih metoda za pronalaženje posla na smanjene vremenskog trajanja nezaposlenosti. Posljednji cilj rada je, pomoću znanstvenih metoda, kreirati prediktivni model kojim će se identificirati utjecaj fleksibilnosti tržišta rada na gospodarski razvoj.

2.3. Primijenjene znanstvene metode

Cjelokupni istraživački segment ove doktorske disertacije temelji se na službenim podacima Eurostata o istraživanju radne snage Europske unije (EU-LFS[2]) koje obuhvaća podatke od 1983. nadalje. EU-LFS-ovi službeni podaci koji se koriste u disertaciji sadrže podatke za sve države članice EU-a. Podaci pokrivaju sve industrije i profesije.

U disertaciji se analiziraju podaci približno 2 milijuna ispitanika u razdoblju od 2008. godine do 2018. godine koji su dobiveni na temelju odobrenog projekta RPP 35/2020-LFS od Europske komisije i Eurostata te preuzeti s platforme S-CIRCABC.

U analizu su uključene zaposlene i nezaposlene osobe starije od 15 godina i mlađe od 64 godine koje žive u kućanstvima na razini svih članica EU-a. Osobe koje obavljaju obvezni vojni rok ili rad u javnom interesu nisu uključene u ciljanu skupinu istraživanja.

U znanstvenom istraživanju, za potrebe doktorske disertacije, upotrijebio se u odgovarajućoj mjeri, veći broj znanstveno-istraživačkih metoda kako bi se osigurale što pouzdanije, vjerodostojnije i konkretnije spoznaje i zaključci o obrađenoj temi. Njihova je upotreba ovisila o postavljenim ciljevima i hipotezama te su se međusobno nadopunjavale u svrhu ostvarenja postavljenih ciljeva i dokazivanja hipoteza.

Znanstveno-istraživačke metode, koje su se koristile prilikom izrade doktorske disertacije, su sljedeće. U teorijskom dijelu korištena je metoda generalizacije, kako bi se od posebnog pojma došlo do općenitijeg te metoda specijalizacije kojom se od općenitijeg pojma dolazilo do pojmova užih po opsegu, a bogatijih po sadržaju. Nadalje, u ovom dijelu koristila se metoda

[2] EU-LFS = Anketa o radnoj snazi Europske unije (engl. *European Union Labour Force Survey*)

sustavnog pristupa kojom su se razmatrale različite komponente određenih struktura i organizacija zbog boljeg razumijevanja njihove suštine. Također, korištena je metoda apstrakcije kojom se je u pojedinim dijelovima izdvajalo opće, a eliminiralo posebno i individualno te obratno i metoda konkretizacije kojom se u sintezu spajalo opće s posebnim, odnosno, individualnim ili posebno s općim. U ovom dijelu su korištene i metoda deskripcije koja je služila za ocrtavanje procesa i činjenica te komparativna metoda za uspoređivanje istih, ali i sličnih činjenica, procesa i odnosa. U teorijskom dijelu disertacije je, između ostalog, korištena i metoda analize kojom su se raščlanjivali složeniji pojmovi i zaključci na jednostavnije sastavne dijelove i elemente te metoda sinteze kojom su se u analizama povezali određeni elementi. Statistička metoda je korištena u empirijskom dijelu doktorske disertacije, a njome su se u sklopu hipoteza otkrivali različiti trendovi (rast, stagnacija ili opadanje) te predviđali tijekovi kretanja određenih pojava.

Metoda deskriptivnog i simboličkog modeliranja bila je korištena za potrebe oblikovanja prediktivnog modela u disertaciji te kako bi se opisale međusobne spone između određenih struktura u modelu i odnosi analogni predmetu istraživanja.

Pri donošenju zaključaka u disertaciji u empirijskom dijelu te u samom zaključku, koristila se induktivna metoda kojom se, na temelju pojedinačnih činjenica, dolazilo do općih zaključaka i obratno, deduktivnom metodom iz općih stavova su se izvodili posebni zaključci. Metodom kauzalnog zaključivanja su se utvrdile uzročno-posljedične veze među promatranim pojavama. Pri zaključivanju su se, između ostaloga, koristile i metoda dokazivanja kojom su se utvrđivale istinitosti određenih stavova ili teorija navedenih u hipotezama te metoda opovrgavanja koja se sastoji u dokazivanju pogrešnosti teze, primjerice, odbacivanju određene hipoteze.

Podaci iz uzorka istraživanja obrađeni su primarno statističkim postupcima za izračunavanje pomoću statističkih programa SPSS i Statistica. Statistička značajnost postavljena je u analizi na razinu od $\alpha = 0.05$. Dobiveni zaključci odnose se isključivo na promatrani uzorak, nikako na populaciju.

U hipotezi H1. korištena je linearna korelacijska analiza te je izračunat koeficijent korelacije, koeficijent determinacije te je pridružena statistička značajnost. Također, korištena je regresijska analiza – model višestruke regresije i to višestruka linearna regresija te višestruka nelinearna regresija pri čemu se odredila značajnost modela, koeficijent determinacije, pravac regresije i pripadajući ponderi prediktorskih varijabli.

U hipotezi H2. korišten je test značajnosti razlike između proporcija.

U hipotezi H3. određene su kontingencijske tablice te je primijenjen χ^2-test za ispitivanje povezanosti dvaju nominalnih varijabli.

2.4. Struktura rada i očekivani znanstveni doprinos

Unutarnja koherencija u istraživačkom postupku u disertaciji se ostvaruje nizom od devet poglavlja.

U uvodnom dijelu disertacije se iznose početna razmatranja, obrazlaže se potreba za istraživanjem, njena opravdanost i aktualnost.

U drugom poglavlju se postavljaju istraživačka pitanja i definiraju se temeljne hipoteze rada na osnovi kojih se provodi istraživanje. U ovom poglavlju se definira svrha i cilj istraživanja te navode primijenjene znanstvene metode u radu. Također, u istom poglavlju, navedena je struktura rada i očekivani znanstveni doprinos, kao i problemi i ograničenja u istraživanju.

U trećem poglavlju se daje pregled glavnih postignuća u području fleksibilnosti tržišta rada Europske unije na temelju znanstvene i stručne literature, referirajući se na eminentne autore u navedenom području.

U četvrtom poglavlju opisuje se i definira tržište rada EU-a. Analizira se kretanje radne snage na tržištu rada EU-a s posebnim osvrtom na migracije i mobilnost na području Europske unije. U ovom poglavlju se ističe značaj obrazovanja te se ono promatra s aspekta konkurentnosti na tržištu rada te, s druge strane, u vidu potrebe za sve prisutnijim cjeloživotnim obrazovanjem. U ovom poglavlju se analizira i ponuda poslova na tržištu rada EU-a, zaključno s novim oblicima rada u digitalnoj ekonomiji EU-a.

U petom poglavlju će biti dan detaljan pregled socio-ekonomskih trendova i politika na tržištu rada EU-a. Bit će navedeni makroekonomski indikatori i socijalna situacija u EU-u, jednako kao i institucije i zakonodavni okvir tržišta rada EU-a. Nadalje, bit će profilirane aktivne politike tržišta rada EU-a koje nedvojbeno utječu na zapošljavanje i socijalnu uključenost, odnosno djeluju u određenom aspektu na razinu nezaposlenosti kao socijalnog rizika na tržištu rada EU-a. Bit će prikazana ekonomska analiza diskriminacije na tržištu rada i pravna regulativa te promjene strukture rada i reforma socijalne politike. U ovom poglavlju će zaključno biti obrađen pojam sigurnosti u radnom i relevantnom socijalnom pravu na tržištu rada EU-a.

U šestom poglavlju definirat će se pojam fleksibilnosti tržišta rada EU-a zajedno s politikama i direktivama EU-a o fleksibilnosti tržišta rada. U istom poglavlju će se analizirati fleksibilnost tržišta rada EU-a u kontekstu fleksibilnosti procesa rada, fleksibilnosti radnopravnog statusa,

fleksibilnosti radnog vremena te fleksibilnosti organizacije rada. Zaključno će se odrediti fleksigurnost kao pojmovna sinergija fleksibilnosti i sigurnosti na tržištu rada EU-a.

Sedmo poglavlje predstavlja samu srž doktorske disertacije i u njemu se ogleda znanstveni doprinos rada. U ovom poglavlju će se analizirati utjecaj fleksibilnosti radne snage na gospodarski razvoj zemalja EU-a. U okviru ovog poglavlja će se definirati varijable koje će se koristiti u radu te metodologija njihova izračuna. Nadalje, analizirat će se uzorak istraživanja te će se statistički obraditi i analizirati podaci istraživanja.

Rasprava je naziv osmog poglavlja u kojem će se diskutirati o predmetu i problemu istraživanja, analizirajući postojeće informacije i njihove izvore, provjeravajući postavljene hipoteze s dobivenim rezultatima provedenog istraživanja.

Nakon osmog poglavlja, slijedi zaključak u kojem će se sumirati rezultati istraživanja, prikazati povezanost doprinosa s ciljevima te navesti prijedlozi za buduća istraživanja opisane problematike. Nakon zaključka će se navesti literatura, popis tablica, slika i grafikona te popis kratica i simbola.

Očekivani doprinos ekonomskoj znanosti u teorijskom smislu očituje se kroz istraživanje dobivenih spoznaja koje bi trebale poslužiti boljem razumijevanju implementacije fleksibilnih oblika rada na tržište rada EU-a i na taj način dodatno objasniti ukupan varijabilitet u dosad slabije istraženim segmentima procesa zapošljavanja osoba u pojedinim fleksibilnim oblicima na tržištu rada EU-a. Dostupni radovi dosadašnjih istraživanja pridonose jednim dijelom boljem razjašnjenju ukupne varijance mjerenja utjecaja fleksibilnosti radne snage na gospodarski razvoj pojedine države članice EU-a. Međutim, najveći dio te varijance je neistražen i samim time nepoznat. Stoga je istraživanje od istaknutog značaja, s obzirom na to da će pokušati preciznije utvrditi postoje li razlike u fleksibilnosti tržišta rada promatranih država EU-a te utječu li iste na gospodarski razvoj država i u kojoj mjeri. Doprinos se očekuje i u utvrđivanju čimbenika koji u najvećoj mjeri utječu na fleksibilnost tržišta rada zemalja EU-a.

Znanstveni doprinos disertacije u aplikativnom smislu očekuje se kroz rezultate istraživanja koji mogu biti temelj za prosudbe i kreiranje novih strategija i politika zapošljavanja od nositelja političkih odluka te učinkovitije kombiniranje mjera kojim bi se potanula fleksibilnost tržišta rada. Osim navedenog, rezultati mogu biti podloga za generiranje inicijativa za promicanje ravnoteže na tržištu rada, ovisno o analizi i stanju na nacionalnim razinama, kao i u osmišljavanju pravog miksa političkih mjera koje se bave dimenzijama fleksibilnosti i sigurnosti rada.

2.5. Problemi i ograničenja u istraživanju

Nekoliko je problema i ograničenja vezanih uz istraživanje u ovoj doktorskoj disertaciji. Prije svega, ograničenje istraživanja se ogleda u tome što je promatrano razdoblje limitirano na jedanaest godina, točnije od 2008. do 2018. godine. Također, treba napomenuti kako podaci za Maltu za 2009. godinu nisu dostupni, što je podatak koji bitno ne utječe na rezultate u nizu od 11 godina za jednu od promatranih 28 država, niti mijenja krajnji ishod po pitanju potvrđivanja ili odbacivanja hipoteza.

U empirijskom dijelu disertacije analiza je ograničena na fleksibilnost radnog vremena i fleksibilnost radnopravnog statusa u kontekstu narednih varijabli: *rad na određeno vrijeme*, *rad s nepunim radnim vremenom*, *privremeno zapošljavanje*, *rad u smjenama*, *večernji rad*, *noćni rad*, *rad subotom*, *rad nedjeljom* i *rad od kuće*. Istraživanje nije prošireno na analizu fleksibilnosti procesa rada te fleksibilnost organizacije rada, što je u okvirima fleksibilnosti tržišta rada preporuka za daljnje istraživanje.

Dodatno ograničenje može se pronaći u hipotezi H1. u kojoj je kao pokazatelj razvijenosti zemalja korišten samo BDP po stanovniku. Iako se isti koristi kao najčešća varijabla putem koje se mjeri gospodarski rast, uz njega bi se mogli analizirati: rast populacije, profesionalna struktura radne snage, urbanizacija, potrošnja po stanovniku, infrastruktura i društveni uvjeti, što je svakako preporuka za daljnje istraživanje.

U hipotezi H1.2 nelinearni model nije mogao biti generiran zbog nedostatka podataka za naredne četiri zemlje: Njemačka, Francuska, Luksemburg i Malta. Ali je analiza za navedene zemlje napravljena prema linearnom modelu, što je u ovom kontekstu dostatno za povrđivanje ili odbacivanje hipoteze.

Još jedno ograničenje se ogleda u analizi podataka za hipotezu H1.2. u kojoj se koristi stopa nezaposlenosti koja se, prema smjernicama Međunarodne organizacije rada, odnosi na osobe u dobi od 15 do 74 godine (iznimno u Italiji, Španjolskoj i Ujedinjenom Kraljevstvu od 16 do 74 godine). U uzorku koji se analizira u disertaciji uključene su osobe od 15 do 64 godine. U dobi od 64 godine veliki dio populacije odlazi u mirovinu, a oni koji ne odlaze ulaze u radne odnose s nepunim radnim vremenom. U Europskoj Uniji u 2018. godini najviši postotak ljudi u dobi od 65 do 74 godine, koji su bili zaposleni, zabilježen je u Estoniji, njih više od jedne četvrtine (26 %). Dok, s druge strane, stope iznad 15 % zabilježene su samo u Rumunjskoj, Litvi, Portugalu, Ujedinjenom Kraljevstvu, Irskoj, Švedskoj i Latviji.

Forbes navodi kako, prema Bureau of Labor Statistics (BLS), u 2020. godini 26,6 % ljudi u svijetu u dobi od 65 do 74 godine je bilo dio radne snage. Ta će se brojka, prema dosadašnjim

parametrima, nastaviti kretati ulaznom putanjom. Ali ako se promotri razdoblje od 2008. do 2018. godine koje se analizira u disertaciji, ta brojka koja se odnosi na osobe iznad 64 godine ne bi bitno utjecala i doprinijela promjeni, kroz analizu, dobivenih rezultata. Stoga, preporuka za daljnje istraživanje bi svakako bila analizirati udio radne snage u dobi iznad 65 godina u svim zemljama EU-a nakon 2018. godine.

U hipotezi H3. kodovi 4-8 za varijablu DURUNE[3] nisu dio analize jer je u upitniku evidentirano kako u uzorku nema ispitanika čije je trajanje nezaposlenosti duže od 6 mjeseci. Preporuka za daljnje istraživanje je usmjerena na analizu tržišta rada EU-a i prikupljanje podataka o nezaposlenima čije je trajanje nezaposlenosti duže od 6 mjeseci kako bi se otkrili uzroci takvih okolnosti te pronašlo rješenje i dale preporuke za akcije koje bi bile usmjerene upravo na smanjenje broja osoba koje su nezaposlene duže od 6 mjeseci.

[3] DURUNE = trajanje nezaposlenosti

3. PRIKAZ DOSADAŠNJIH ISTRAŽIVANJA

S ciljem boljeg razumijevanja problematike koja se istražuje u disertaciji, nužno je sagledati najvažnije rezultate prethodno provedenih studija te analizirati teorije gospodarskog rasta. Stoga su u nastavku prezentirane ključne spoznaje do kojih su došli autori istražujući različite aspekte fleksibilnosti tržišta rada u kontekstu ekonomskog razvoja te su navedene teorije i ekonomski modeli koji prikazuju i istražuju kriterije i podlogu za gospodarski razvoj.

U literaturi postoje tri smjera vezana uz stavove i poimanje gospodarskog razvoja. Prvi smjer, čiji su predstavnici Mishan i Boulding, predstavlja gospodarski razvoj kao kategoriju koja dovodi do problema i pogoršanja, a ne poboljšanja te se može reći kako ovaj smjer karakterizira pesimističan pogled na razvoj jer se na isti gleda sa skepticizmom. Mishan i Boulding razlog tome vide u činjenici da je upravo rast odgovoran za većinu društvenih stresova, za pogrešnu inflatornu i intervencionističku ekonomsku politiku. Ono što je ključno naglasiti za ovaj smjer je stav da je za zadovoljavajući život bitno provođenje stacionarne ekonomije te pronalaženje alternativnih ekonomskih i socijalnih politika u tom kontekstu.

Za razliku od Mishana i Bouldinga, koji u svom postulatu nude oprečnost rastu i razvoju gospodarstva, Beckerman i Kneese, kao predstavnici druge škole, promatraju gospodarski rast kroz prizmu moderne marginalne analize oportunitetnih troškova. Postavljaju pitanje o vrednovanju rasta na margini u usporedbi s drugim ciljevima te se u njihovoj teoriji pokušava dati odgovor na pitanje kako procijeniti povećanje rasta u jedinicama slobodnog vremena ili odgađanje sadašnje potrošnje povećanjem ulaganja za budućnost. Ovaj pristup je manje subjektivan te se njime racionalno uspoređuje veći rast ili manji rast na račun manjeg ili većeg ostvarenja drugih ciljeva.

Treći pristup Keynesa i njegovih sljedbenika stavlja u fokus pojedince koji bi, prema njihovoj doktrini, trebali štedjeti manje i trošiti više, podižući svoju graničnu sklonost potrošnji kako bi se postigao gospodarski rast i puna zaposlenost. Prema ovoj teoriji, jedan dolar potrošen na fiskalne poticaje na kraju stvara više od jednog dolara rasta. Oni su vizualizirali rast kao rješavanje ekonomskog problema čovječanstva unutar 100 godina. Smatraju da je snaga eksponencijalnog rasta takva da bi se kapitalna oprema mogla povećati na oko deset puta u odnosu na predratnu razinu, a ljudski napor bi se uvelike smanjio. Međutim, Keynes je pretpostavio da neće biti velikih ratova, zagađenja, značajnog povećanja stanovništva i nedostatka neobnovljivih resursa. Ipak, danas, gotovo 100 godina nakon, situacija nije ni približno takva. Čak naprotiv, ako se nastave sadašnji trendovi u porastu stanovništva i industrijalizacije, uskoro bi moglo doći do granica rasta.

Pitanje važnosti različitih čimbenika u određivanju gospodarskog rasta seže još od Adama Smitha te T. R. Malthusa koji su tvrdili da zemlja ima ključnu ulogu u gospodarskom rastu. Smith je smatrao da se proizvodnja povećava paralelno s povećanjem stanovništva, što znači da bi realna nadnica po radniku bila konstantna tijekom vremena. No, s vremenom, stanovništvo bi se nastavilo povećavati te bi se u konačnici sva zemlja mogla zauzeti. Nakon toga više neće biti moguć scenarij uravnoteženog rasta zemlje, rada i proizvodnje, već dolazi do zakona opadajućih prinosa (jer dolazi do opadajućeg graničnog proizvoda rada, a time i do pada realnih nadnica). Jednako tako, Malthus smatra da će povećanje stanovništva dovesti do situacije u kojoj će radnici živjeti u minimalnim uvjetima za preživljavanje. Njegova teorija se zasniva na mišljenju kako stanovništvo raste kada su nadnice iznad egzistencijalne razine, dok, s druge strane, nadnice ispod egzistencijalne razine bi dovele do depopulacije. Ovdje će se navesti kratka digresija - nadnice su, prema klasičnoj školi, dugoročno određene troškovima života, troškovi života prema D. Ricardu (hrana i ostale potrepštine) su elastični i ovise o navikama i običajima ljudi.

Malthusova pesimistična teorija ima osnovu u tezi da udvostručenje stanovništva dovodi do gotovo dvostrukog povećnja hrane i odjeće, što povratno smanjuje proizvodnju po stanovniku jer je sve više ljudi na ograničenoj zemlji pa opadajući prinosi smanjuju proizvodnju po osobi. Malthusova teorija se pokazala neprimjenjivom na prethodno i početak ovog stoljeća jer nije uključivala tehnološki napredak te nije navedena mogućnost kapitalnih investicija koje bi mogle prevladati zakon opadajućih prinosa.

Da akumulacija kapitala i tehnološki napredak donose promjene i umnogome utječu na gospodarski razvoj, činjenica je koju je dokazao Robert M. Sollow. Jednako tako, Sollow navodi kako svi potrošači u gospodarstvu štede konstantan udio svojih prihoda i troše ostatak.

R. Harrod je, slično kao i Sollow, došao do zaključka da zajednica želi trošiti konstantan dio dohotka, a ostatak predstavlja štednju. I on, kao Sollow, tvrdi kako je trenutna tehnologija ključna te nameće omjer kombinacije kapitala i rada. E. Domar, za razliku od Harroda, ne navodi eksplicitno tehnološki napredak, ali ističe dvostruku ulogu investicija u proizvodnji i razvoju.

Kada se spominje tehnološki razvoj, bitno je spomenuti i J. Schumpetera koji je isticao ulogu poduzetnika koji, između ostalog, inicira i zapaža tehnička poboljšanja te ih uspijeva praktično koristiti. Ovaj pregled se može zaključiti sa Sollowljevom tvrdnjom kako više od polovice povećane proizvodnje prije potječe od tehničkih promjerna, industrijskih poboljšanja te znanstvenog napretka, nego od štednje i akumulacije.

U narednoj tablici (tablica 1.) bit će analitički prikazana prethodna istraživanja povezana s predmetnom problematikom u disertaciji.

Tablica 1. Analitički prikaz prethodnih istraživanja povezanih s predmetnom problematikom u disertaciji

Autori i godina istraživanja	Varijabla	Utjecaj na fleksibilnost tržišta rada
Okun (1962) Seyfried (2005) Volker (2005) Zaidi (2005) Noor i suautori (2007) Eita i Ashipala (2010) Meidani i Zabihi (2011) Jesus (2012) Hafiz i suautori (2014) Balan (2014) Hassan i Nassar (2015) Chand, Tiwari i Phuyal (2017)	nezaposlenost i stopa BDP-a	- smanjenje nezaposlenosti za 1 % je produkt povećanja bruto domaćeg proizvoda za 2 % - stopa nezaposlenosti se smanjuje kao rezultat povećanja gospodarskog rasta - postoji obrnuti (negativni) odnos između promjena u stopama rasta realnog BDP-a i nezaposlenosti
Mayes i Viren (2002) Silvapulle, Moosa i Silvapulle (2004) Holmes i Silverstone (2006) Owyang i Sekhposyan (2012) Jardin i Gaétan (2012) Mosikari (2013) Valadkhani i Smyth (2015) Koutroulis i suautori (2016) Tang i Bethencourt (2017) Nebot, Beyaert i García-Solanes (2019)		- odnos između promjena u stopama rasta realnog BDP-a i nezaposlenosti je pozitivan - Okunovi nekonstantni koeficijenti tijekom vremena zapravo bi mogli biti posljedica različitih režima u eksplanatornim varijablama, a ne izravno zbog strukturne promjene povezane s vremenom - asimetrija u Okunovom zakonu može biti rezultat neusklađenosti između poslova i nezaposlenosti u različitim regijama i sektorima na tržištu rada
Klau i Mittelstadt (1986) Alonson i suautori (2004) Bande i Karanassou (2009) Barbieri (2009)	stopa nezaposlenosti u kontekstu fleksibilnih oblika rada	- razlike u regionalnim stopama nezaposlenosti ovise o stupnju regionalne fleksibilnosti tržišta rada - zemlje s fleksibilnim tržištem rada imaju malu nezaposlenost

Baráth i Wojčák (2017), (2020)		- cjenovni šokovi koji nastaju u uvjetima »krutih« tržišta rada dovode do veće strukturne nezaposlenosti, dok fleksibilna tržišta rada omogućuju prilagodbe takvim šokovima bez gubitka zaposlenosti ili s malim gubitkom zaposlenosti
Blanchard i Wolfers (2000) Carmeci i Mauro (2003) Palokangas (2003) Di Tell i MacCulloch (2005) Urban i Velo (2006) Anderson (2009) Parello (2010) Bruno i Rovelli (2010) Herwartz i Niebuhr (2011) Ball, Leigh i Loungani (2012) Balleer i suautori (2014) Zweig (2015) Lastauskasov i Stakenasbov (2017) Sahnoun i Abdennadher (2019)	aktivne politike tržišta rada (nasuprot rigidnim tržištima rada)	- više stope zaposlenosti općenito su pozitivno povezane s korištenjem aktivnih politika tržišta rada i njihovim mjerama, a negativno s institucijama i politikama koje izazivaju rigidnost na tržištu rada - aktivne mjere politika tržišta rada uzrokuju veće socijalne interakcije, a time i smanjen osjećaj društvene isključenosti - zemlje s fleksibilnim tržištem rada imaju bolje ekonomske performanse (povećanje zaposlenosti i stope participacije) od rigidnih tržišta rada - veća zaštita pri zapošljavanju jedan je od čimbenika koji povećavaju trajanje nezaposlenosti u Europi, a time i stopu nezaposlenosti - visoki stupanj fleksibilnosti tržišta implicira veću spremnost na gospodarske transformacije koje su potaknute globalizacijom - negativan učinak na dugoročni gospodarski rast i zaposlenost imaju velikodušan sustav socijalne skrbi, rigidno tržište rada i restriktivan zakon o radu

Izvor: Izrada autorice

Nakon pregleda i analize do sada objavljenih studija, evidentno je da je većina autora, koja je proučavala problematiku tržišta radne snage, relativno rijetko istraživala fleksibilnost iste na razini svih država članica Europske unije, kao što je to slučaj u disertaciji. Neovisno o tome, razmatranje prethodnih istraživanja nužno je za sustavni i cjeloviti pristup problematici fleksibilnosti radne snage i utjecaju iste na gospodarski razvoj zemalja analiziranih u empirijskom dijelu disertacije.

Cilj svakog gospodarstva je postići veću stopu gospodarskog rasta kako bi se smanjila razina nezaposlenosti. Arthur Okun (1962) je istraživao odnos između nezaposlenosti i gospodarskog rasta SAD-a i uočio značajan negativan dugoročni odnos. Također se zalagao za povećanje razine proizvodnje zbog postizanja razine pune zaposlenosti.

Prema Okunovom zakonu, ako se nezaposlenost pomakne iznad normalne točke za jedan posto, rast BDP-a pada za dva posto. To znači da su nezaposlenost i gospodarski rast obrnuto proporcionalni. Ovaj je zakon često bio predmet istraživanja mnogih autora kako bi testirali uzročnu vezu između rasta proizvodnje i razine nezaposlenosti između država. No u istim istraživanjima se nerijetko mogu pronaći oprečni zaključci.

Seyfried (2005) istražuje odnos između ekonomskog rasta i razine zaposlenosti za deset odabranih, razvijenih ekonomija za razdoblje od 1990. do 2003. Njegovi rezultati su u skladu sa značajnim negativnim odnosom između ekonomskog rasta i razine nezaposlenosti odabranih razvijenih ekonomija. Noor i suautori (2007) istraživali su utjecaj gospodarskog rasta na razinu nezaposlenosti u Bangladešu za razdoblje od 1970. do 2004. koristeći metodu najmanjih kvadrata. Rezultati njegovog empirijskog istraživanja ukazuju na značajan negativan utjecaj gospodarskog rasta na razinu nezaposlenosti. Metodom najmanjih kvadrata u svom istraživanju služi se i Jesus (2012) koji istražuje odnos između nezaposlenosti i gospodarskog rasta u Peruu i Limi za razdoblje od 1992. do 2012. godine. Rezultati potvrđuju negativan odnos između nezaposlenosti i gospodarskog rasta u obama slučajevima.

Eita i Ashipala (2010) su istraživali uzroke nezaposlenosti u Namibiji za razdoblje od 1971. do 2007. koristeći Engle-Grangerov test za kointegraciju u dvama koracima. Njihovi rezultati sukladni su značajnom negativnom učinku gospodarskog rasta na nezaposlenost u Namibiji. Hafiz, Nazir, Abbas i Sana (2014) također su uočili negativan odnos između nezaposlenosti i ekonomskog rasta u Pakistanu. Rezultat je potvrđen Okunovim zakonom.

Balan (2014) zaključuje kako postoji statistički značajan negativan učinak BDP-a na nezaposlenost, a učinak neto prosječne plaće na nezaposlenost mladih je pozitivan. Hassan i Nassar (2015) su u svom istraživanju utvrdili kako na stopu nezaposlenosti negativno utječe gospodarski rast. Do jednakog zaključka dolaze i Chand, Tiwari i Phuyal (2017). Navedena

empirijska istraživanja potvrdila su značajan negativan utjecaj nezaposlenosti na gospodarski rast.

U literaturi se jednako tako mogu pronaći studije u kojima se istraživao utjecaj gospodarskog rasta na razinu nezaposlenosti, ali se u istima nije potvrdio negativan odnos.

Mayes and Viren (2002) objašnjavaju asimetriju u Okunovom zakonu kao rezultat neusklađenosti između poslova i nezaposlenosti u različitim regijama i sektorima na tržištu rada. Silvapulle, Moosa i Silvapulle (2004) asimetriju u Okunovu zakonu objašnjavaju kroz tripartitnu teorijsku osnovu koju čine institucionalna rigidnost, gomilanje radne snage te nesklonost poduzeća riziku. Owyang i Sekhposyan (2012) navode kako bi nekonstantnost Okunovih koeficijenata tijekom vremena zapravo mogla biti posljedica različitih režima u eksplanatornim varijablama, a ne izravno zbog strukturne promjene povezane s vremenom. Jardin and Gaétan (2012) koriste fleksibilniji semiparametrijski pristup Kernela na panel podacima za 16 europskih zemalja i potvrđuju nelinearnost u prosječnom Okunovom zakonu svih tih zemalja. Mosikari (2013) u svom istraživanju razmatra učinak nezaposlenosti na bruto domaći proizvod u Južnoj Africi u razdoblju od 1980. do 2011. Primjenom Grangerovog testa uzročnosti utvrđeno je kako ne postoji uzročnost između stope nezaposlenosti i rasta BDP-a.

Koristeći metodologiju sličnu Holmesu i Silverstoneu (2006), Valadkhani i Smyth (2015) procjenjuju asimetrične Okunove odnose za SAD. Iako to čine oko egzogene fiksne nulte vrijednosti cikličke nezaposlenosti, također detektiraju asimetriju u Okunovom zakonu. Tang i Bethencourt (2017) procjenjuju asimetrije nelinearnim autoregresijskim modeliranjem distribuiranog kašnjenja na sličan način kao što su to u istraživanju napravili Koutroulis i suautori (2016). Nebot, Beyaert i García-Solanes (2019) navode kako u njihovom istraživanju postoje značajne razlike između Okunova zakona zemalja eurozone, posebice između jezgre i Španjolske, što implicira potrebu za smanjenjem institucionalnih razlika i regulacije impliciranih nacionalnih tržišta rada.

Na temelju uvida u dostupnu literaturu, autori koji su istraživali pozadinu raznolikosti na tržištu rada EU-a te nejednakosti u vidu strukturnih reformi tržišta rada koje provode pojedine članice EU-a su Dafermos i Papatheodorou (2013) koji u svom radu proučavaju utjecaj makroekonomskih i institucionalnih čimbenika u svrhu pronalaska pokretača nejednakosti i siromaštva u EU-u. Koristeći tehniku analize panel podataka, posebnu pozornost su posvetili utjecaju promjene okruženja u makroekonomskom smislu, važnosti socijalne zaštite i institucija tržišta rada. U empirijskoj analizi koju su proveli pokazalo se da socijalni transferi u gotovini, i to uglavnom transferi koji ne uključuju mirovine, imaju izražen utjecaj na nejednakost i siromaštvo. Ovo istraživanje je bitno u kontekstu disertacije jer ističe čimbenike koji utječu na

nejednakost i siromaštvo, a koje Europska unija nastoji minimalizirati u što većoj mjeri zajedničkom socijalnom politikom.

Acemoglu (2002) utvrđuje tehničke promjene i nejednakosti na tržištu rada. U svom djelu ističe kako dvadeseto stoljeće karakteriziraju tehničke promjene pristrane prema vještinama jer je nagli porast ponude kvalificiranih radnika potaknuo razvoj tehnologija koje se nadopunjuju upravo vještinama. Tehnologija ima bitnu ulogu u primjeni fleksibilnih oblika rada, prvenstveno kada se govori o izdvojenom radnom mjestu ili zanimanju kao što je *freelancer*. Dobiveni rezultati Acemoglua u potpunosti su u skladu s rezultatima istraživanja Šribara (2005) koji navodi kako, zahvaljujući ubrzanom razvoju tehnologija, nastaju nove mogućnosti vezane uz rad te mjesta rada koja postaju fleksibilnija.

O nejednakosti plaća, fleksibilnosti i dualnosti tržišta rada u istočnoj i zapadnoj Europi pišu u svom djelu Hölscher, Perugini i Pompei (2014). Autori prikazuju složenost i heterogenost tržišta rada zemalja članica EU-a 2007. godine u počecima nastanka ekonomske krize u kontekstu komponenata vezanih uz razlike u zaradi, a s posebnim naglaskom na dimenzije fleksibilnosti tržišta rada koje se mogu identificirati s ugovornim aranžmanima - privremeno naspram stalnog zaposlenja i samozapošljavanje. Od 2007. godine do danas su se dogodile mnoge promjene: od zakonodavstvenih, institucijskih, tehnoloških do društvenih te same učestalosti primjene ugovornih aranžmana, kao što su privremeno zapošljavanje i samozapošljavanje. Zanimljivo bi bilo usporediti pojavnost navedenih ugovornih aranžmana u 2020. i 2021. godini u kontekstu krize uzrokovane pandemijom.

U fokusu Lastauskasovog i Stakenasbovog (2017) istraživanja su strukturne reforme tržišta rada u EU-15 gdje, osim strukturnih promjena, analiziraju i ekonomski dinamiku zemalja EU-15. U svom radu, na temelju triju alata politike tržišta rada - naknadama za nezaposlenost, politikama aktivacije i poreznim klinom, ističu da se one raspršuju u otvorenim gospodarstvima. Također su dokumentirali dokaze o pozitivnom i negativnom prelijevanju politika među europskim gospodarstvima te smatraju kako koordinacija jača makroekonomske odgovore na politike tržišta rada. Jednako tako, Bruno i Rovelli (2010) ističu kako su više stope zaposlenosti općenito pozitivno povezane s korištenjem aktivnih politika tržišta rada i njihovim mjerama, a negativno s institucijama i politikama koje izazivaju rigidnost na tržištu rada. Dobiveni rezultati u potpunosti su u skladu s rezultatima istraživanja Andersona (2009) koji dodatno navodi kako aktivne mjere politika tržišta rada uzrokuju veće socijalne interakcije, a time i smanjen osjećaj društvene isključenosti. Anderson, kao i Lastauskasov i Stakenasbov, zaključuje kako navedene politike pozitivno utječu na obrasce država u kontekstu društvene kohezije. Carmeci i Mauro (2003), Herwartz i Niebuhr (2011), Parello (2010) te Ball, Leigh and Loungani (2012) smatraju

kako negativan učinak na dugoročni gospodarski rast i zaposlenost imaju velikodušan sustav socijalne skrbi, rigidno tržište rada i restriktivan zakon o radu.

Tematikom fleksibilnosti tržišta radne snage, zaposlenosti te stopama nezaposlenosti bavi se nekoliko autora. Jedni od najrelevantnijih autora su svakako Baráth i Wojčák (2020) koji su u svom djelu analizirali učinke promjena stope nezaposlenosti, BDP-a po stanovniku[4] i skraćenog radnog vremena u odabranim europskim zemljama. Pritom, u istom članku utvrđuju koji od ekonomskih pokazatelja značajno izravno ili neizravno utječu na fleksibilnost izbora zaposlenika i ravnotežu radnog života u odabranim zemljama. Isti autori su tri godine ranije (2017) pisali o razlikama u primjeni nepunog radnog vremena u zemljama EU-a, prednostima i nedostacima istih. Baráth i Wojčák su u navedenom radu saželi pozitivne i negativne aspekte rada na određeno vrijeme, njegove primjene u organizacijama, prednosti i nedostatke za zaposlenike u zemljama EU-a. Kao nedostatak rada na određeno vrijeme Barbieri (2009) navodi veće rizike od nezaposlenosti nakon isteka ugovora te ulazak u okvire nesigurnog zapošljavanja. Barbieri je istraživanje proveo 2009. godine, nakon koje se mnogo toga promijenilo u EU-u u okviru zaštite zaposlenika te dinamike zapošljavnja.

Bande i Karanassou (2008) izučavaju fleksibilnost tržišta rada i regionalnu dinamiku stope nezaposlenosti. Navode kako se stupanj fleksibilnosti tržišta rada razlikuje između regija s visokom i niskom nezaposlenošću. U disertaciji se analizirala stopa nezaposlenosti u kontekstu narednih oblika fleksibilnosti na tržištu rada; rad u smjenama, večernji i noćni rad, rad subotom i nedjeljom te rad od kuće. Rezultati se razlikuju u tome što je analizom podataka u disertaciji ustanovljeno kako je fleksibilnost tržišta rada specifična za svaku zemlju, a povećanja rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće utječe na smanjenje stope nezaposlenosti u narednim zemljama: Austriji, Belgiji, Danskoj, Finskoj, Grčkoj, Italiji, Mađarskoj, Nizozemskoj, Njemačkoj, Poljskoj i Sloveniji.

Espinosa i Diaz-Emparanza (2019) u svom radu izučavaju dugoročnu vezu između međunarodne radne migracije i nezaposlenosti u Španjolskoj. Autori analiziraju obilježja migracijske politike u Španjolskoj, nezaposlenost i imigraciju te su ustanovili kako imigracija uzrokuje nezaposlenost. Ta je uzročno-posljedična veza pozitivna, u smislu da što je veća imigracija, to je veća nezaposlenost. Iako migracije imaju mnogo pozitivnih aspekata, Cristea i suautori (2014) navode kako bi države EU-a svakako trebale biti oprezne u pogledu demografskih posljedica zapošljavanja radnom migracijom. Razlog tome može se pronaći u

[4] BDP po stanovniku ili BDP per capita = ukupan BDP zemlje podijeljen s brojem stanovnika

činjenici kako prirodna depopulacija u većini zemalja EU-a te migracije mladih osoba u druge zemlje utječe na usporavanje ekonomskog rasta i smanjenje BDP-a po stanovniku.

Grekousis i Gialis (2018) istražuju socijalne pokazatelje kroz prostorno-vremensku analizu fleksibilizacije rada i bruto domaćeg proizvoda u krizama pogođenim regijama Europske unije. Jednako kao u disertaciji, fleksibilnost tržišta rada u analizi Grekousis i Gialisa napravljena je u okviru sljedećih varijabli: privremeno zaposleni, zaposleni na određeno vrijeme, zaposleni na neodređeno vrijeme, samozaposleni i zaposleni na nepuno radno vrijeme. U njihovu studiju su dodatno uključene i osobe koje pomažu u obiteljskim poslovima. Analizom navedenih fleksibilnih ugovornih aranžmana i BDP-a po stanovniku, autori zaključuju kako rezultati za južnu regiju EU-a, naročito za Portugal, Španjolsku i Grčku, pokazuju kako je intenziviranje fleksibilizacije rada dovelo do pada BDP-a po stanovniku. U disertaciji su u empirijskom dijelu statističkom analizom podataka za Portugal i Grčku potvrđeni rezultati studije Grekousis i Gialisa.

O pojmu globalne fleksibilnosti rada u svojoj knjizi piše Standing (1999). U istoj navodi kako su od 1970-ih globalizacija i fleksibilna tržišta rada povećali nesigurnost i nejednakosti. Iste stavove dijeli i Mills (2004) koji ističe kako preraspodjela radnog vremena i porast fleksibilnih i nesigurnih oblika nestandardnog zapošljavanja stvaraju nove nesigurnosti i nejednakosti koje utječu na sve društvene skupine. Nesigurnosti i nejednakosti koje navode autori vezane su uz europska tržišta rada koja su i sada, a osobito u 70-im godinama prošlog stoljeća, bila rigidnija u pogledu konvencionalnog sustava radnopravnih odnosa koji utvrđuje uvjete zapošljavanja, samog rada i otkaza uz prisutnost utjecajnih sindikata. Pojavom globalizacije i fleksibilnih oblika rada uslijedila je postepena transformacija koja je donijela određene nesigurnosti i nejednakosti. Za razliku od europskog tržišta rada, tržište rada Sjedinjenih Američkih Država u istom vremenskom periodu bilo je odlikovano niskom razinom socijalne regulative te visokim stupnjem fleksibilnosti samog tržišta te je bilo spremnije na gospodarske transformacije koje su potaknute globalizacijom. Samu potrebu za implementacijom mjera fleksibilnosti ističu i autori Urban i Velo (2006).

Značajan doprinos u istraživanju ekonomskog razvoja u svojim djelima dali su sljedeći autori. Empirijska strategija Hetschko, Schöb i Wolfa (2020) kombinira različitosti u dizajnu sa sintetičkim kontrolnim skupinama za analizu prijelaza radnika između nezaposlenosti, stalnog zaposlenja i subvencioniranog zaposlenja. Autori ističu kako rad čini ljude općenito boljima, ali osobe koje su zaposlene putem subvencioniranog zapošljavanja ne dosežu razinu zadovoljstva životom kao osobe koje su stalno zaposlene. Navedeno se može povezati s činjenicom kako stalan posao uključuje beneficije, kao što su određena sigurnost zaposlenja jer

je osobu u stalnom radnom odnosu kompliciranije otpustiti (duži otkazni rok, pravo na otpremninu itd.).

O bruto domaćem proizvodu, kao pokazatelju ekonomskog rasta i razvoja, u svojim djelima piše nekolicina autora. Ayouba, Le Gallo i Vallone (2019) su na temelju BDP-a analizirali socio-ekonomske raznolikosti europskih regija. Istraživačku analizu prostornih podataka primijenjenu na raspodjeli BDP-a po stanovniku u europskim regijama u svoje istraživanje uključuju, između ostalih, sljedeći autori: Le Gallo i Ertur (2003), Dall'erba (2005) ili Ertur i Koch (2006). S druge strane, autori Dìaz Dapena, Rubiera-Morollon i Paredes (2019) ističu kako analiziranje BDP-a po stanovniku kao jedinog pokazatelja razvoja ima svojih nedostataka. Iako se BDP po stanovniku koristi kao globalna mjera za mjerenje prosperiteta nacija i istu koriste ekonomisti, zajedno s BDP-om, za analizu prosperiteta zemlje na temelju njezina gospodarskog rasta, ograničenja njegovog korištenja kao jedine varijable vidljiva su u činjenici da ne uključuje društvene i ekološke troškove proizvodnje, stoga se ne može reći da je dobra mjera za razinu općeg blagostanja. Jednako tako, BDP po stanovniku ne uključuje niti ekonomske prilike ni sigurnost i zdravlje ljudi.

Bergeaud, Cette i Lecat (2019) su izučavali konvergenciju BDP-a po stanovniku u naprednim zemljama tijekom dvadesetog stoljeća. Zaključuju kako, uz politike koje podržavaju inovacije, najrelevantnije politike za utjecaj na proces konvergencije BDP-a po stanovniku su one koje povećavaju produktivnosti povezane s tehnološkim šokovima, politike usmjerene na smanjenje antikompetitivnih barijera na tržištu proizvoda ili uvođenje veće fleksibilnosti na tržištu rada i, naravno, politike usmjerene na povećanje razine obrazovanja radno sposobnog stanovništva.

Autori su potvrdili kako veća prilagodba globalizaciji u tehnološkom aspektu i većoj fleksibilnosti te svakako povećanjem udjela visokoobrazovanih osoba zemlje vodi ka većem BDP-u po stanovniku. U emprijskom dijelu disertacije veća fleksibilnost dovodi do povećanja BDP-a po stanovniku u sljedećim državama: Austriji, Belgiji, Bugarskoj, Cipru, Francuskoj, Hrvatskoj, Litvi, Nizozemskoj, Poljskoj, Rumunjskoj, Španjolskoj i Švedskoj. S druge strane, tumačenjem rezultata u disertaciji zaključeno je kako visokoobrazovane osobe rijetko prihvaćaju fleksibilne oblike rada te su sklonije radu na neodređeno. Rezultati pokazuju stanje do 2018. godine nakon koje su se dogodile određene promjene, izmđu ostaloga i pandemija, koja je umnogome utjecala na veću implementaciju fleksibilnih oblika rada na tržištu rada EU-a.

O fleksibilnosti tržišta rada, na način da se sustavno izučavaju fleksibilnost radnog vremena i stalnost posla, pišu sljedeći autori. Babos (2014) izučava prijelaz s ugovora na određeno vrijeme na ugovore na neodređeno vrijeme u srednjoistočnoj Europi. Glavni doprinos istraživanja

navedenog autora je u tome što isti ispituje kakvu funkciju imaju ugovori na određeno vrijeme u novim članicama EU-a, zemljama koje još nisu bile uključene u istraživanje u navedenoj domeni. U ovom istraživanju autor analizira koje pojedinačne karakteristike utječu na prijelaz na stalno zaposlenje i kako institucije tržišta rada mogu pomoći u razumijevanju razlika među zemljama. Ovo istraživanje se može povezati s istraživanjem Booth, Francesconi i Franka (2002) koji analiziraju jesu li privremeni poslovi uspješna strategija ili neodgovarajuća politika na tržištu rada (odnosno kategorije definiraju kao stepenice i/ili slijepe ulice). Autori navode kako je u Velikoj Britaniji oko 7 % zaposlenih muškaraca i 10 % zaposlenih žena na privremenim poslovima. Koristeći podatke iz britanske ankete o kućanstvima, potvrdili su popularnu percepciju da privremeni poslovi uglavnom nisu poželjni u usporedbi s trajnim zaposlenjem jer, kako navode, privremeni radnici imaju nižu razinu zadovoljstva poslom, manje se osposobljavaju i slabije su plaćeni. Nadalje, u svom radu iznose kako su ugovori na određeno vrijeme sredstvo za postizanje konačnog cilja, tj. za stalni rad jer žene koje započnu s ugovorom na određeno vrijeme i prijeđu na stalni posao u potpunosti sustižu one koje započinju sa stalnim poslom.

O privremenim poslovima, zaštiti zaposlenja i učinku na tržištu rada pišu i Cahuc i Postel-Vinay (2002). Navode kako se istodobna uporaba jake zaštite radnih mjesta i mjera aktivne politike zapošljavanja u vidu privremenih poslova čini kontradiktornom jer prva ima za cilj ograničiti zatvaranje radnih mjesta, a druga je pojačava. Kao što je prethodno navedeno, jaka zaštita radnih mjesta, uz koju se vežu i utjecajni sindikati, djeluje destimulirajuće za pojavne oblike fleksibilnosti na tržištima rada te, u tom pogledu, reducira efekte mjera aktivne politike na tržištu rada.

Mertens, Gash i McGinnity (2007) analiziraju trošak fleksibilnih oblika rada uspoređujući kazne za plaće za ugovore na određeno vrijeme u Njemačkoj i Španjolskoj pomoću kvantilne regresije. Autori ističu kako pojedinci koji imaju ugovor o radu na određeno vrijeme zarađuju manje od ekvivalentnih radnika s ugovorom na neodređeno vrijeme, u objema državama. Comi i Grasseni (2011) su provele slično istraživanje u kojem analiziraju jesu li privremeno zaposleni radnici u Europi diskriminirani. Njihovi rezultati ukazuju na činjenicu kako je u zemljama u kojima je zaposlenje na neodređeno vrijeme bolje zaštićeno veća diskriminacija radnika na određeno vrijeme. Europska unija svojim zakonskim okvirom i raznim mehanizmima nastoji zaštiti radnike u Europskoj uniji. Direktivom o privremenom radu preko agencija (2008/104/EZ) definiran je opći okvir primjenjiv na uvjete rada privremenih radnika u Europskoj uniji. Direktiva ima za cilj jamčiti zaštitu privremenim radnicima i doprinijeti razvoju sektora privremenog rada kao fleksibilne opcije za poslodavce i radnike.

Težište rada Fernández-Kranza, Paula i Rodríguez-Planasa (2015) je na poslovima s nepunim radnim vremenom i ugovorima na određeno vrijeme ženskih radnika. Autori ističu da, iako je iskustvo na poslovima s nepunim radnim vremenom manje nagrađeno nego na poslovima s ugovorom na određeno vrijeme, učinci nisu toliko štetni za plaće žena kao prekid zaposlenja. To sugerira da je posao s nepunim radnim vremenom bolji od nikakvog, čak i na tržištu rada poznatom po svojoj dubokoj segmentaciji. Weber, Gonen i Spiegel (2017) istražuju utjecaj fleksibilnosti plaća i rada na poslodavce i zaposlenike. U svom radu su razvili teorijski model kako bi se utvrdio idealan jaz u plaćama između stalno zaposlenih i zaposlenih na nepuno radno vrijeme. Autori predlažu kao rješenje metodu izračunavanja "poštene" stope nadnica za zaposlene s nepunim radnim vremenom koja je vođena isključivo financijskim razmatranjima koja osiguravaju da ni poslodavci ni zaposlenici nisu zakinuti ugovorenim aranžmanima o zapošljavanju. U disertaciji je također navedeno kako Europska unija nastoji ukloniti diskriminaciju te Zakonom o jednakosti zabranjuje diskriminaciju na radnom mjestu na temelju rasnog ili etničkog podrijetla, vjere ili uvjerenja, invaliditeta, dobi, spolne orijentacije ili, u ovom slučaju, na temelju visine nadnica.

Kao što je prethodno navedeno, autori Buddelmeyer, Mourre i Ward-Warmedinger (2004) ističu kako je zakonodavstvo o zaštiti zapošljavanja pozitivno povezano sa stopom zaposlenosti s nepunim radnim vremenom, što je u skladu s korištenjem rada s nepunim radnim vremenom kao alatom za povećanje fleksibilnosti.

O globalizaciji i radnom vremenu pišu Burgoon i Raess (2009) analizirajući radno vrijeme i fleksibilnost u Njemačkoj. Autori objašnjavaju kako ekonomska otvorenost ima neujednačene posljedice na radno vrijeme te navode kako će se utjecaj globalizacije ogledati u značajnijem smanjenju uobičajenog radnog vremena u korist fleksibilnosti radnog vremena. Ističu kako mjere globalizacije smanjuju standardno radno vrijeme, ali donose više privremenog rada, rada na temelju različitih ugovora i fleksibilnih radnih aranžmana. Do istovjetnih zaključaka dolazi i autor Kim (2000) koji ističe kako je globalizacija za sobom donijela ne samo funkcionalnu reorganizaciju, nego i tehnološke inovacije te fleksibilno radno vrijeme. Huneault, Mathieu i Tremblay (2011) jednako tako pojašnjavaju kako je utjecaj neredovitog radnog vremena brza i nepredviđena posljedica globalizacije. Može se zaključiti kako je globalizacija ključan čimbenik koji potiče fleksibilnost na tržištu rada, kao i povremeni šokovi na tržištu te krize kao što je nedvojbeno bila ona iz 2020. uzrokovana pandemijom, na koje je fleksibilnost tržišta rada jedan od najefektivnijih odgovora.

4. TRŽIŠTE RADA EU-a

„Labor omnia vincit“[5] *(Latinska izreka)*

Rad kao središte stvaranja ekonomskog bogatstva i kao osnova ekonomske aktivnosti definirao je još u 18. stoljeću Adam Smith, otac suvremene znanosti o ekonomiji. U svom djelu „*Bogatstvo naroda*“ navodi kako veliku ulogu u stvaranju i povećavanju bogatstva naroda ima podjela rada s kojom je povezana i veća proizvodnost. Nadalje, Smith smatra kako je rad izvor svog bogatstva. Podjela rada ograničena je veličinom tržišta i to tako da je podjela rada razvijenija što je tržište veće.

Tržište rada obuhvaća sveukupnost transakcija vezanih za kupoprodaju rada. Temeljni uvjet za djelovanje tržišta rada jest postojanje radne snage. Radnik time stječe osobno-pravnu slobodu i istovremeno postaje oslobođen, otuđen od vlasništva nad sredstvima za proizvodnju. (Bušelić, 2017: 7) Radnika u središte svojih promišljanja postavlja Karl Marx razvijajući postavljenu doktrinu Adama Smitha o radnoj teoriji vrijednosti i teoriji kapitalističke eksploatacije. (Bušelić, 2014: 7) Temeljna ideja Marxovog pogleda na znanost bazirana je na njegovoj viziji o, prvenstveno, čovjeku kao radniku, a potom o osobi koja se, na temelju prvotne, prethodno navedene uloge, bori za vlast, sudjeluje u političkom životu te promišlja o filozofiji i religiji. (Dragičević, 1979: 558)

„Suvremena ekonomija rada koristi teorije izbora da bi analizirala i predviđala ponašanje sudionika tržišta rada i ekonomske posljedice aktivnosti tržišta rada. Prema tome, ona nastoji odgovoriti na pitanja poput: Zašto neki ljudi odlučuju raditi, a drugi ne? Zašto neki potencijalni sudionici na tržištu rada odlučuju odgoditi svoj ulazak na tržište rada kako bi pohađali fakultet? Zašto neki poslodavci odlučuju zaposliti malo radnika i puno kapitala, dok drugi odlučuju zaposliti puno radnika i malo kapitala? Zbog čega tijekom recesije poslodavci otpuštaju neke radnika, a zadržavaju druge? Ukratko, suvremena ekonomija rada usredotočuje svoju pažnju na odluke o izboru – zbog čega se donose i kakvi su im rezultati. Zbog toga je potrebno biti svjestan tri implicitne pretpostavke koje leže u osnovi ove *ekonomske perspektive*:

1. **Relativna oskudnost** – zemlja, rad, kapital i poduzetnički resursi oskudni su, ili ograničeni, u odnosu na brojne pojedinačne i kolektivne želje društva. Ta relativna oskudnost nameće društvu izbor kako i za koje namjene treba alocirati rad i ostale resurse. Također, pojedinci se suočavaju s relativnom oskudnošću vremena i

[5] lat. rad sve pobjeđuje; konstatacija kojom se navodi kako se sve može postići upornim radom

raspoloživog dohotka. Moraju birati koliko se trenutačnog dohotka (roba i usluga) odreći za mogućnost postizanja većih budućih zarada. Moraju odlučiti koje robe i usluge kupiti, a kojih se odreći. Relativna je oskudnost – vremena, osobnog prihoda i društvenih resursa – znači, osnovni element ekonomske perspektive.

2. **Svrhovito ponašanje –** zbog toga što nas relativna oskudnost sprječava da imamo sve što želimo, prisiljeni smo birati između alternativa. Za svaki izbor, recimo da se radi o većem broju sati, nešto se dobiva, a nešto drugo žrtvuje. Ta je žrtva – propušteni output privatnog sektora – *oportunitetni* trošak. Ekonomska perspektiva pretpostavlja kako ljudi uspoređuju troškove s očekivanim koristima. Prema tome, suvremena ekonomija rada traži svrhu, ili racionalnost, u ponašanju na tržištu rada i, iz istog razloga, u institucijama tržišta rada. Relativna oskudnost traži donošenje odluka (izbora), ekonomska perspektiva pretpostavlja da će one biti donesene svrhovito, a ne kaotično, slučajno.
3. **Prilagodljivost –** zbog toga što relativna oskudnost tjera ljude na donošenje odluka i zbog toga što se odluke donose svrhovito, sudionici tržišta rada odgovaraju na promjene opaženih troškova i koristi. Na primjer, neki će radnici prilagoditi broj sati rada kada im se promijeni nadnica. Manje će ljudi odlučiti stjecati specifične vještine kad im raste trošak ili kad opada nadnica za one koji već posjeduju te vještine. Poduzeća će promijeniti broj radnika kad se promijeni potražnja za njihovim proizvodima. Neki radnici će migrirati iz područja sa slabim plaćama u područja gdje je značajno porasla potražnja za radom, a time i nadnica. Drukčije rečeno, ekonomska perspektiva pretpostavlja da radnici, poslodavci i ostali sudionici tržišta rada, *obnavljaju, prilagođavaju* ili *mijenjaju* svoja ponašanja kao odgovor na promjene u očekivanim troškovima i očekivanim dobicima.“ (Campbell, McConnell i Brue, 1994: 4-5)

Tržište rada EU-a živo je tkivo koje je definirano ne samo ponudom i potražnjom za radom, nego, s jedne strane, nacionalnim, a s druge globalnim kretanjima.

Područje tržišta rada funkcionalno je zemljopisno područje ili regija izvan administrativnih granica definiranih u svrhu sastavljanja, izvještavanja i procjene zaposlenosti, nezaposlenosti te dostupnosti radne snage. To je ekonomski integrirana prostorna jedinica unutar koje stanovnici mogu pronaći posao ujedno mijenjajući mjesto prebivališta pošto je u EU-u zajamčeno uklanjanje prepreka pravičnoj mobilnosti radne snage ili mogu promijeniti posao bez promjene mjesta prebivališta. Na tragu navedenog koncepta područja tržišta rada dizajnirale su se politike zapošljavanja, mobilnosti radne snage i urbanog planiranja, pri čemu

se vodilo računa o usklađenosti metodologije i standardizaciji postupaka koji bi trebali biti upotrebljivi i ponovljivi na razini cijele EU. (Eurostat, 2020e)

Jedan od originalnih ciljeva Europske zajednice je i finaliziranje ideje o jedinstvenom tržištu u kojem neće biti administrativnih prepreka niti prepreka u ostvarenju slobodne trgovine. Prema McCormicku (2010) „ovaj projekt je bio toliko važan za identitet i samu svrhu Europske zajednice da je jedinstveno tržište tijekom 1960-ih i 1970-ih bilo poznato i pod nazivom Zajedničko tržište. Samu srž jedinstvenog tržišta činile su „četiri slobode“, tj. uklanjanje prepreka slobodnom kretanju ljudi, kapitala, roba i usluga;

- *Ljudi*: osobama koje zakonito borave u državama članicama Zajednice trebalo bi omogućiti da žive i rade u bilo kojoj državi članici, odnosno osigurati priznavanje njihovih profesionalnih kvalifikacija.
- *Kapital*: trebalo bi omogućiti slobodan protok kapitala između država članica, a stanovnicima Zajednice omogućiti pristup financijskim uslugama u bilo kojoj državi članici.
- *Robe*: trebalo bi omogućiti kompanijama da prodaju svoje proizvode na području čitave Zajednice, a potrošačima da kupuju te proizvode u bilo kojoj državi članici bez dodatnih troškova ili nameta.
- *Usluge*: svi tipovi usluga – od arhitektonskih do bankarskih, osiguravateljskih, pravnih, zdravstvenih, itd. – trebali bi biti dostupni u svim državama članicama, bez obzira na to iz koje države dolazi pružatelj usluga.“ (McCormick, 2010: 143)

Temeljna zamisao unutarnjeg tržišta je stvoriti ekonomski prostor iz izdvojenih gospodarstava država članica koji u najvećoj mogućoj mjeri nalikuje jedinstvenom tržištu kakvo bi postojalo unutar jedne države. Iz prethodnog proizlazi da „unutarnje tržište obuhvaća područje bez unutarnjih granica u kojemu je slobodno kretanje robe, ljudi, usluga i kapitala osigurano u skladu s odredbama Ugovora.“ (Mintas Hodak i suautori, 2010: 192)

„Pravo unutarnjeg tržišta obuhvaća odredbe primarnog prava, tj. osnivačkih ugovora (Ugovor o Europskoj uniji i Ugovor o funkcioniranju Europske unije) čiji je temeljni cilj uklanjanje prepreka slobodi ekonomske aktivnosti koje nastaju u državama članicama. Primjena tih odredaba od strane Europskoga suda i nacionalnih sudova naziva se negativna integracija – integracija putem uklanjanja prepreka kretanju ekonomskih čimbenika.“ (Mintas Hodak i suautori, 2010: 193)

Ekonomska integracija ima brojne raznovrsne učinke na zemlje članice, ali i na one koje su izvan integracije, a na koje integracije direktno ili indirektno utječu. „Koncepcija s kojom se startalo imala je dvije teorijske polazne osnove:

- učinak stvaranja trgovine (*trade creation*) – kojim se supstituira najmanje učinkovita domaća proizvodnja s efikasnijom u drugim zemljama carinske unije. Time se poboljšava alokacija globalnih resursa i predstavlja početni korak u ostvarenju slobodne trgovine.
- učinak trgovinskog skretanja (*trade diversion*) – (kojeg je Viner[6] definirao kao supstituciju uvoza, koji je prije stvaranja carinske unije dolazio iz trećih zemalja, a sada će pritjecati iz zemalja-članica, unatoč tome što je ta proizvodnja u zemljama-članicama skuplja, ali ne plaća se carina). To je rezultat diskriminirajuće prirodne carine.“ (Jovančević, 2005: 135)

4.1. Kretanje radne snage na tržištu rada EU-a

Pravni korijeni državljanstva EU-a mogu se naći u odredbama o slobodnom kretanju radnika Pariškog i Rimskog ugovora. (European Commission, 2013: 20) „Pravo EU-a predviđa niz individualnih prava izravno izvršivih sudskim presudama, i horizontalno među pojedincima i vertikalno između pojedinca i države. Nadahnuto načelom slobode kretanja ljudi predviđene ugovorima, uvođenje svojevrsnog oblika europskog građanstva s jasno definiranim pravima i obvezama počelo se razmatrati još šezdesetih godina prošlog stoljeća. Nakon pripremnih aktivnosti dovršenih tijekom 1970-ih, Ugovorom o Europskoj uniji usvojenim u Maastrichtu 1992. Unija je dobila za cilj „jačanje zaštite prava i interesa državljana svojih država članica uvođenjem građanstva Unije”.“ (Bux, 2020) „Svaka osoba koja ima državljanstvo države članice građanin je Unije. Građanstvo Unije dodaje se nacionalnom državljanstvu i ne zamjenjuje ga. Građanstvo Europske unije predstavlja svojevrsnu nadgradnju nacionalnog građanstva i pruža dodatne mogućnosti državljanima država članica.“ (Dimitrova, 2014: 687-688) Iako nacionalna državljanstva pretpostavljaju ‘ukorijenjenost’ ljudi, državljanstvo EU-a usko je povezano s mobilnošću građana i prijelazima granica država članica. Mobilnost u ovom slučaju ima osobnu i kolektivnu dimenziju. Pomaže u promicanju gospodarskog rasta, produktivnosti i integracije, ali također povezuje društva i narode EU-a, što utječe na perspektive i ponašanje ljudi.

Dakle, dok se nacionalno državljanstvo smatra političkim odrazom već postojećeg etnosa ili građanskog nacionalnog tijela, građanstvo EU-a se odnosi na nadogradnju zajedničkog

[6] Jacob Viner (1892. – 1985.) - kanadski ekonomist koji se uz Franka Knighta i Henryja Simonsa smatra jednim od "nadahnjujućih" mentora rane »Chicago school of economics« 1930-ih. Modificirao je klasičnu teoriju vanjske trgovine i valutnog pariteta.

političkog i društvenog prostora koje institucije na nadnacionalnoj razini, vlade i građani Europske unije zajednički stvaraju. 'Sustvaranje' se temelji na međusobnim vezama, multilateralnim dijalozima i odnosima, a manje na autonomiji i institucionalnom zatvaranju. Ono podrazumijeva prepoznavanje uzajamne međuovisnosti institucionalnih čimbenika i pravnih poredaka te njihovo zajedničko sudjelovanje u stvaranju stvarnosti koja poboljšava životne uvjete ljudi. (European Commission, 2013: 14-16)

Značajan čimbenik uspješne integracije stranaca u društvo je i njihova mogućnost zaposlenja. Premda se kroz povijest nalaze primjeri zemalja koje su priznavale strancima pravo na nastanjenje i rad bez ograničenja (Tintić, 1972: 42 navedeno u Vukorepa, 2018: 86), danas takav slobodan režim postoji samo među povezanim državama, kao što su, npr. zemlje članice EU-a. (Vukorepa, 2018: 86)

„U praksi su poznata dva oblika ekonomskih politika prema zapošljavanju:

- kretanje ljudi ka poslu (*moving people to job*)
- kretanje posla ka ljudima (*moving job to people)* – sve više prisutna strategija u uvjetima današnje globalizacije.

Outsourcing je noviji termin za politiku kretanja posla. Europska ekonomska politika već nekoliko desetljeća je uglavnom privlačila ljude poslu, asimilirajući pridošlice. (Jovančević, 2005: 307) Ekonomska politika EU-a, zajedničko tržište i regionalna politika trebaju osigurati jednaka prava za sve građane EU-a. U praksi to znači da će se prema svim građanima EU-a postupati na jednak način u svakoj državi članici te se neće favorizirati pojedini građani u nekoj od država članica i obrnuto. Osnovna dimenzija formiranja socijalne politike proizlazi iz slobodnog kretanja osoba. Pitanje socijalne politike kao zajedničke politike Europske unije i dalje je kontroverzno u pogledu suvereniteta država članica na ovom polju. Socijalna prava uglavnom se temelje na pravu građanina na život, danas dostojanstven život - kao dio ljudskog dostojanstva, jednakosti, slobode i solidarnosti. (Lipková, 2011 navedeno u Harakal'ova, Lipková, Gress, 2015: 318).

Europska unija (EU) ima vjerojatno najnapredniji multilateralni sustav koji omogućuje prijenos socijalnih beneficija. Pod prijenosom se podrazumijeva mogućnost stjecanja i zadržavanja prava na socijalne beneficije i/ili socijalnih prava u slučaju mobilnosti iz radnih razloga. Mobilnost može biti povezana s promjenom poslodavca u istoj zemlji (mobilnost od posla do posla) ili može uključivati istodobnu i povezanu promjenu poslodavca i zemlje.

Problem prenosivosti bio je centralni za politike EU-a, budući da se nedostatak prenosivosti smatra preprekom uspjehu jedinstvenog tržišta rada. Zapravo, ako ljudi vjeruju da preseljenje

poslova (u različitim zemljama) dovodi do gubitka, u smislu pokrivenosti socijalnom sigurnošću, to uvjerenje može obeshrabriti slobodno kretanje unutar EU-a iz profesionalnih razloga. Politike prenosivosti socijalnih beneficija i prava u EU-u razvijene su za različite vrste socijalnih naknada: zdravstvene usluge, dugoročne naknade poput starosnih i invalidskih mirovina, kratkoročnu socijalnu pomoć (poput majčinstva, naknada za nezaposlenost, obiteljskih doplataka, kao i za javno stanovanje i obrazovanje). Ipak, dubina i učinkovitost takvih politika vrlo su raznolike. Svaka pogodnost povlači za sobom određene složenosti. Čak i među relativno jednostavnim prijenosima nisu uklonjene sve prepreke.

Odluke o preseljenju u inozemstvo i gdje se naseliti donose se kroz složeni postupak procjene rizika/troškova naspram prilika/koristi povezanih s preseljenjem. Očekivanja o razini dohotka koji se može zaraditi u novoj državi ključne su odrednice odluke o preseljenju. Važni su životni uvjeti i socijalno okruženje zemlje domaćina, kao i prisutnost obitelji, prijatelja ili zajednice državljana koji su već nastanjeni u zemlji odredišta. (D'Addio i Cavelleri, 2015: 346)

4.1.1. Odnos intelektualnog kapitala i razvoja globalnog gospodarstva

Jedan od ključnih mehanizama koji stvaraju konvergenciju u stopama globalnog ekonomskog rasta je prijenos tehnologije iz razvijenih u zemlje u razvoju. Prema neoklasičnim modelima rasta, tehnologija je utjelovljena unutar kapitala koji se kreće iz bogatih u siromašne zemlje kroz proces traženja viših prinosa koji se nalaze u siromašnim zemljama zbog smanjenja povrata na kapital u razvijenim gospodarstvima s većim kapitalom.

Iz perspektive ekonomske teorije, postoje dva glavna pristupa u razumijevanju veza između akumulacije ljudskog kapitala i gospodarskog rasta. Prva se vraća na temeljni rad Roberta Solowa iz 1950-ih, koji se temelji na proizvodnoj funkciji gdje je dugoročni rast potaknut tehnološkim napretkom i stopom rasta stanovništva (a ne eksplicitno ljudskim kapitalom), pri čemu se obje varijable smatraju egzogenima. Podrazumijeva se da, usprkos nedvosmislenom enormnom doprinosu suvremenoj teoriji rasta, Solowov model još uvijek u cijelosti ne objašnjava kako se određuje proces rasta, što se smatra preprekom u okviru neoklasičnog rasta. Međutim, u svom radu, Mankiw, Romer i Weil (1992) izradili su vrlo utjecajnu empirijsku studiju uvećavajući varijablu ljudskog kapitala u Solowu modelu i ukazujući na pretjerivanje uloge fizičkog kapitala u procesu rasta kad je ljudski kapital izostavljen u regresiji. (Tiruneh, 2013: 345)

„Ekonomija se danas sve više bavi nematerijalnim, odnosno neopipljivim resursima u kojima ljudi, njihova znanja i intelektualni potencijali imaju ključnu ulogu. Dakle, ljudski je kapital taj

koji u novije doba postaje poseban interes ekonomije, sa naglaskom na znanje kao najvažniji resurs, potom informacije, intelektualno vlasništvo, iskustvo i druge čimbenike koji se mogu upotrijebiti za stvaranje bogatstva." (Požega, 2012: 6) „Razvoj ljudskih potencijala postaje preduvjet gospodarskoga, tehnološkoga, političkoga, kulturnoga i svakoga drugoga napretka." (Zelenika, Sundać i Pupavac, 2002: 62 navedeno u Bušelić, 2017: 130) „Nova svjetska ekonomija zasnovana je na većem oslanjanju na tržišne mehanizme i liberaliziranu trgovinu i velika se uloga daje privatnom sektoru. Tradicionalne čimbenike proizvodnje; zemlju, rad i kapital, potisnula je potreba za informacijama, znanjem, strategijskom analizom i menadžmentom. Razvoj znanja i ljudskih potencijala posljedica su interaktivnog odnosa intelektualnog kapitala i razvoja globalnog gospodarstva." (Bušelić, 2017: 130)

Apsorpcija ljudskog kapitala kroz politiku obrazovanja i mobilnosti ključni je element budućih ciljeva Europske unije (EU) i njezinih država članica. (Zimmermann, 2009: 1)

Na tragu prethodno navedenog, izvjesno je da između demografskog i gospodarskog razvoja postoji određeni odnos reciprociteta. Akrap (2020) navodi kako su promjene koje nastaju u razvoju stanovništva pod utjecajem društveno-gospodarskog razvoja te i same povratno djeluju na taj razvoj, bilo da ga stimuliraju ili usporavaju. Stoga je poznavanje stanja i očekivanog kretanja broja stanovnika i promjena u njegovim strukturama, prema različitim obilježjima, nezaobilazno za sve ekonomske discipline. Stanovništvo je ključni čimbenik ne samo za kreiranje tekuće ekonomske politike, već i za promišljanje srednjoročnih i dugoročnih strategija ukupnog razvoja.

4.1.2. Migracije i mobilnost na području Europske unije

Slobodno kretanje radne snage kamen je temeljac agende politike EU-a, s osnovnim ciljem poticanja međudržavnih razmjena i uravnoteženja razlika između nacionalnih sustava. Migracija i mobilnost važni su aspekti prethodno navedenoga i neophodni su za rješavanje određenih neravnoteža povezanih sa znanjem i vještinama te su odgovor na zahtjeve tržišta rada i pružanje mogućnosti građanima EU-a. (Eurofound, 2020)

Shodno tome, jedan od segmenata trenutnih globalizacijskih procesa su svakako mobilnosti i migracije radne snage koji su postali njihovo karakteristično obilježje. Slobodno kretanje ljudi i radnika jedno je od prava građana Europske unije (EU), a uključuje pravo na preseljenje, prebivalište i rad u državama članicama EU-a bez diskriminacije. (Bajzíková i Bajzík, 2020: 103)

Kako bi se analiziralo kretanje radne snage na području EU-a, potrebno je pojmovno odrediti koncept migracije i mobilnosti.

Mobilnost unutar EU-a je kretanje državljana EU-a unutar EU-a, bilo unutar države članice ili između država članica, kao mobilnih radnika. U slučajevima kada je taj pomak između država članica i barem polutrajan, to predstavlja unutarnju migraciju. Pojam predstavlja kratkoročno kretanje te uključuje pojave poslanih radnika i prekograničnih putnika. (Eurofound, 2020)

Migracije su kretanja radnika između država na trajnoj ili polutrajnoj osnovi. Ta migracija može biti unutarnja migracija između država članica ili migracija radnika iz trećih zemalja izvan EU-a. (Eurofound, 2020)

Radne migracije zauzimaju najznačajniji dio migracija u okviru tržišta rada EU-a. Prema Eurostatovoj statistici stanovništva u 2017. godini, u EU-u je bilo 17 milijuna *pokretljivog stanovništva* EU-28[7], među kojima 12,4 milijuna radno sposobne dobi (20-64 godine) u odnosu na 11,8 milijuna u 2016. godini.

EU-LFS odražava isti trend, ali procjenjuje da je broj pokretljivog stanovništva EU-28 u radnoj dobi nešto niži, na 11,5 milijuna u odnosu na 11,0 milijuna godinu prije. Oko 83 % pokretljivog stanovništva radne dobi u 2017. godini bilo je aktivno (zaposleno ili u potrazi za poslom), što je iznosilo 9,5 milijuna. Umnogome, u EU-u je bilo 1,4 milijuna prekograničnih radnika[8]. (Fries-Tersch i suautori, 2019: 13)

Njemačka je već dugi niz godina glavna imigracijska destinacija, a slijede je Ujedinjeno Kraljevstvo, Španjolska, Francuska, Italija te Švicarska kada se uzmu u obzir i podaci za cijeli Europski gospodarski prostor (EGP). Najveći broj emigranata u EU-u dolazi iz Rumunjske, Poljske, Njemačke, Italije i Francuske. (Fries-Tersch, Tugran i Bradley, 2017: 21-22, Canetta, Fries-Tersch i Mabilia, 2014: 6, 8 – 9, 17, 19 navedeno u Vukorepa, 2018: 88) Ipak, treba primijetiti da unutar EU-a postoji i tendencija vraćanja u državu podrijetla (engl. *return mobility*). (Fries-Tersch, Tugran i Bradley, 2017:12 – 13, 33, 81 – 115 navedeno u Vukorepa, 2018: 88)

S obzirom na sve veću tendenciju stanovništva ka preseljenju u zemlju koja nije zemlja porijekla, u potrazi za poslom ili iz drugih razloga, Cristea i suautori (2014: 1541) navode kako bi države EU-a svakako trebale biti oprezne u pogledu demografskih posljedica zapošljavanja radnom migracijom.

[7] Određeni su kao građani EU-a (svih dobnih skupina) koji žive u državi članici EU-a koja nije njihova zemlja državljanstva.

[8] Riječ je o građanima EU-a ili EFTA-e koji žive u jednoj državi članici EU-a, a rade u drugoj.

Oprečno prethodnoj tvrdnji, a na temelju sljedeće činjenice da se tržište rada Europske unije „suočava s manjkom radne snage usprkos visokoj nezaposlenosti“, autorica Penava (2011: 340) tvrdi kako bi se taj problem nadvladao „implementacijom jedne od dviju opcija – porastom priljeva imigranata, kako visoko, tako i nisko kvalificiranih ili povećanjem mobilnosti domaćih radnika.“ Za razloge manjka radne snage usprkos visokoj nezaposlenosti Penava navodi da; „s jedne strane postoje različite preferencije, kvalifikacije i regionalne nepodudarnosti između ponude i potražnje za radom, a s druge prevladavajući demografski trendovi u EU.“ (Penava, 2011: 340)

„Problematika demografskih promjena koje obilježavanju sve dulji životni vijek, starenje stanovništva, niske stope nataliteta i prirodnog prirasta, zajedničke su članicama EU-a. Navedeno predstavlja opterećenje za djelovanje socijalnih i mirovinskih sustava pa je stoga u svim zemljama članicama prisutan napor u postizanju viših stopa zaposlenosti. To je vrlo zahtjevna i složena zadaća koja zahtijeva djelovanje u više segmenata kao i aktivnosti na svim razinama vlasti, od regionalnih i nacionalnih do nadnacionalne razine EU-a. EU daje okvire i smjernice djelovanja, a svaka zemlja članica treba postaviti vlastite ciljeve i definirati mjere i aktivnosti.“ (Kersan-Škabić, 2015: 353)

„Pojam slobodnog kretanja osoba danas ima drugačije značenje nego u trenutku uvođenja. Prve odredbe o tom pitanju, one iz Ugovora o osnivanju Europske ekonomske zajednice iz 1957. godine, obuhvaćale su samo slobodno kretanje radnika i slobodu poslovnog nastana, dakle pojedince kao zaposlenike ili pružatelje usluga. Ugovorom iz Maastrichta uveden je pojam građanstva EU-a koje automatski dobiva svaki državljanin države članice. Upravo građanstvo EU-a čini temelj na kojem počiva pravo osoba na slobodno kretanje i boravak na teritoriju država članica.“ (Marzocchi, 2020)

Ugovorom iz Maastrichta uveden je pojam europsko „državljanstvo“ (s obzirom na razliku između europskog „državljanstva“ i sličnog odnosa koji postoji između građana i pripadajućih im država, koristi se i izraz „europsko građanstvo“), premda ono nije zaživjelo u punom smislu svoje definicije. (McCormick, 2010: 130)

Ugovorom iz Lisabona pravo osoba na slobodu kretanja i boravak na teritoriju drugih država članica je potvrđeno, a uvršteno je i u opće odredbe o području slobode, sigurnosti i pravde.

„Ključni trenutak pri uspostavi unutarnjeg tržišta sa slobodnim kretanjem osoba bilo je zaključivanje dvaju schengenskih sporazuma – Schengenskog sporazuma od 14. lipnja 1985. i Konvencije o provedbi Schengenskog sporazuma koja je potpisana 19. lipnja 1990., a stupila je na snagu 26. ožujka 1995. Isprva se Konvencija o provedbi Schengenskog sporazuma (koju su potpisali samo Belgija, Francuska, Luksemburg, Nizozemska i Njemačka) temeljila na

međudržavnoj suradnji u području pravosuđa i unutarnjih poslova. Protokolom priloženim Ugovoru iz Amsterdama utvrđen je prijenos schengenske pravne stečevine u Ugovore. U skladu s Ugovorom iz Lisabona ta stečevina danas podliježe parlamentarnom i sudskom nadzoru. Budući da je većina schengenskih propisa danas dio pravne stečevine EU-a, od proširenja EU-a 1. svibnja 2004. države pristupnice više nemaju mogućnost neprimjenjivanja određenih odredbi (članak 7. Schengenskog protokola).“ (Marzocchi, 2020)

„Tako se s vremenom pravo u ovom području razvijalo te uključuje sljedeće: pravo na jednako postupanje s obzirom na uvjete rada, pravo na socijalnu, gospodarsku i kulturnu integraciju u drugu državu članicu te adekvatna prava za članove radnikove obitelji. Dakle, sloboda kretanja radnika proširila se i na ostale osobe, kao što su studenti i članovi obitelji radnika.“ (Mintas-Hodak i suautori, 2004: 127)

Nastavno na prethodno navedeno, a „kako bi Zajednica prerasla u područje istinske slobode i mobilnosti za sve svoje građane, godine 1990. donesene su direktive kojima se jamči pravo boravka i drugim osobama, a ne samo radnicima: Direktiva Vijeća 90/365/EEZ o pravu boravka zaposlenih i samozaposlenih osoba koje su se prestale baviti profesionalnom djelatnošću, Direktiva Vijeća 90/366/EEZ o pravu boravka studenata i Direktiva Vijeća 90/364/EEZ o pravu boravka (za državljane država članica koji nemaju to pravo na temelju drugih odredbi prava Zajednice i za članove njihovih obitelji).

Kako bi se konsolidirali različiti dijelovi zakonodavstva (što obuhvaća i prethodno navedene akte) i uvažila bogata sudska praksa povezana sa slobodnim kretanjem osoba, godine 2004. donesena je nova sveobuhvatna direktiva — Direktiva 2004/38/EZ Europskog parlamenta i Vijeća od 29. travnja 2004. o pravu građana Unije i članova njihovih obitelji na slobodno kretanje i boravište na području države članice. Tom se Direktivom želi potaknuti građane Unije da ostvaruju svoje pravo na slobodno kretanje i boravak u državama članicama, ograničiti administrativne formalnosti na najnužniju mjeru, bolje definirati status članova obitelji te suziti mogućnosti za zabranu ulaska ili ukidanje prava boravka.“ (Marzocchi, 2020)

Povećanje mobilnosti u svrhu rada poboljšava raspodjelu radnih resursa unutar Unije i povećava ekonomsku proizvodnju i dobrobit kao rezultat učinkovitije upotrebe resursa. (Heinz i Ward-Warmedinger, 2006., Kahanec, 2013. navedno u Barslund i Busse, 2014: 119)

Zapošljavanje i pokretljivost radne snage jedan je od jedanaest prioriteta kohezijske politike u razdoblju od 2014. do 2020. ("tematski cilj 8"). Jedan od prioriteta je svakako ulaganje u aktivnu politiku tržišta rada, samozapošljavanje, institucije tržišta rada, aktivno i zdravo starenje, zapošljavanje mladih i druge mjere namijenjene povećanju zapošljavanja i pokretljivosti radne snage. (Europska komisija, 2020)

„Politika pune zaposlenosti jedno je od trajnih načela koje je prisutno u ekonomskoj politici zemalja Europske unije. Smatra se, unatoč teškoćama kvantifikacije pojma, da je puna zaposlenost preduvjet stabilnosti cijelog sustava (pogotovo zbog rastućih prava koje uživaju zaposleni), pa su stoga zemlje-članice EU-a iznimno osjetljive na realizaciju tog načela.
Termin „puna zaposlenost“ uvela je kembridžska škola ekonomije tridesetih godina (J. M. Keynes, Joan Robinson i W. Beveridge). Sam pojam nikada nije u ekonomiji označavao „punu“ zaposlenost, već je većina ekonomista zastupala gledište po kojem je puna zaposlenost ostvarena ako se broj nezaposlenih kreće između 3 i 5 % od ukupnog radno sposobnog stanovništva. U novije doba neki ekonomisti dozvoljavaju da broj nezaposlenih dostigne i 7 %, a da se to ipak smatra stanjem pune zaposlenosti.“ (Jovančević, 2005: 291)
Berg (2015: 15) navodi kako je politika pune zaposlenosti temelj osiguranja ravnopravnih društava. Postizanje pune zaposlenosti zahtijeva potporne monetarne i fiskalne politike koje mogu stabilizirati poslovni ciklus i osigurati produktivna ulaganja koja stvaraju radna mjesta.
„R. Nurkse je u svojoj knjizi „Ravnoteža i rast u svjetskoj ekonomiji“ predstavio svoju varijantu trgovinske i devizne politike koja se temelji na kejnezijanskoj koncepciji *pune zaposlenosti*. Nurkse povezuje ravnotežu platne bilance sa zaposlenošću, tvrdeći da zemlja koja održava punu zaposlenost ne može zapasti u situaciju platnobilančne neravnoteže. Puna zaposlenost označava unutarnju ravnotežu, a to je dovoljan uvjet da se vanjska ravnoteža postiže bez uporabe ograničavajućih i restriktivnih mehanizama. Odgovornost za punu zaposlenost ne treba tražiti u međunarodnim kretanjima, već isključivo u vladi koja provodi unutarnju ekonomsku politiku.“ (Strahinja, 2007: 129-130)

Stopa zaposlenosti predstavlja postotak zaposlenih osoba u odnosu na usporedivu ukupnu populaciju. Za ukupnu stopu zaposlenosti radi se usporedba s populacijom radno sposobne dobi, ali se stope zaposlenosti mogu izračunati i za određenu dobnu skupinu i/ili spol na određenom zemljopisnom području. (Eurostat, 2020$_b$) U sljedećoj tablici (tablica 2.) prikazan je ukupan broj zaposlenih u Europskoj uniji, broj zaposlenih žena te stopa zaposlenosti u razdoblju od 2008. godine do 2018. godine.

Tablica 2. Ukupan broj zaposlenih u Europskoj uniji, broj zaposlenih žena te stopa zaposlenosti od 2008. do 2018. (stanovništvo u dobi od 20 do 64 godine)

Godina	Ukupan broj zaposlenih (u tisućama)	Broj zaposlenih žena (u tisućama)	Stopa zaposlenosti (%)

2008.	185 686	83 025	70,2
2009.	182 724	82 620	68,9
2010.	180 348	81 814	68,5
2011.	180 421	82 105	68,6
2012.	179 695	82 157	68,4
2013.	178 936	82 079	68,4
2014.	180 407	82 919	69,1
2015.	182 248	83 815	70
2016.	184 812	84 994	71
2017.	187 336	86 165	72,1
2018.	189 298	87 148	73,1
$\bar{x}$	182 901	83 531	69,8
M_e	182 248	82 919	69,1

Izvor: Izrada autorice prema podacima Europske komisije, Eurostata (2020_b). te podacima Eurostata (2020_j).

Iz tablice 2. je vidljivo da se ukupan broj zaposlenih s početnih 185 686 tisuća u 2008. godini povećao za 1,9 % u 2018. godini. Povećanje nije znatno zbog velikog pada u ukupnom broju zaposlenih nakon Velike recesije u baznoj 2008. godini.

Žene su i dalje nedovoljno zastupljene na tržištu rada (European Commission, 2021_o) te „u svim državama EU-a žene sudjeluju na tržištu rada manje od muškaraca“. (European Commission, 2017_d: 1) Izračunavanjem udjela zaposlenih žena u ukupnom broju zaposlenih u EU-u, isti se povećao za 1,3 postotna boda s 44,7 % u 2008. godini na 46 % u 2018. godini.

U razdoblju od 2008. do 2018. godine stopa zaposlenosti ukupnog stanovništva u dobi od 20 do 64 godine u EU-u povećala se za 2,9 postotna boda, to jest sa 70,2 % na 73,1 % uz određene oscilacije i stagnacije. Prosječna stopa zaposlenosti između 2008. i 2018. iznosi 69,8 %. Uzimajući u obzir stopu zaposlenosti, medijan iznosi 69,1 % te se može konstatirati da je prosjek neznantno veći, kao i pola elemenata niza koji imaju vrijednost veću od medijana.

U državama članicama Europske unije, radnici su zaštićeni od različitih aspekata diskriminacije jer im je UFEU-om zajamčeno pravo na prihvaćanje ponuda za zaposlenje te pravo na slobodno kretanje. Uz navedena prava, zajamčeno im je i pravo boravka u državi u kojoj rade te pravo na ostanak u toj državi i po prestanku zaposlenja. S druge strane, Tadin (2012: 31-32) navodi kako države EU-a također mogu primijeniti opravdana ograničenja za zaposlenja u javnoj službi kao

i određenim radnim mjestima u državnoj upravi. No područja koja su obuhvaćena zaštićenim pravima građanstva Europske unije uz slobodu poslovnog nastana su dolazak članova obitelji radnika, školovanje njihove djece, kao i područja zdravstvenog i mirovinskog osiguranja.

4.2. Obrazovanje kao preduvjet konkurentnosti na tržištu rada

„Znanje je globalno prihvaćeno kao čimbenik u javnim politikama koji povezuje gospodarski razvoj, socijalnu stabilnost i obrazovanje. Društvo temeljeno na znanju i ekonomija temeljena na znanju koriste se kao politički obrazac koji pretpostavlja ulaženje znanja u sve pore ekonomije i društva. Sami pojmovi nisu u javnim politikama jednoznačno određeni i počivaju na pretpostavci po kojoj je znanje ključni pokretač ekonomskog rasta, a pritom društvo znanja slijedi iz ekonomije znanja.“ (Prpić, 2005: 6 navedeno u Bečić i suautori, 2009: 12) „Često se ti pojmovi koriste nedovoljno specificirani uz „postindustrijsko društvo“, „informacijsko društvo“, „društvo koje uči“.“ (Jarvis, 2003: 26-27 navedeno u Bečić i suautori, 2009: 12)
Bečić i suautori (2009: 12) navode kako se društvo temeljeno na znanju i ekonomija temeljena na znanju koriste kao početni okvir opravdanja i način senzibiliziranja javnosti za područje određene javne politike. Schultz i Becker ističu kako se ljudsko znanje oblikuje u ljudski kapital, koji postaje vrijedan kao i fizički kapital. Najbitniju stavku u koncepciji ljudskog kapitala smatraju akumulaciju znanja i sposobnosti pojedinaca u svrhu povećanja produktivnosti i zarade, a posljedično i na bogatstvo društva. Socijalni kapital je iznimno bitna stavka u kriznim situacijama i periodima nesigurnosti jer u takvim okolnostima veliku razliku u izlasku iz istih pokazuju organizacije u kojima su zaposlenici umreženi te imaju povjerenje u nadređene, u norme koje su postavljene te strateški smjer koji je u poduzeću postavljen. Navedeno olakšava koordinirano djelovanje i podiže razinu učinkovitosti. Zaposlenici s ljudskim kapitalom čine u poduzeću mrežu međuodnosa koja, ako je izgrađena na kvalitetnim temeljima, doprinosi većoj produktivnosti ljudskog kapitala.
Prioritetni cilj socijalne politike EU-a i njezinih država članica je poboljšati zapošljavanje i mobilnost radnika kako bi se poboljšala kvaliteta poslova i uvjeti rada, informirati i savjetovati radnike, boriti se protiv siromaštva i socijalne isključenosti promičući jednakost između muškaraca i žene. (Harakal’ova, Lipková, Gress, 2015: 318-319)
Temelj poboljšanja kvalitete poslova i uvjeta rada te ključan čimbenik u borbi protiv siromaštva i socijalne isključenosti je svakako obrazovanje.
EU potiče države članice u njihovim nastojanjima da građanima pruže najbolje obrazovanje i osposobljavanje. Promiče i višejezičnost u Europi, pomaže u poučavanju i učenju jezika, potiče

mobilnost studenata, pripravnika, nastavnika i mladih te olakšava razmjenu informacija i iskustava. (Europa, 2020)

„EU se pokazala aktivnom u poticanju akademskih razmjena i – što je iznimno važno – učenja stranih jezika. Program za cjeloživotno učenje EU-a (engl. *The Lifelong Learning Programme*, LLP) koji je zamijenio raniji program pod imenom Socrates, pridonosi promidžbi prekograničnog obrazovanja i to preko svojih potprograma pod nazivom Comenius (partnersko u području osnovnoškolskog i srednjoškolskog obrazovanja), Erasmus (visokoškolsko obrazovanje) te Leonardo da Vinci i Grundtvig (strukovno obrazovanje).

Prenosivost kvalifikacija unaprijeđena je zahvaljujući Bolonjskom procesu (1999.), čiji je cilj stvoriti europski prostor visokog obrazovanja s kompatibilnim, usporedivim i uzajamno priznatim visokoškolskim sustavom te europsko visoko obrazovanje učiniti privlačnijim i međunarodno konkurentnijim. Bolonjski proces uključuje Europski sustav za prijenos i prikupljanje studijskih bodova (engl. *European Credit Transfer and Accumulation System*, ECTS). To znači da se studiji na svim europskim sveučilištima temelje na jedinstvenom sustavu studijskih bodova, što doprinosi većim obrazovnim mogućnostima za europske studente.“ (McCormick, 2010: 129)

ECTS povećava fleksibilnost studijskih programa za studente. Također, podržava planiranje, izvođenje i vrednovanje programa visokog obrazovanja. To je središnji alat u Bolonjskom procesu čiji je cilj učiniti nacionalne obrazovne sustave međunarodno usporedivijima. ECTS također pomaže učiniti druge dokumente, poput dodatka diplomi (*Diploma Supplement*), jasnijima i lakšima za upotrebu u različitim zemljama. ECTS je usvojila većina zemalja u Europskom prostoru visokog obrazovanja kao nacionalni kreditni sustav. (European Commission, 2020$_e$)

Zajednički je interes svih država članica EU-a iskoristiti puni potencijal kulture i obrazovanja kao pokretača stvaranja radnih mjesta, gospodarskog rasta i poboljšane socijalne kohezije, kao i sredstva za spoznavanje europskog identiteta u svoj njegovoj raznolikosti.

Europska komisija razvija inicijative za pomoć u radu na europskom obrazovnom prostoru. Vizija sadržana u politici EU-a u području obrazovanja i osposobljavanja je promicanje narednih vrijednosti na razini svih država članica EU-a:

- provođenje vremena u inozemstvu za učenje i studiranje treba postati norma
- akreditirane školske i visokoškolske kvalifikacije trebaju biti priznate bez izuzetaka
- poznavanje dvaju jezika uz nečiji materinji jezik bi trebao biti standard

- svatko bi trebao biti u mogućnosti pristupiti visokokvalitetnom obrazovanju, bez obzira na svoju socijalno-ekonomsku pozadinu
- ljudi bi trebali imati snažan osjećaj svog identiteta kao Europljanina, europske kulturne baštine i njene raznolikosti. (European Commission, 2020_c)

U tablici 3. prikazane su inicijative Europske unije čije je provođenje ključno za obrazovanje, mlade i kulturu u okviru europskog obrazovnog prostora.

Tablica 3. Inicijative Europske unije koje ističu ključnu ulogu obrazovanja, mladih i kulture u izgradnji europskog obrazovnog prostora

Ključne kompetencije za cjeloživotno učenje	Cilj ove inicijative je poboljšati razvoj ključnih sposobnosti i kompetencija ljudi svih dobnih skupina tijekom njihova života i pružiti smjernice državama članicama za postizanje ovog cilja. Poseban fokus stavlja se na promicanje poduzetničkih projekata i misaonog sklopa usmjerenog ka inovativnosti kako bi se otključali osobni potencijal, kreativnost i samoinicijativa. Štoviše, Komisija preporučuje korake za poticanje kompetencija u znanosti, tehnologiji, inženjerstvu i matematici (STEM) i motiviranje mladih u biranju karijere u navedenim poljima.
Digitalne vještine	Inicijativa promiče strategije kojima EU može pomoći ljudima, obrazovnim institucijama i obrazovnim sustavima da se bolje prilagode životu i radu u doba brzih digitalnih promjena uz: ▪ bolje korištenje digitalne tehnologije za poučavanje i učenje ▪ razvijanje digitalnih kompetencija i vještina potrebnih za život i rad u doba digitalne transformacije ▪ poboljšanje obrazovanja boljom analizom podataka i predviđanjem. Inicijative uključuju potporu školama brzom širokopojasnom vezom, proširivanje novog alata za samoprocjenu škola o korištenju tehnologije za podučavanje i učenje (SELFIE) i kampanju za podizanje svijesti javnosti o internetskoj sigurnosti, medijskoj pismenosti i *cyber* higijeni.
Zajedničke vrijednosti i inkluzivno obrazovanje	Ovom se inicijativom predlažu načini kojima mladi ljudi kroz prizmu obrazovanja mogu uvidjeti ulogu i važnost zajedničkih vrijednosti utvrđenih u članku 2. Ugovora o Europskoj uniji. Cilj inicijative je ojačati socijalnu koheziju i pridonijeti borbi protiv porasta populizma, ksenofobije, razdornog nacionalizma i širenja lažnih vijesti. Prijedlog također jača inkluzivno obrazovanje za promicanje kvalitetnog obrazovanja za sve učenike, kao i europsku dimenziju poučavanja, tako da i djeca uče o europskoj zajedničkoj baštini i raznolikosti te stječu uvid u funkcioniranje EU-a. Da bi podržala ove ciljeve, Komisija poduzima korake za povećanje virtualne razmjene među školama, posebno kroz uspješnu mrežu e-Twinning, i povećavanja mobilnost škola kroz program Erasmus+.

Izvor: izrada autorice na temelju izvješća European Commission (2020_c) te izvješća European Commission (2018)

U današnjem globalnom okruženju u kojem se ljudi educiraju i zapošljavaju, neminovne su digitalne promjene koje se događaju u sve kraćim intervalima. Europska unija stoga promiče razvoj digitalnih vještina te kompetencija iz područja znanosti, tehnologije i matematike koje su ključne za stvaranje kreativnosti, inovativnosti te, u konačnici, konkurentnosti. Jednako tako, Europska unija želi postići inkluzivno obrazovanje na svim razinama te stvoriti i oplemeniti zajedničke vrijednosti u cilju jačanja socijalne kohezije.

Domović i suautori (2013: 9) ističu kako su europska društva postala međusobno ovisna zbog rastuće međudržavne isprepletenosti u Europi, mobilnosti, migracija, interneta i procesa europskoga proširenja. Zbog tih promjena te utjecajem globalizacije nastaje potreba za modifikacijom obrazovnih sustava u Europi kako bi se povećala konkurentnost Europske Unije i nacionalnih država, potaknula mobilnost građana Europe te, na koncu, izgradila zajednička europska svijest koja može očuvati jezičnu i kulturnu raznolikost kontinenta kao identitetsko obilježje. No to mora biti rezultat i doprinos, navode Domović i suautori (2011: 17-21), svih europskih zemalja koje kroz svoje odgojne i obrazovne institucije oblikuju programe obrazovanja u koje upisuju ono što društvo misli o sebi.

Sahlberg (2012: 174-175) također naglašava da cijelo društvo mora usklađeno djelovati kako bi se ostvario gospodarski napredak te napredak u obrazovanju. Za to je nužan razvoj obrazovne politike koja se treba temeljiti na integraciji, pružanju jednakih mogućnosti kvalitetnog obrazovanja za sve te na uključivanju privatnog sektora i industrije u stvaranju i nadzoru rezultata, a ne na zasebnim politikama podsektora. Jednako tako, od velike važnosti je razvoj i promjena strategijskog okvira koji treba biti usklađen i prilagođen za različite sektore, a sve u svrhu veće kreativnosti i razvoja pristupačnosti u lokalnim i regionalnim ustanovama. Jedan od bitnih čimbenika u provedbi obrazovnih i gospodarskih reformi je uloga vlasti i javnih ustanova u sustavu te visokoobrazovna radna snaga koja čini fundament ljudskog kapitala potrebnog za kvalitetnu isporuku obrazovnih usluga i gospodarski rast.

Tragom prethodnih navoda, može se konstatirati da je jedna od ključnih varijabli koja determinira ljudski kapital neke zemlje mogućnost obrazovanja dostupna radnoj snazi. „Kombinacija visokog stupnja obrazovanosti, snažne radne etike i velikog stupnja nezaposlenosti čini zemlju atraktivnom za strane tvrtke, zbog visoke produktivnosti i niske fluktuacije.“ (Noe i suautori, 2006: 542)

4.2.1. Pravo na obrazovanje, strukovno osposobljavanje i profesionalno usmjeravanje

„Izgradnja zajednice europskih država na osnovi ekonomske, monetarne, političke i socijalne integracije uzrokovala je i sličnost obrazovnih sustava i sustava osposobljavanja u različitim europskim zemljama unatoč važnim kulturnim i povijesnim razlikama.“ (Sellin, 2002: 52 navedeno u Bečić i suautori, 2009: 29)

Prvi koraci u tom smjeru poduzeti su navođenjem obrazovanja kao temeljnog ljudskog prava u Univerzalnoj deklaraciji o ljudskim pravima (1948.).

Bečić i suautori (2009: 29-30) navode kako je profesionalno usmjeravanje najprije bilo u okviru obrazovnog sustava, a tek se kasnije proširilo i na svijet rada zbog toga što se uočila povezanost porasta nezaposlenosti i profesionalnog usmjeravanja. Bitno je istaknuti da se, u okviru djelotvornog ostvarivanja prava na rad te u kontekstu suzbijanja nezaposlenosti i iskorjenjivanja neslaganja ponude i potražnje na tržištu rada, ističe potreba za profesionalnim usmjeravanjem i osposobljavanjem, kako u procesu obrazovanja, tako i sferi tržišta rada. To se može postići pravilnim i pravovremenim planiranjem karijere, informiranjem, osposobljavanjem te prekvalifikacijama.

Bečić i suautori također ocjenjuju razvoj i održavanje visokokvalificirane radne snage sposobne odgovoriti na tehnološke izazove i industrijske promjene kao vrlo važan parametar tržišnog natjecanja i temelj ekonomske dobrobiti europskih zemalja. Time se profesionalno usmjeravanje i osposobljavanje mogu formulirati kao nužni čimbenici za ostvarivanje konkurentnosti.

Pravo na obrazovanje jedno je od ključnih načela na kojima se temelji i Agenda obrazovanja 2030 i cilj održivog razvoja br. 4 (SDG4[9]) koju je usvojila međunarodna zajednica. SDG4 nastoji osigurati puno uživanje prava na obrazovanje kao temelja za postizanje održivog razvoja.

Normativni instrumenti UN[10]-a i UNESCO[11]-a utvrđuju međunarodne pravne obveze kojima se priznaje i jača pravo svake osobe da uživa pristup kvalitetnom obrazovanju. Države članice i međunarodna zajednica smatraju da je ovaj pravni okvir od velike važnosti u provedbi prava na obrazovanje. UNESCO podupire države u uspostavljanju čvrstih nacionalnih pravnih i političkih okvira koji stvaraju temelje i uvjete za pružanje i održivost kvalitetnog obrazovanja.

[9] SDG4 = cilj održivog razvoja br. 4 (engl. *Sustainable Development Goal 4*)
[10] UN = Ujedinjeni narodi (engl. *United Nations*)
[11] UNESCO = Organizacija Ujedinjenih naroda za obrazovanje, znanost i kulturu (engl. *United Nations Educational, Scientific and Cultural Organization*)

Zauzvrat, vlade moraju odgovarati za ispunjavanje svojih zakonskih i političkih obveza za pružanje kvalitetnog obrazovanja za sve i za učinkovitiju provedbu i nadzor obrazovnih politika i strategija. (UNESCO, 2019)

4.2.2. Cjeloživotno obrazovanje

Cjeloživotno obrazovanje postaje imperativ današnjice jer je obrazovanje temelj društva znanja. „Obilježja znanja kao ključnog resursa jesu: mogućnost njegova nekontroliranog širenja, vertikalni razvoj znanja kroz sustav obrazovanja, uvjetovanost znanja kao čimbenika koji se koristi u poslovnom procesu, a ne mora biti garancija uspjeha.“ (Šundalić, 2012: 123 navedeno u Bušelić, 2017: 145)

Bečić i suautori (2009: 12-13) navode kako je potrebno biti dio cjeloživotnog obrazovanja da bi se znanje moglo širiti i primjenjivati te na temelju toga stvarati društvo znanja. Autori jednako tako navode kako klasični obrazovni sustav nije bio dovoljan te su se morali pronaći obrazovni odgovori na nove potrebe te društvene, gospodarske i političke izazove. Ideje o konceptu cjeloživotnog obrazovanja su zabilježene u dokumentima UNESCO-a, Vijeća Europe, OECD[12]-a te u Memorandumu o cjeloživotnom učenju iz 2000. godine u kojem je navedeno kako cjeloživotno učenje obuhvaća formalno, neformalno i informalno obrazovanje.

Formalno obrazovanje → Sustav u zemlji koji redovno obrazovanje i osposobljavanje pruža na službeni i strukturirani način, od osnovnog do tercijarnog i obrazovanja odraslih. Formalno obrazovanje organiziraju javne ili javno priznate institucije s jasno definiranim fazama koje vode do formalnih kvalifikacija koje priznaju nacionalne obrazovne vlasti.

Neformalno obrazovanje → Obrazovanje koje je institucionalizirano, s namjerom i planirano od davatelja obrazovanja kao dodatak, alternativa i/ili dopuna formalnom obrazovanju kao dijelu cjeloživotnog učenja. Često se pruža kako bi se svima zajamčilo pravo na pristup obrazovanju. Namijenjen je ljudima svih dobnih skupina, ali može biti kratkog trajanja i/ili niskog intenziteta. Neformalno obrazovanje obično se pruža u obliku kratkih tečajeva, radionica ili seminara. Vodi uglavnom do kvalifikacija koje relevantne nacionalne ili podnacionalne obrazovne vlasti ne priznaju. Ipak, neki specifični programi neformalnog obrazovanja mogu dovesti do priznatih kvalifikacija, posebno kada im je cilj popuniti praznine u formalnom obrazovanju osobe.

[12] OECD = Organizacija za ekonomsku suradnju i razvoj

Informalno obrazovanje → Učenje koje je namjerno, ali manje organizirano i manje strukturirano od neformalnog učenja. Uključuje aktivnosti učenja koje se događaju u obitelji, na radnom mjestu i u svakodnevnom životu svake osobe, na vlastitoj, obiteljskoj ili društvenoj osnovi. (European Parliament, 2021)

Za razliku od formalnog i neformalnog obrazovanja, informalno obrazovanje se odvija izvan obrazovnih institucija i proizlazi iz uključivanja osoba u aktivnosti koje se ne poduzimaju sa svjesnom svrhom učenja. Informalno obrazovanje je neizbježan dio svakodnevnog života - iz tog razloga se ponekad naziva iskustveno znanje. U današnjem digitalno povezanom svijetu neprestano se stječu nova osobna znanja i vještine, otkrivaju se nove metode rada i načini zarađivanja za život, rješavaju se problemi i mijenjaju načini na koje se stvaraju i dijele informacije, a sve to kroz informalno učenje.

Osobe prihvaćaju doktrine cjeloživotnog obrazovanja iz različitih razloga: kako bi poboljšali svoje šanse za zaposlenje, razvili se osobno ili profesionalno i stekli vještine, poput kritičkog mišljenja. Učenje u svim životnim dobima, naročito nakon formalnog obrazovanja, doprinosi poboljšanju socijalne kohezije i promiče aktivno građanstvo.

Rezolucija koju je Vijeće usvojilo o obnovljenom Europskom programu za obrazovanje odraslih (EAAL) naglašava potrebu za značajnim povećanjem sudjelovanja odraslih u formalnom, neformalnom i informalnom učenju, bilo za stjecanje radnih vještina, za aktivno građanstvo ili za osobni razvoj i samoaktualizaciju. U programu su postavljeni posebni prioriteti za 2015. - 2020. godinu:

- poboljšati upravljanje boljom koordinacijom između područja politike povećanom učinkovitošću i društvenom važnošću
- značajno povećati ponudu i potražnju za visokokvalitetnim pružanjem usluga, posebno u pismenosti, računanju i digitalnim vještinama
- osigurati učinkovite strategije usmjeravanja i motivacije za pomoć odraslim polaznicima
- nuditi fleksibilnije mogućnosti za odrasle za učenje i napredniji pristup kroz više učenja na radnom mjestu, korištenje ICT programa i takozvanih kvalifikacijskih programa „druge šanse“
- poboljšati kvalitetu učenja odraslih praćenjem utjecaja politika i poboljšanjem obuke koja se pruža predavačima. (European Commission, 2021_g)

Pojedinci se sve više moraju pouzdati u kontinuirani profesionalni razvoj kako bi ostali konkurentni na tržištu rada. Stoga je usredotočenost na učenje odraslih od vitalne važnosti za Europu kako bi prevladala ekonomske izazove s kojima se trenutno suočava te kako bi bila spremna odgovoriti na potražnju za novim vještinama i održivom produktivnošću u sve digitaliziranijoj svjetskoj ekonomiji. (European Commission, 2021g) Na tragu prethodno spomenutog, Torres (2001) ističe kako je za članice EU-a nužno implementirati politike razvoja ljudskih resursa, obrazovanja, osposobljavanja i cjeloživotnog učenja kako bi gospodarski razvoj bio održiv u kontekstu globalizirajućeg gospodarstva i društva temeljenoga na znanju i vještinama.

4.3. Ponuda poslova na tržištu rada EU-a

„Nijedan uspješan čovjek nikad se nije požalio na nedostatak prilika“ (R. W. Emerson)

Dugoročni čimbenici ponude rada prema Bušelić (2017: 28) su oni koji djeluju na kretanje stopa aktivnosti u ponudi radne snage. Oni se mogu podijeliti na demografske i ekonomske. Demografski čimbenici su natalitet i mortalitet, prirodni priraštaj, migracije, itd.

Prema Bogunović (2006: 35), brojnost stanovništva i ekonomska snaga određuju veličinu unutarnjeg tržišta, a dobna struktura i obrazovna stanja upućuju na radno sposobno i uzdržavano stanovništvo te na stanje ljudskog kapitala. Izučavanje struktura stanovništva bitna je podloga za strategiju razvitka, ali i za ocjenu potencijalnog mehaničkog kretanja stanovništva u prostoru.

Kulušić (2009: 104) ističe kako mobilnost radnika, kao specifičan oblik fleksibilnosti tržišta rada, omogućuje učinkovitiju alokaciju radne snage, odnosno pri tome države članice EU-a imaju mogućnost uspješno balansirati radnom snagom drugih država članica unutar pojedinih deficitarnih zanimanja.

Europska komisija je 2006. proglasila godinom u kojoj će se promicati mobilnost radnika. Bečić i suautori (2009: 82) pojašnjavaju kako je bitno povećati svijest i razumijevanje koristi koje donosi promjena mjesta boravišta radi zaposlenja u drugoj državi članici i promjena zanimanja. Mobilnost radne snage s usporedivim znanjima u jedinstvenom europskom gospodarskom prostoru potrebna je zbog dualnog efekta: visokokvalificirana radna snaga doprinosi gospodarskom prosperitetu države te se samom mobilnošću ostvaruju bolji životni i radni uvjeti radnika i članova njihovih obitelji.

Janavičiūtė, Telešienė i Barynienė (2017: 506) naglašavaju kako se inicijative za privlačenje visokokvalificiranih radnika u Europskoj Uniji provode na dva načina: na nacionalnoj razini država članica i na općoj razini EU-a. Skupina zemalja, koja ima širu nacionalnu migracijsku politiku, uključuje: Belgiju, Estoniju, Finsku, Grčku, Mađarsku, Litvu, Luksemburg, Slovačku, Sloveniju i Švedsku. Ostale imaju zasebne politike razvijene za targetiranje visokokvalificiranih radnika: Austrija, Češka, Njemačka, Francuska, Irska, Nizozemska, Španjolska i Velika Britanija.

Bušelić (2014: 107) ističe kako mogućnost za otvaranje novih radnih mjesta u uvjetima globalizacije imaju zemlje koje su liberalizirale svoja trgovinska tržišta te su na taj način zanimljive za ulaganja multinacionalnim korporacijama. Upravo su te korporacije jedan od glavnih pokretača direktnih stranih ulaganja u svijetu i omogućavaju stvaranje radnih mjesta i izravno zapošljavanje u svim sektorima s kojima je povezano njihovo poslovanje. Prema Kersan-Škabić (2015: 350), potrebne su imigracije mladih, obrazovnih kadrova sposobnih primijeniti i razvijati suvremene tehnologije kako bi gospodarstva mogla održavati postojeću gospodarsku aktivnost i pri tome postići umjerene stope rasta.

4.3.1. Kohezijska politika Europske unije

Kohezijska politika glavna je EU investicijska politika. Fokus joj je na svim regijama i gradovima Europske unije kako bi se podržalo otvaranje novih radnih mjesta, potaknula poslovna konkurentnost, omogućio gospodarski rast i održivi razvoj te poboljšala kvaliteta života građana EU-a.

McCormick (2010: 175-176) navodi kako se kohezijska politika sastoji od regionalne politike i socijalne politike. Za regionalnu politiku je karakteristično to da nastoji smanjiti razliku u bogatstvu i prihodima pojedinih regija i to kroz investicije u nazadujuća industrijska područja i siromašnija ruralna područja. Povrh svega, cilj regionalne politike je ojačati europsko tržište smanjenjem ekonomskih razlika, poticanjem uravnoteženog ekonomskog razvoja, rješavanjem problema uzrokovanih zemljopisnom udaljenošću i nerazvijenim prometnim vezama između urbanih i ruralnih područja te uklanjanje uzroka društvene deprivacije i nedovoljnog obrazovanja. Drugi dio kohezijske politike predstavlja socijalna politika koja se bavi pitanjima vezanima uz zapošljavanje, poput stvaranja novih poslova, slobodnog kretanja radnika, unaprjeđenja životnih i radnih uvjeta te zaštite prava i povlastica radnika.

Okosnicu ove politike čine Europska strategija zapošljavanja, čiji je cilj smanjenje zabrinjavajuće visoke (i začuđujuće ustrajne) stope nezaposlenosti u pojedinim dijelovima EU-a i Socijalna agenda, čiji je cilj osiguravanje radnih mjesta, borba protiv siromaštva, reforma mirovinskog i zdravstvenog sustava te rješavanje problema nejednakosti i diskriminacije.

4.3.1.1. Europska strategija zapošljavanja

Unatoč postupnom smanjivanju barijera u zapošljavanju radne snage između država članica i uspostavljanju unutarnjeg tržišta EU-a, politika zapošljavanja dugo se smatrala strogo nacionalnom prerogativom. Međutim, stabilan i zapanjujuće sličan uspon stope nezaposlenosti u većini država članica od 1970-ih, a posebno tijekom recesije početkom 1990-ih, inicirao je zajedničke napore i koordinaciju politika zapošljavanja između članica EU-a. (Kónya, 2019: 2) Kersan-Škabić (2015: 353-354) pojašnjava kako se Europska strategija zapošljavanja počela razvijati nakon 1993. godine kada je u Delorsovoj Bijeloj knjizi istaknuto područje zaposlenosti kao jedno od ključnih i najznačajnijih područja za razvoj EU-a. Ciljevi politike zaposlenosti postali su poznati kao Strategija iz Essena, odnosno Strategija koordiniranja nacionalnih politika zaposlenosti. Strategija zapošljavanja razvijala od tada u skladu s novim razvojnim dokumentima EU-a te su u okviru strategije Europa 2020 definirane smjernice koje trebaju voditi postizanju pune zaposlenosti. Kao ključni ciljevi politike zapošljavanja mogu se izdvojiti: razvijanje fleksibilnijih radnih modela; jednaka prava zapošljavanja žena u odnosu na muškarce; iskorištavanje potencijala informacijskih društava za stvaranje radnih mjesta i novih oblika organizacije rada; smanjenje troškova i administrativnih opterećenja i promidžba lokalnog razvoja kroz partnerstvo s onima koji su uključeni u socijalnu politiku, posebno lokalnih socijalnih partnera.

U revidiranim smjernicama ističu se naredni ciljevi:

- postizanje pune zaposlenosti
- cjeloživotno obrazovanje
- razvijanje vještina sukladno zahtjevima tržišta rada
- fleksibilnost i sigurnost zaposlenja
- poticanje investiranja u ljudski kapital
- prilagodba sustava obrazovanja zahtijevanim kompetencijama tržišta.

EU je za razdoblje 2007. - 2013. uspostavila i poseban program za poticanje zapošljavanja i socijalnu sigurnost PROGRESS (engl. *The EU Programme for Employment and Social Solidarity*) koji je namijenjen pružanju financijske potpore za provedbu ciljeva Europske unije

u područjima zapošljavanja i socijalnih pitanja. PROGRESS je usmjeren na pet područja: zapošljavanje, socijalno uključivanje i zaštitu, radne uvjete, nediskriminaciju te različitosti i ravnopravnost spolova. (Kersan-Škabić, 2015: 354)

Ciljevi ovog programa su:

- razviti i širiti visokokvalitetno komparativno analitičko znanje
- omogućiti učinkovitu i uključivu razmjenu informacija, uzajamno učenje i dijalog
- pružiti financijsku potporu za testiranje inovacija u socijalnoj i politici tržišta rada
- pružiti organizacijama financijsku potporu kako bi povećale svoj kapacitet za razvoj, promicanje i potporu provedbi instrumenata i politika EU-a. (European Commission, 2020$_d$)

Svake godine vlade zemalja članica i institucije EU-a donose paket dokumenata koji se odnose na zaposlenost. Kersan-Škabić (2015: 359-360) ističe kako se kod politike zapošljavanja primjenjuje europski semestar, što znači da proces započinje Godišnjim pregledom rasta kojim se utvrđuju prioriteti EU-a za predstojeću godinu kako bi se potaknuo gospodarski rast i otvaranje radnih mjesta. Prvenstveno se ističu smjernice za zapošljavanje u kojima se navode zajednički prioriteti i ciljevi politika zapošljavanja. Jednako tako, za nacionalne vlade je ključno zajedničko Izvješće o zapošljavanju te nacionalni programi reformi koji trebaju biti sukladni sa Strategijom Europa 2020.

Nastavno na Strategiju zapošljavanja, Europska komisija je razvila posebnu mrežu koja služi kao instrument poboljšanja mobilnosti, odnosno prostorne i profesionalne pokretljivosti radne snage u Europskoj uniji - EURES.

EURES je europska mreža za suradnju službi za zapošljavanje uspostavljena s ciljem promicanja pokretljivosti, pružanja informacija, savjetodavnih usluga i usluga upućivanja te posredovanja između poslodavaca i tražitelja posla na europskom tržištu rada. (Europska komisija, 2021$_b$)

Koordinirana je od Europske komisije u cilju „pružanja informacija o nizu praktičnih, pravnih i administrativnih pitanja kako bi tražitelji posla i poslodavci mogli donositi informirane odluke o mobilnosti. EURES-ov portal za mobilnost zapošljavanja nudi informacijske alate radi pružanja pomoći i potpore prilikom razmatranja preseljenja u drugu državu ili zapošljavanja iz druge države. Baza podataka o uvjetima života i rada sadrži detalje o brojnim važnim pitanjima,

poput pronalaženja smještaja, pronalaženja škole, porezima, troškovima života, zdravstvu, socijalnom zakonodavstvu, usporedivosti kvalifikacija itd.
Drugi vrijedan informacijski alat odjeljak je s informacijama o tržištu rada koji sadrži informacije o trenutačnim trendovima na europskom tržištu rada prema državi, regiji ili sektoru aktivnosti.“ (Europska komisija, 2021$_b$)

U sklopu Europske strategije zapošljavanja, u travnju 2012. pokrenut je *Paket za zapošljavanje* koji čini skup političkih dokumenata koji su osnova za istraživanje kako se politike zapošljavanja EU-a križaju s nizom drugih područja politike koje su potpora pametnom, održivom i uključivom rastu. Paketom se identificiraju najveća područja potencijalnih radnih mjesta u EU-u i najučinkovitiji načini za stvaranje novih radnih mjesta u zemljama EU. Mjere su predložene u sljedećim područjima:

- ✓ podrška stvaranju novih radnih mjesta;
- ✓ obnavljanje dinamike tržišta rada;
- ✓ poboljšanje upravljanja Europskom unijom. (European Commission, 2021$_e$)

Europskom strategijom zapošljavanja se nastoji uključiti *migrante koji dolaze iz država izvan Europske unije* na tržište rada. U EU-u živi 21,6 milijuna državljana trećih zemalja, što čini 4,2 % ukupne populacije EU-a. Novi migranti koji se naseljavaju u EU svake godine predstavljaju manje od 0,5 % stanovništva EU-a. Pretpostavka je da će većina migranata s prebivalištem u EU-u vjerojatno ostati u srednjoročnom razdoblju u EU-u, stoga je pronalaženje posla i uključivanje u društvo presudno za njihovu uspješnu integraciju. Socijalna podrška, poput pristupa stanu, zdravstvene zaštite i pomoći djeci je jednako važna.
Integracija državljana trećih zemalja nosi sa sobom i određene izazove:
→ Lošiji ishodi na tržištu rada u odnosu na državljane Europske unije: prosječna stopa zaposlenosti radno sposobnih migranata izvan EU-a koji borave u EU-u iznosila je 55 % u 2017. godini (naspram 68 % državljana zemlje domaćina);
→ Veće razlike u radu i nadnicama među ženama;
→ Nepovoljni ishodi u obrazovanju, vještinama i socijalnoj uključenosti: 39 % državljana trećih zemalja (ili 5,7 milijuna) živi u relativnom siromaštvu, što je dvostruko više od državljana EU-a (17 %).
Razlozi za nedostatke u integraciji migranata koji nisu iz EU-a uglavnom se odnose na zaostajanje u obrazovanju, jezične barijere, diskriminaciju, nejednak pristup zapošljavanju i

pristojnom stanovanju i socijalnim uslugama, i/ili neusklađenost poslova i pretjerana kvalifikacija u slučaju visokoobrazovanih migranata. (European Commission, 2021$_j$)
Iako su migracijske politike nacionalna nadležnost, institucije EU-a dugi niz godina pružaju podršku i olakšavaju put integracije migranata u europska tržišta rada i društva. Rješavanje izazova integracije je višedimenzionalni proces i zahtijeva integrirane mjere politike u brojnim područjima politike.

Nakon Europske agende o migracijama, Komisija je iznijela:

- ✓ Akcijski plan za integraciju državljana trećih zemalja, predstavljen u lipnju 2016., za jačanje zajedničkog pristupa u svim političkim područjima i uključivanje svih relevantnih aktera
- ✓ dijalog vezan uz izvješće o napretku u provedbi Europske agende za migracije (ožujak 2019.), koja je istaknula potrebu kontinuiranog odlučnog djelovanja sa sveobuhvatnim pristupom
- ✓ zajedničke aktivnosti i napore s državama članicama, u suradnji s partnerima izvan EU-a. (European Commission, 2021$_j$)

U tablici 4. naveden je ukupan broj imigranata u zemljama članicama Europske unije u razdoblju od 2008. do 2018. godine. Brojke se odnose na žensku i mušku populaciju svih dobnih razreda.

Tablica 4. Broj imigranata u zemljama članicama Europske unije u razdoblju od 2008. do 2018. godine

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	x̄
Austrija	73.772	69.295	70.978	82.230	91.557	101.866	116.262	166.323	129.509	111.801	105.633	101.748
Belgija	-	-	135.281	147.377	129.477	120.078	123.158	146.626	123.702	126.703	137.860	132.251
Bugarska	-	-	-	-	14.103	18.570	26.615	25.223	21.241	25.597	29.559	22.987
Cipar	21.060	22.581	20.206	23.037	17.476	13.149	9.212	15.183	17.391	21.306	23.442	18.549
Češka	108.267	75.620	48.317	27.114	34.337	30.124	29.897	29.602	64.083	51.847	65.910	51.374
Danska	57.357	51.800	52.236	52.833	54.409	60.312	68.388	78.492	74.383	68.579	64.669	62.133
Estonija	3.671	3.884	2.810	3.709	2.639	4.109	3.904	15.413	14.822	17.616	17.547	8.193
Finska	29.114	26.699	25.636	29.481	31.278	31.941	31.507	28.746	34.905	31.797	31.106	30.201
Francuska	296.608	296.970	307.111	319.816	327.431	338.752	340.383	364.221	377.709	369.621	387.158	338.707
Grčka	66.529	58.613	60.462	60.089	58.200	57.946	59.013	64.446	116.867	112.247	119.489	75.809
Hrvatska	16.883	13.213	8.846	8.534	8.959	10.378	10.638	11.706	13.985	15.553	26.029	13.157

Irska	82.592	50.604	52.339	57.292	61.324	65.539	73.519	80.792	85.185	78.499	97.712	71.400
Italija	534.712	442.940	458.856	385.793	350.772	307.454	277.631	280.078	300.823	343.440	332.324	364.984
Latvija	4.678	3.731	4.011	10.234	13.303	8.299	10.365	9.479	8.345	9.916	10.909	8.479
Litva	9.297	6.487	5.213	15.685	19.843	22.011	24.294	22.130	20.162	20.368	28.914	17.673
Luksemburg	17.758	15.751	16.962	20.268	20.478	21.098	22.332	23.803	22.888	24.379	24.644	20.942
Mađarska	37.652	27.894	25.519	28.018	33.702	38.968	54.581	58.344	53.618	68.070	82.937	46.300
Malta	6.043	6.161	4.275	5.465	8.256	10.897	14.454	16.936	17.051	21.676	26.444	12.514
Nizozemska	143.516	122.917	126.776	130.118	124.566	129.428	145.323	166.872	189.232	189.646	194.306	151.154
Njemačka	682.146	346.216	404.055	489.422	592.175	692.713	884.893	1.571.047	1.029.852	917.109	893.886	773.047
Poljska	15.275	189.166	155.131	157.059	217.546	220.311	222.275	218.147	208.302	209.353	214.083	184.241
Portugal	29.718	32.307	27.575	19.667	14.606	17.554	19.516	29.896	29.925	36.639	43.170	27.325
Rumunjska	138.929	135.844	149.885	147.685	167.266	153.646	136.035	132.795	137.455	177.435	172.578	149.959
Slovačka	8.765	6.346	5.272	4.829	5.419	5.149	5.357	6.997	7.686	7.188	7.253	6.387
Slovenija	30.693	30.296	15.416	14.083	15.022	13.871	13.846	15.420	16.623	18.808	28.455	19.321
Španjolska	599.075	392.962	360.705	371.331	304.053	280.772	305.454	342.114	414.746	532.132	643.684	413.366
Švedska	101.171	102.280	98.801	96.467	103.059	115.845	126.966	134.240	163.005	144.489	132.602	119.902
Ujedinjeno Kraljevstvo	590.242	566.514	590.950	566.044	498.040	526.046	631.991	631.452	588.993	644.209	603.953	585.312
$\bar{x}$	142.520	119.119	119.764	121.247	118.546	122.030	135.279	167.376	152.946	157.001	162.366	

Izvor: izrada autorice prema podacima sa Eurostat-a (2021_b).

Iz tablice 4. je evidentno kako je Njemačka najpoželjnija odredišna destinacija za imigrante. U 2015. godini u Njemačku je imigriralo 1 571 047 osoba. U razdoblju od 2008. do 2018. godine, uz Njemačku, najviše je osoba imigriralo u Ujedinjeno Kraljevstvo (6 438 434), Španjolsku (4 547 028) i Francusku (3 725 780).

Podaci za Belgiju u 2008. i 2009. nisu poznati, kao i za Bugarsku u razdoblju od 2008. do 2011. godine.

Uzimajući u obzir prosječne vrijednosti po godinama, pad broja imigranata počinje od 2009. godine, što je u većoj mjeri rezultat Velike recesije te se, uz manje oscilacije, taj trend zadržao do 2014. godine u kojoj se može uočiti povećanje broja imigranata koji se nastavlja sve do 2018. godine s neznatnim padom u 2016. i 2017. godini. Prema prosječnim vrijednostima po zemljama, interesantno je da su zemlje u koje se najmanje imigrira Slovačka (6 387), Estonija (8 193) i Latvija (8 479).

EU, između ostaloga, podupire države članice u smanjenju *nezaposlenosti i neaktivnosti mladih*. Tijekom globalne financijske krize 2008., nezaposlenost mladih porasla je sa 16,0 % u 2008. do najviše vrijednosti od 24,4 % u 2013,. nakon koje je započeo padajući trend.

Međutim, nezaposlenost mladih uvijek je ostala više nego dvostruko veća od opće nezaposlenosti. Europska unija je zbog toga 2013. godine usvojila *Garanciju za mlade*. Od tada je pomogla više od 24 milijuna mladih ljudi. Na temelju prijedloga Komisije, preporuka Vijeća

vijeća za 2020. o pojačanoj Garanciji za mlade jamči da će mladi, ako se prijave, u roku od četiri mjeseca dobiti ponudu za zaposlenje, obrazovanje ili pripravništvo. Štoviše, garancija je proširena na stariju kategoriju djece od 15 do 29 godina, čime je inkluzivnija u vidu izbjegavanja bilo kakvog oblika diskriminacije. Dodatni elementi koji podržavaju zapošljavanje mladih povezuju se s Europskom mrežom javnih službi za zapošljavanje, Akcijskim planom za socijalnu ekonomiju i jačom bazom podataka o pristupu socijalnoj zaštiti za mlade. (European Commission, 2021_p)

Kroz Europsku strategiju zapošljavanja se zaključno daje podrška poduzetnicima i samozaposlenima, čime se stvaraju radna mjesta, razvijaju vještine uključenih, pruža nezaposlenima i ranjivim skupinama prilika da u potpunosti sudjeluju u društvu i gospodarstvu. Strategija Europa 2020 prepoznaje poduzetništvo i samozapošljavanje kao ključ za postizanje pametnog, održivog i uključivog rasta. Štoviše, glavni prioritet Komisije je "ponovno postići rast Europe i povećati broj radnih mjesta bez stvaranja novog duga". U svojoj potpori poduzetništvu i samozapošljavanju, Europska komisija usmjerava svoje napore na:

- pokretanje poslovanja od nezaposlenih i osoba iz ranjivih skupina
- podršku socijalnim poduzetnicima
- mikrofinanciranje i želi:
    - povećati znanje o poduzetništvu i samozapošljavanju
    - izgraditi kapacitete u zemljama i regijama EU-a
    - financijski podržati poduzetništvo. (European Commission, 2021_m)

4.3.1.2. Socijalna agenda

Socijalna agenda integrirani je odgovor politike koji nadopunjuje Lisabonsku strategiju i pokazuje predanost postizanju rezultata u vidu povećanja kvalitete života te prava i sigurnosti za građane. To pokazuje da europske vrijednosti ostaju u središtu politika EU-a i sastavni su dio odgovora EU-a na globalizaciju. Ona odražava snažnu predanost Komisije socijalnoj dimenziji, koja je već utvrđena u njezinim strateškim ciljevima i važan je doprinos širim naporima da Unija postane ekonomski jaka, društveno odgovorna i sigurna. (Commission of the European Communities, 2008: 4)

Temeljni socijalni ciljevi Europe ostali su nepromijenjeni: snažna predanost skladnim, kohezivnim i inkluzivnim društvima poštujući temeljna prava u zdravim socijalnim tržišnim gospodarstvima. To je jasno navedeno u ciljevima Unije i Povelji o temeljnim pravima

Europske unije. Promjene koje se događaju na tržištima i u društvu potaknute efektima globalizacije iziskuju presjek stanja i redefiniranje fokusa europske socijalne agende. (Commission of the European Communities, 2008: 4)

U posljednjoj generaciji, socijalna dimenzija napravila je ogroman korak naprijed kako se jedinstveno europsko tržište širilo i produbljivalo. Osamdesetih je Socijalna agenda zamišljena kao sredstvo za osiguravanje pristanka na industrijsko restrukturiranje u koje je bio uključen plan iz 1992. godine. Fokus je bio na zaštiti zapošljavanja i potrebi postizanja konsenzusa između socijalnih partnera kako bi se olakšale industrijske promjene. Danas je potreban mnogo širi društveni program koji Europi omogućuje da u potpunosti iskoristi mogućnosti koje donosi globalizacija kako bi se pomoglo građanima da se prilagode promjenjivim okolnostima i pokaže solidarnost s onima koji su negativno pogođeni promjenama. (Commission of the European Communities, 2008: 5)

Rezolucija Europskog parlamenta o obnovljenoj Socijalnoj agendi naglašava potrebu za napretkom i dovršavanjem propisa o koordinaciji sustava socijalne sigurnosti te prijedloga direktive o provedbi načela jednakog postupanja bez diskriminacije. Parlament također ističe važnost harmonizacije zakonodavstva na europskoj razini naglašavajući kako bi učinkovita suradnja između država članica i učinkovito praćenje prenošenja zakona EU-a trebali biti prioritet. Kako je prikazano na slici 1., suštinu Agende čine temeljni koncepti mogućnosti, pristupa i solidarnosti: svatko bi trebao imati pravo pristupa kvalitetnim uslugama kao što su obrazovanje i zdravstvena zaštita svih dobnih skupina, a trebala bi nadasve postojati i solidarnost kako između pojedinaca i generacija, tako i između regija. (Eichhorst i suautori, 2010: 27)

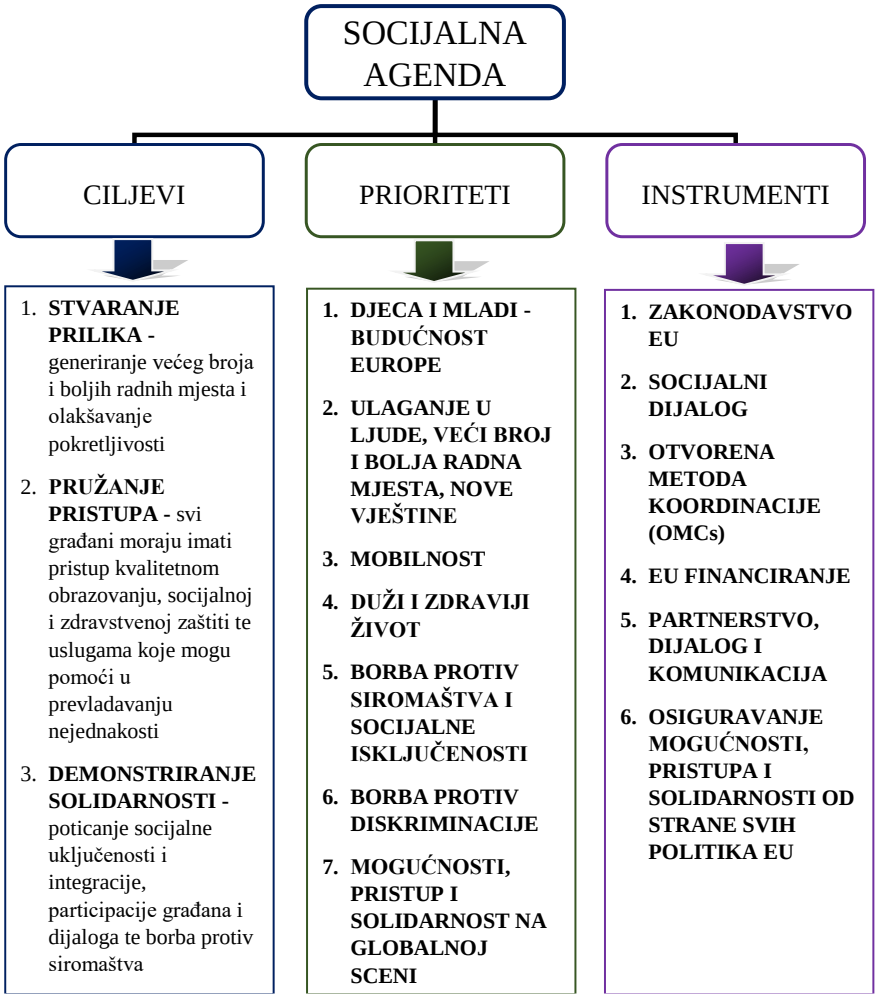

Slika 1. Ciljevi, prioriteti i instrumenti redefinirane Socijalne agende

Izvor: izrada autorice prema Commission of the European Communities (2008: 6-18).

Na slici su prikazana tri ključna cilja Socijalne agende – stvaranje prilika, pružanje pristupa te demonstriranje solidarnosti. Naglašeni su prioriteti u koje bi trebalo investirati, a to su prvenstveno ljudi, njihova radna mjesta i zdravlje te, s druge strane, prioriteti koje bi trebalo rješavati, kao što su borba protiv siromaštva i socijalne isključenosti te borba protiv diskriminacije. Shodno tome, prikazani su instrumenti kojima bi se osiguralo ispunjenje ciljeva i rješavanje prioriteta istaknutih u Socijalnoj agendi od kojih je najrelevantnije zakonodavtsvo EU-a.

„Europski parlament, Vijeće i Komisija proglasili su 17. studenoga 2017. na sastanku na vrhu za pravedno zapošljavanje i rast u Göteborgu u Švedskoj europski stup socijalnih prava. U okviru tog stupa utvrđeno je 20 ključnih načela i prava kojima će se podupirati pravedna i funkcionalna tržišta rada, a koja su strukturirana oko triju poglavlja:

I. jednakih mogućnosti i pristupa tržištu rada

II. pravednih uvjeta rada

III. socijalne zaštite i uključenosti.“ (Europska komisija, 2021$_e$)

„Bit je europskog stupa socijalnih prava osiguravanje novih i djelotvornijih prava građanima.“ (Europska komisija, 2021$_d$) Stup se temelji na 20 ključnih načela, razvrstanih u prethodno navedene tri kategorije, prikazane u tablici 5. sukladno navedenom.

Tablica 5. Europski stup socijalnih prava i njegovih 20 načela

Poglavlje I.: Jednake mogućnosti i pristup tržištu rada	1. Obrazovanje, osposobljavanje i cjeloživotno učenje	*Svaka osoba ima pravo na kvalitetno i uključivo obrazovanje, osposobljavanje i cjeloživotno učenje kako bi održala i stekla vještine pomoću kojih može u potpunosti sudjelovati u društvu i uspješno prelaziti s jednog radnog mjesta na drugo na tržištu rada.*
	2. Rodna jednakost	*Jednako postupanje i jednake mogućnosti za žene i muškarce moraju se osigurati i poticati u svim područjima, uključujući sudjelovanje na tržištu rada, uvjete zaposlenja i napredovanje u karijeri.*
	3. Jednake mogućnosti	*Bez obzira na rod, rasnu ili etničku pripadnost, vjeru ili uvjerenje, invaliditet, dob ili spolnu orijentaciju, svatko ima pravo na jednako postupanje i jednake mogućnosti u pogledu zapošljavanja, socijalne zaštite, obrazovanja te pristupa robi i uslugama dostupnima javnosti.*
	4. Aktivna potpora zapošljavanju	*Svaka osoba ima pravo na pravovremenu i individualno prilagođenu pomoć u poboljšavanju izgleda za zapošljavanje ili samozapošljavanje. To uključuje pravo na potporu pri traženju posla, osposobljavanju i prekvalifikaciji.*
Poglavlje II.: Pravedni radni uvjeti	5. Sigurno i prilagodljivo zaposlenje	*Bez obzira na vrstu i trajanje radnog odnosa, radnici imaju pravo na pravedno i jednako postupanje u pogledu radnih uvjeta, pristupa socijalnoj zaštiti i osposobljavanja. Potiče se prelazak na zapošljavanje na neodređeno vrijeme.* *U skladu sa zakonodavstvom i kolektivnim ugovorima, osigurava se potrebna fleksibilnost poslodavaca da se brzo prilagode gospodarskim promjenama.*
	6. Plaće	*Radnici imaju pravo na pravedne plaće kojima se osigurava pristojan životni standard.* *Osigurava se primjerena minimalna plaća kojom se mogu zadovoljiti potrebe radnika i njihovih obitelji u određenim nacionalnim gospodarskim i društvenim uvjetima te pristup zapošljavanju i poticaji za traženje zaposlenja.*
	7. Informacije o uvjetima zaposlenja i zaštita u slučaju dobivanja otkaza	*Radnici imaju pravo na početku zaposlenja u pisanom obliku biti upoznati sa svojim pravima i obvezama koji proizlaze iz radnog odnosa, uključujući onima tijekom probnog roka.* *Prije dobivanja otkaza, radnici imaju pravo biti upoznati s razlozima za njegovo dobivanje i mora im se dati razuman otkazni rok.*

	8. Socijalni dijalog i uključenost radnika	*Provodi se savjetovanje sa socijalnim partnerima o osmišljavanju i provedbi gospodarskih i socijalnih politika te politika zapošljavanja u skladu s nacionalnom praksom. Radnici i predstavnici radnika imaju pravo pravovremeno biti upoznati s pitanjima koja su za njih relevantna te se uključiti u raspravu o njima, osobito u pogledu prelaska, restrukturiranja i spajanja poduzeća te kolektivnog otpuštanja.*
	9. Ravnoteža između poslovnog i privatnog života	*Roditelji i druge osobe koje moraju skrbiti o drugima imaju pravo na primjeren dopust, fleksibilne radne uvjete i pristup uslugama skrbi. Žene i muškarci imaju jednako pravo pristupa posebnom dopustu ili izostanku s posla kako bi ispunili svoje obveze skrbi te ih se potiče na jednakomjerno korištenje tog dopusta ili izostanka.*
	10. Zdravo, sigurno i dobro prilagođeno radno okruženje te zaštita podataka	*Radnici imaju pravo na visoku razinu zaštite zdravlja i sigurnosti na radu.* *Radnici imaju pravo na radno okruženje koje je prilagođeno njihovim profesionalnim potrebama te koje će im omogućiti da što dulje budu uključeni na tržište rada.* *Radnici imaju pravo na zaštitu osobnih podataka na radnom mjestu.*
Poglavlje III.: Socijalna zaštita i uključenost	11. Skrb o djeci i potpora djeci	*Djeca imaju pravo na pristupačan i kvalitetan rani i predškolski odgoj i obrazovanje. Djeca imaju pravo na zaštitu od siromaštva. Djeca u nepovoljnom položaju imaju pravo na posebne mjere za poticanje jednakih mogućnosti.*
	12. Socijalna zaštita	*Bez obzira na vrstu i trajanje radnog odnosa, radnici, a u usporedivim uvjetima i samozaposlene osobe, imaju pravo na primjerenu socijalnu zaštitu.*
	13. Prava za vrijeme nezaposlenosti	*Nezaposlene osobe imaju pravo na primjerenu potporu za aktivaciju od javnih službi za zapošljavanje radi (ponovnog) uključivanja na tržište rada i primjerenu naknadu za vrijeme nezaposlenosti koja se isplaćuje u razumnom trajanju, u skladu sa svojim doprinosima i nacionalnim pravilima o ispunjavanju uvjeta za primanje naknade.*
	14. Minimalni dohodak	*Svaka osoba koja nema dovoljno sredstava ima pravo na primjereni minimalni dohodak kojim se omogućuje dostojanstven život u svim njegovim fazama te pravo djelotvornog pristupa dobrima i uslugama kojima se takav život omogućuje.*
	15. Dohodak u starosti i starosna mirovina	*Umirovljeni radnici i samozaposlene osobe imaju pravo na mirovinu koja odgovara njihovim doprinosima i čini primjeren dohodak. Žene i muškarci imaju jednake mogućnosti za ostvarivanje prava na mirovinu.* *Sve starije osobe imaju pravo na resurse koji im osiguravaju dostojanstven život.*
	16. Zdravstvena skrb	*Svaka osoba ima pravo pravovremenog pristupa kvalitetnoj preventivnoj i kurativnoj zdravstvenoj skrbi po povoljnim cijenama.*

	17. Uključenost osoba s invaliditetom	*Osobe s invaliditetom imaju pravo na potporu dohotku koja im omogućuje dostojanstven život, usluge koje im omogućuju sudjelovanje na tržištu rada i u društvu te radno okruženje prilagođeno njihovim potrebama.*
	18. Dugotrajna skrb	*Svaka osoba ima pravo na povoljne i kvalitetne usluge dugotrajne skrbi, osobito na usluge skrbi u vlastitom domu i u zajednici.*
	19. Stanovanje i pomoć beskućnicima	*a. Onima kojima je to potrebno omogućuje se pristup kvalitetnim socijalnim stanovima ili kvalitetnoj pomoći za stanovanje.* *b. Ranjive osobe imaju pravo na primjerenu pomoć i zaštitu od prisilnih deložacija.* *c. Osiguravaju se primjerena skloništa i usluge za beskućnike radi promicanja njihove socijalne uključenosti.*
	20. Pristup osnovnim uslugama	*Svaka osoba ima pravo pristupa kvalitetnim osnovnim uslugama, uključujući vodu, odvodnju, energiju, promet, financijske usluge i digitalnu komunikaciju. Potpora pristupu takvim uslugama mora biti dostupna onima kojima je potrebna.*

Izvor: izrada autorice prema Europskoj komisiji (2021_d).

Prethodna tablica ukazuje na tri jaka stupa socijalnih prava u Europskoj uniji - jednake mogućnosti i pristup tržištu rada, pravedni radni uvjeti te socijalna zaštita i uključenost. Svaki stup sadrži skup načela čijim se usvajanjem svaka članica EU-a približava ispunjenju ciljeva socijalne politike.

Kao što je prethodno navedeno, socijalna politika dio je kohezijske politike koja je „jedan je od glavnih investicijskih alata EU-a za stvaranje rasta i radnih mjesta, borbu protiv klimatskih promjena i energetske ovisnosti te smanjenje siromaštva i socijalne isključivosti.

Reformirana kohezijska politika je usmjerena na jačanje gospodarske, socijalne i teritorijalne kohezije u Europskoj uniji ispravljanjem neravnoteže između regija. Da bi se postigli navedeni ciljevi, tri fonda u okviru kohezijske politike EU-a (Europski fond za regionalni razvoj, Europski socijalni fond i Kohezijski fond) podržavat će 11 tematskih ciljeva.“ (Europska komisija, 2014) Jedanaest tematskih ciljeva kohezijske politike prikazano je shematski na slici 2. Kohezijska politika pokriva različite prioritete, poput jačanja u pogledu istraživanja i razvoja, potpore prelasku prema nisko-ugljičnom gospodarstvu ili promicanja održivog zapošljavanja, mobilnosti radne snage i socijalne uključenosti. (Ayouba, Le Gallo i Vallone, 2019: 1)

Slika 2. 11 tematskih ciljeva kohezijske politike

Izvor: izrada autorice prema Europskoj komisiji (2014).

Sumirajući ciljeve prikazane na slici 2. može se reći da je krovni „cilj kohezijske politike smanjenje razlika u prosperitetu i dobrobiti te promicanje ekonomske i socijalne konvergencije unutar EU-a, njegovih država članica i regija.“ (Becker, 2018: 147)

Za razliku od razdoblja 2014.-2020., u narednom razdoblju, od 2021. do 2027., kohezijska politika je usmjerena na samo 5 ključnih ciljeva koji podržavaju rast te je tematski koncentrirana na sljedeće; konkurentniju i pametniju Europu te zeleniju Europu koja prelazi iz gospodarstva s niskom emisijom ugljika na gospodarstvo s nultom emisijom ugljika. Jednako tako, u ciljeve se ubraja povezanija Europa ojačana mobilnošću, socijalnija i inkluzivnija Europa te Europa koja će biti bliže građanima poticanjem održivog i integriranog razvoja cijelog teritorija.

4.3.1.3. Europski socijalni fond

Prethodno je navedeno da su „temeljni dokumenti kojima se određuje politika zapošljavanja i socijalna politika EU-a: Europska strategija za zapošljavanje koja definira program stvaranja novih radnih mjesta i Strategija za reformu tržišta rada te Socijalna agenda, koja daje smjernice kako da svako društvo i svaka regija ostvare korist od rasta same Unije.
Europski socijalni fond ima zadatak financiranja projekata u ostvarenju ciljeva ovih strategija.“ (Bušelić, 2014: 44)
„Europski socijalni fond glavni je europski instrument za promicanje zapošljavanja i socijalne uključenosti. Pomaže građanima u pronalasku novog (ili boljeg) radnog mjesta, uključuje osobe u nepovoljnom položaju u društvo te osigurava bolje životne prilike za sve. To čini ulaganjem u građane Europe i njihove vještine, bez obzira na to jesu li zaposleni, stari ili mladi. Zahvaljujući fondu svake godine oko 10 milijuna ljudi uspije se zaposliti ili unaprijediti svoje vještine radi budućeg zaposlenja.“ (Europska komisija, 2021$_c$)
Zadatak Fonda je borba protiv nezaposlenosti te olakšavanje ulaska na tržište rada, promovirajući jednakost u prilikama zapošljavanja, potičući razvoj profesionalnih vještina i kvalifikacija te otvaranje novih radnih mjesta. Bušelić (2014: 45) ističe kako Fond predstavlja instrument za financiranje provedbe nacionalnih akcijskih planova za zapošljavanje. Prvotni cilj je visoka razina zaposlenosti uz istovremeno poboljšavanje uvjeta života i rada. U ciljeve se ubrajaju i jačanje tržišta rada i obrazovanje radne snage koja je sposobna prilagoditi se promjenama na tržištu rada te poboljšanje kvalitete socijalne politike i socijalne zaštite.

„O strategiji i proračunu ESF[13]-a zajednički se dogovaraju i odlučuju vlade država članica EU-a, Europski parlament i Komisija. Sedmogodišnje operativne programe planiraju vlade država članica, a odobrava ih Europska komisija. Sredstva se daju nizu organizacija (javna tijela,

[13] ESF = Europski socijalni fond (engl. *European Social Fund*)

privatna poduzeća i civilno društvo) koje građanima nude praktičnu pomoć u pronalasku ili zadržavanju radnog mjesta.“ (Europska komisija, 2021$_c$)

U tablici 6. prikazan je proračun Europskog socijalnog fonda po zemljama, u razdoblju od 2014. do 2020. godine, prikazan u eurima.

Tablica 6. Proračun ESF-a izražen u eurima po zemljama EU-a od 2014. godine do 2020. godine

(iznosi iskazani u €)

Naziv države članice	Iznos određen od EU-a	Nacionalno sufinanciranje	Ukupno određeni iznos
Austrija	442.087.353	433.651.942	875.739.295
Belgija	973.364.655	1.193.488.764	2.166.853.419
Bugarska	1.476.847.810	259.361.218	1.736.209.028
Cipar	150.320.136	26.527.085	176.847.221
Češka	3.656.824.254	843.870.952	4.500.695.206
Danska	213.024.265	197.785.384	410.809.649
Estonija	576.583.967	105.650.804	682.234.771
Finska	518.262.892	518.262.892	1.036.525.784
Francuska	5.458.415.738	4.173.693.903	9.632.109.641
Grčka	3.898.650.621	1.139.564.712	5.038.215.333
Hrvatska	1.414.736.310	249.659.352	1.664.395.662
Irska	416.370.407	416.370.407	832.740.814
Italija	10.265.946.183	6.703.892.214	16.969.838.397
Latvija	647.694.186	114.298.987	761.993.173
Litva	1.200.360.754	211.828.372	1.412.189.126
Luksemburg	20.056.223	20.056.223	40.112.446
Mađarska	4.677.552.807	1.046.043.322	5.723.596.129
Malta	134.643.448	33.660.862	168.304.310
Nizozemska	510.282.703	520.488.357	1.030.771.060
Njemačka	7.511.452.339	5.038.474.646	12.549.926.985
Poljska	12.874.296.133	2.274.606.140	15.148.902.273
Portugal	7.176.394.711	1.510.252.885	8.686.647.596
Rumunjska	4.622.426.282	816.183.864	5.438.610.146
Slovačka	2.471.664.494	515.523.074	2.987.187.568
Slovenija	718.769.595	179.692.403	898.461.998

Španjolska	7.087.084.176	3.201.704.167	10.288.788.343
Švedska	719.642.020	716.959.715	1.436.601.735
Ujedinjeno Kraljevstvo	4.722.008.045	3.865.432.514	8.587.440.559
$\bar{x}$	3.019.848.661	1.297.392.327	4.317.240.988
M_e	1.307.548.532	519.375.625,5	1.700.302.345

Izvor: izrada autorice prema podacima iz *European Social Fund* (2021).

U razdoblju od 2014. do 2020. godine stvarna izdvajanja iz ESF-a iznose 24,8 % proračuna Strukturnih fondova (ESF i ERDF[14]). Uvođenje minimalnog udjela (23,1 %) učinkovito zaustavlja postupno smanjivanje udjela ESF-a u posljednjih 25 godina. Osamnaest država članica odlučilo je dodijeliti dodatna sredstva ESF-u iznad minimalnog udjela. Iz tablice 5. se može uočiti da su Luksemburg, Irska i Finska odredile iznos nacionalnog sufinanciranja jednak iznosu koji je odredila EU za te zemlje, dok su sljedeće zemlje odredile iznos veći od iznosa koji je odredila EU: Nizozemska za 2 % i Belgija za čak 22,6 %. Promatrajući medijan u ukupno određenom iznosu ESF-a po pojedinim članicama, uz Hrvatsku, zemlje koje imaju vrijednost manju vrijednosti medijana su: Cipar, Luksemburg, Švedska, Nizozemska, Austrija, Irska, Finska, Malta, Litva, Latvija, Slovenija, Estonija i Danska.

„Ciljevi i financiranje u razdoblju od 2014. godine do 2020. godine će se odnositi na sljedeće akcije:

- ✓ osposobljavanje građana i potporu njihovu zapošljavanju
- ✓ promicanje socijalne uključenosti
- ✓ poboljšanje obrazovanja i osposobljavanja
- ✓ poboljšanje kvalitete javnih službi u zemljama članicama.“ (Europska komisija, 2021_c)

„Ukratko:

- financiraju se države članice i njihove regije, posebice one gdje je gospodarski razvoj manje napredan
- ESF je ključni element strategije Europa 2020 za rast i zapošljavanje s kojom se namjeravaju poboljšati životi građana EU-a tako da im se pruže bolje vještine i bolje perspektive za zapošljavanje.“ (Europski fondovi, 2021)

[14] ERDF = Europski fond za regionalni razvoj (engl. *European Regional Development Fund*)

Glavni cilj strategije Europe 2020 je postići pametan, održiv i inkluzivan rast kroz zapošljavanje, obrazovanje i društveno uključivanje. To zahtjeva akciju na svim razinama, od europske razine prema nacionalnim lokalnim razinama. Države članice mogle su odabrati niz konkretnih ciljeva kako to postići, kao što je stopa zapošljivosti od 75 % za dobnu skupinu 20 - 64 te smanjiti broj siromašnih i isključenih ljudi za 20 milijuna. Kroz strategiju Europa 2020, ESF pruža pomoć u poboljšanju sustava obrazovanja, što se pozitivno odražava na završetak škola i fakulteta više od 2 milijuna mladih ljudi godišnje. ESF jednako tako pomaže više od milijun ugroženih Europljana godišnje u savladavanju prepreka vezanih uz rad te kako bi izbjegli isključenje i siromaštvo. Uz to što je od 2007. godine pomogao u uspostavljanju više od 10 000 malih i srednjih poduzeća kao mjeru poticanja poduzetništva, ESF pomaže, kroz poticanje novih vještina, aktivno starenje kao odgovor na demografske izazove. (Europski fondovi, 2021)

Konkretno, Europski socijalni fond usmjerava financijska sredstva u obuku mladih ljudi, nezaposlenih i onih koji su isključeni s tržišta rada. Prema Bušelić (2014: 45-46), ESF usmjerava više sredstava u obuku starijih ljudi kako bi ostali duže zaposleni ili se vratili na tržište rada jer se Europa suočava sa starenjem populacije. Pri tome, Fond podupire inicijative pružanja skrbi starijim osobama, kako bi članovima njihovih obitelji omogućio ostajanje ili povratak na posao.

U tom kontekstu, jedan od ciljeva ESF-a je borba protiv dugoročne nezaposlenosti i olakšavanje profesionalnog uklapanja mladih te integracija osoba kojima prijeti isključenje s tržišta rada. Fond promiče razvoj i strukturno prilagođavanje nerazvijenih regija te, kroz mehanizme socijalne politike, olakšava prilagodbe radnika industrijskim promjenama.

U novom razdoblju koje traje od 2021. do 2027., Fond mijenja naziv u Europski socijalni fond plus (ESF+) te kroz strukturne reforme na osobit način doprinosi socijalnim i obrazovnim politikama EU-a. U kontekstu socijalnih politika, Fond je usmjeren na borbu protiv siromaštva i socijalne isključenosti te na omogućavanje pristupa hrani i osnovnoj materijalnoj pomoći najpotrebitijima. Ujedno, kada se govori o doprinosu kroz obrazovne politike, Fond potiče razvoj vještina i cjeloživotno učenje za sve kao i u prethodnom razdoblju, ali od 2021. s naglaskom na zelenu i digitalnu tranziciju. U ovom razdoblju, za razliku od prethodnog razdoblja, fokus je na društvenim inovacijama.

Fond od 2021. doprinosi politikama u području zapošljavanja poglavito kroz još veći naglasak na lakši pristup zapošljavanju nedovoljno zastupljenim skupinama te promicanje povećanja inkluzije žena na tržište rada.

4.3.2. Novi oblici rada u digitalnoj ekonomiji EU-a

„Razvoj digitalne infrastrukture predstavlja ključnu predispoziciju za dublju integraciju digitalnih tehnologija u poslovne i javne servise država članica EU-a. S obzirom na nebrojene učinke digitalizacije na društvo, Europska unija postavila je sebi cilj uspostaviti održivo digitalno jedinstveno tržište kako bi se u cijelosti iskoristile sve prednosti digitalizacije.
Godine 2010. Europska unija je u sklopu desetogodišnje strategije Europa 2020. donijela Digitalnu agendu za Europu. Bila je to prva od sedam ključnih inicijativa, a cilj joj je bio omogućiti gospodarstvu i građanima EU-a ostvarivanje maksimalne dobrobiti korištenjem digitalnih tehnologija. Napredak u ostvarivanju spomenutih mjera znatno se razlikovao među državama članicama. Imajući u vidu izazove digitalizacije za unutarnje tržište, Unija je 2015. godine usvojila novi krovni strateški dokument, Strategiju jedinstvenog digitalnog tržišta.“ (Butković i Samardžija, 2019: 22 - 23)
„Nova strategija jedinstvenog digitalnog tržišta EU-a navodi 16 ciljanih aktivnosti koje se temelje na trima stupovima:

1. bolji pristup digitalnim dobrima i uslugama za potrošače diljem Europe
2. osiguravanje odgovarajućih ravnopravnih uvjeta za procvat digitalnih mreža i inovativnih usluga
3. iskorištavanje punog potencijala rasta digitalnog gospodarstva.“ (Europa, 2015)

Mjerenje stupnja digitalizacije na razini EU-a isprva je bilo usmjereno na pristup internetu, a kasnije je dopunjeno drugim indikatorima kojima se mjere korištenje interneta, razvoj novih digitalnih usluga i digitalizacija industrije u sklopu, tzv. Indeksa digitalne ekonomije i društva (DESI) koji objavljuje Europska komisija. DESI indeks sumira relevantne indikatore kojima se prati stanje digitalizacije u državama članicama EU-a radi poticanja njihove digitalne konkurentnosti.“ (Butković i Samardžija, 2019: 25) Na godišnjoj razini prate se indikatori iz pet područja:

1. povezivost - fiksni širokopojasni pristup i pokrivenost te širokopojasne cijene
2. ljudski kapital - vještine korisnika interneta i napredne vještine
3. upotreba internetskih usluga - korištenje građana internetskim uslugama i internetskim transakcijama
4. integracija digitalne tehnologije - poslovna digitalizacija i e-trgovina
5. digitalne javne usluge - e-Uprava. (European Commission, 2020_a)

Na grafikonu 1. prikazan je Indeks digitalne ekonomije i društva za zemlje članice Europske unije u 2018. godini. Ukupni DESI indeks je izračunat kao ponderirani prosjek pet glavnih DESI dimenzija: 1 - povezivost (25 %), 2 - ljudski kapital (25 %), 3 - upotreba internetskih usluga (15 %), 4 - integracija digitalne tehnologije (20 %) i 5 - digitalne javne usluge (15 %). DESI indeks u konačnici daje ukupan rezultat zemlje, od najmanje 0 do maksimalno 100.

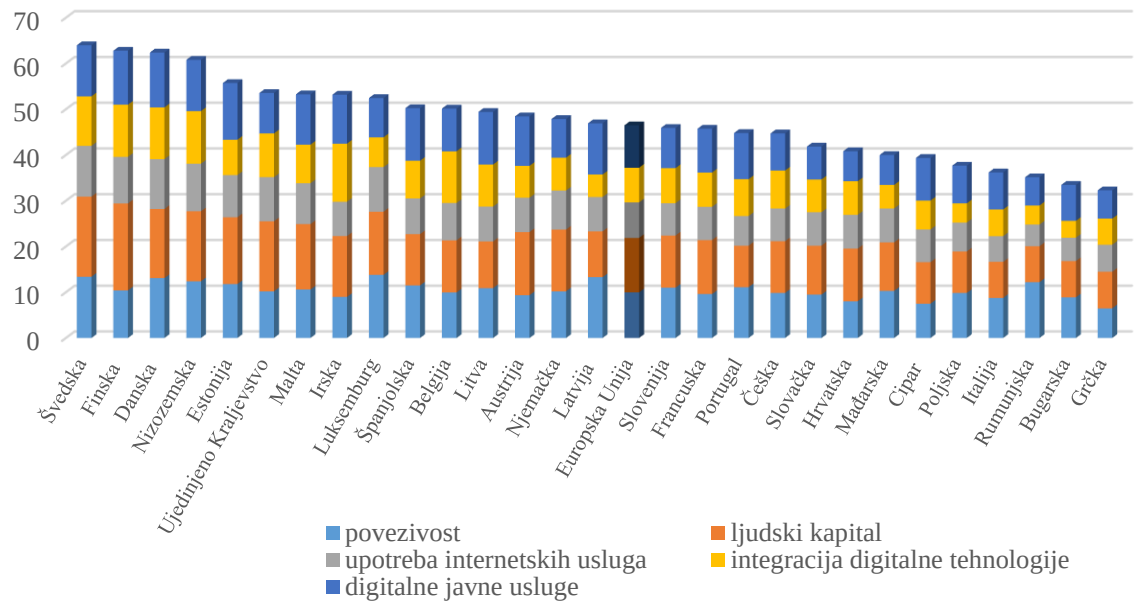

Grafikon 1. Indeks digitalne ekonomije i društva prema područjima u 2018. godini za zemlje članice Europske unije
Izvor: izrada autorice prema podacima iz European Commission (2021_d).

Na grafikonu 1., na kojem je prikazan Indeks digitalne ekonomije i društva prema područjima za zemlje članice Europske unije u 2018. godini, može se primijetiti da Švedska ima najveći ukupni rezultat zemlje (64 boda). Slijede ju Finska (62,8 boda), Danska (62,4 boda) i Nizozemska (60,8 boda). Europski prosjek je 46,49 boda. Najniži ukupni rezultat zemlje ima Grčka s 32,28 boda.

„Eurofound[15] je 2015. objavio studiju o novim oblicima rada u kontekstu stalno rastuće digitalne ekonomije. Studija je identificirala devet novih oblika rada i zapošljavanja koji su se u Europi pojavili većinom nakon 2000. godine. Ti novi oblici rada i zapošljavanja mogu se općenito klasificirati u dvije skupine:

[15] EUROFOUND = Europska zaklada za poboljšanje životnih i radnih uvjeta

I. novi modeli zapošljavanja između poslodavca i zaposlenika ili klijenta i radnika
II. novi obrasci rada, tj. novi načini obavljanja posla.

U studiji se zaključuje da kod svih navedenih novih oblika rada i zapošljavanja fleksibilnost predstavlja ključnu karakteristiku koja je izbila u prvi plan zbog povećane potražnje za fleksibilnim radom kako kod poslodavaca tako i kod radnika. No, također se zaključuje da zbog nestabilnih ekonomskih prilika za radnike i poslodavce upuštanje u nove oblike rada i zapošljavanja nije nužno slobodan izbor već često izbor iz nužde.“ (Butković i Samardžija, 2019: 26) Sistematizirani pregled spomenutih oblika rada, koji su u glavnom fokusu interesa navedenog istraživanja, su prikazani u tablici 7.

Tablica 7. Sistematizirani pregled novih oblika rada u digitalnoj ekonomiji EU-a

Oblici rada	Opis načina primjene
Dijeljenje zaposlenika	Više poslodavaca angažira jednog zaposlenika kako bi se zadovoljile potrebe za ljudskim resursima više tvrtki, što rezultira punim radnim vremenom za tog zaposlenika.
Dijeljenje posla	Poslodavac zapošljava dva ili više zaposlenika kako bi zajedno radili na nekom poslu, kombinirajući dva ili više poslova s nepunim radnim vremenom u jedno radno mjesto s punim radnim vremenom.
Privremeno upravljanje	Poslodavac privremeno zapošljava visokokvalificiranog stručnjaka za specifičan projekt ili rješavanje nekog problema, čime se integriraju vanjski kapaciteti menadžmenta u organizaciji rada.
Povremeni rad	Poslodavac nije obvezan redovito davati posao zaposleniku, nego ima fleksibilnost pozvati ga na zahtjev.
Mobilni rad temeljen na informacijsko-komunikacijskim tehnologijama (IKT)	Poslodavac omogućuje radniku obavljati posao s bilo kojeg mjesta u bilo koje vrijeme, uz podršku informacijsko-komunikacijskih tehnologija.
Rad na temelju vaučera	Poslodavac plaća usluge vaučerima kupljenim od ovlaštene organizacije koja pokriva plaće i doprinose za socijalno osiguranje angažiranih radnika.
Portfeljni rad	Više poslodavaca koristi samozaposlenog pojedinca za obavljanje manjih poslova za svakog od njih.
Online platforme koje uparuju poslodavce i zaposlenike	Poslodavac ili klijent velike zadatke obično dijeli među zaposlenicima putem „virtualnog oblaka“.
Suradničko zapošljavanje	Honorarni radnici, samozaposleni ili mikropoduzeća djeluju zajedno kako bi prevladali ograničenja svoje veličine i profesionalne izolacije.

Izvor: izrada autorice prema Butković, H., Samardžija, V. (2019: 26 - 27).

U studiji Eurofounda također je naznačeno da diljem Europe prethodno navedeni novi oblici rada i zapošljavanja nisu kao takvi bili predmet brojnih rasprava o tržišnim politikama. „Umjesto toga raspravljalo se o modalitetima povećanja fleksibilnosti i inkluzivnosti tržišta rada, legalizaciji neformalnih praksi zapošljavanja, osiguravanju solidnih uvjeta za socijalnu zaštitu kao i suzbijanju potiskivanja standardnog zapošljavanja od strane novih oblika rada i zapošljavanja. Studija također naglašava da su takve debate obično vodili socijalni partneri. Poslodavci su većinom branili fleksibilnost i smanjivanje troškova koje donose novi oblici rada i zapošljavanja, dok su sindikati izražavali zabrinutost vezano uz socijalnu zaštitu, prava iz zaposlenosti, itd.“ (Butković i Samardžija, 2019: 27)
Iako ova fleksibilnost može podržati bolju ravnotežu između posla i privatnog života, ponekad također podrazumijeva neregularnost rada i prihoda, čak i za visokokvalificirane radnike.

Cilj digitalne strategije EU-a je ovu transformacija u digitalno društvo olakšati kako ljudima, tako i tvrtkama, dok istovremeno pomaže postići svoj cilj klimatski neutralne Europe do 2050. godine, „odnosno postati gospodarstvo s nultom neto stopom emisija stakleničkih plinova. Taj je cilj srž europskog zelenog plana te je u skladu s obvezom EU-a na temelju Pariškog sporazuma o globalnom djelovanju u području klime.“ (Europska komisija, 2021_a)
Komisija je jednako tako odlučna u intenciji donošenja europskog „digitalnog desetljeća“ zbog kojeg Europa treba ojačati svoj digitalni suverenitet i postaviti standarde - s jasnim fokusom na podatke, tehnologiju i infrastrukturu. (Europa, 2021)
Uz navedeno, bitno je istaknuti da je i „fenomen globalizacije vođen tehnološkim napretkom, koji smanjuje troškove transporta, mobilnosti i komuniciranja te političkim odlukama kojima se smanjuju ili čak eliminiraju barijere međunarodnoj mobilnosti.“ (Buiter, 2001 navedeno u Grgić i Bilas, 2008: 606)

5. SOCIO-EKONOMSKI TRENDOVI I POLITIKE NA TRŽIŠTU RADA EU-a

Socijalna politika je vezivno tkivo različitih disciplina, kao što su povijest, pravo, politika, ekonomija, sociologija i psihologija. Neosporna činjenica je da većina država svojim izborom socijalne politike nastoji postići i promicati socijalnu pravdu i blagostanje, osigurati socijalne ciljeve i reducirati negativne ekonomske posljedice za svoje građane / državljane.

Mintas Hodak i suautori (2010: 478) navode kako u današnje vrijeme, u kojem je liberalno-tržišno viđenje gospodarstva dominantno u zapadnim zemljama, socijalna politika ostaje ključno područje u kojem se negativne popratne posljedice slobodne tržišne utakmice mogu u određenoj mjeri dokinuti državnom akcijom. Njenim provođenjem, prema Stubbsu i Zrinšćaku (2005: 159), utječe se na prava i mogućnosti građana u kontekstu zadovoljenja njihovih životnih potreba. Međutim, kako navode Puljiz i suautori (2005: 3), socijalna politika je složen i prijeporan pojam iz razloga što se nasljeđe i praksa socijalne politike znatno razlikuju od jedne do druge zemlje pa se razlikuju i termini kojima se označavaju sadržaji koje socijalna politika, uvjetno rečeno, pokriva.

5.1. Makroekonomski indikatori i socijalna politika EU-a

Makroekonomski indikatori su osnovne analitičke veličine kojima se izražava stanje nacionalnog gospodarstva i predstavljaju statističke informacije o ekonomskoj aktivnosti te su kao takvi input za donošenje ekonomskih odluka.

Makroekonomski indikatori fundamentalni su podaci ekonomske statistike koje vladine agencije i privatne organizacije objavljuju periodično. Ovi pokazatelji pružaju uvid u gospodarske performanse zemlje ili regije i stoga mogu imati značajan utjecaj na tržište. (Baráth i Wojčák, 2020: 3680)

„Od svih makroekonomskih pojmova najvažniji je bruto domaći proizvod – BDP (engl. *gross domestic product* - GDP) koji mjeri ukupnu vrijednost roba i usluga proizvedenih u nekoj zemlji. BDP je dio *nacionalnog dohotka i računa proizvoda* (*ili računa nacionalnog dohotka*), statističkog sustava koji donositeljima političkih odluka omogućuje utvrditi je li ekonomija u razdoblju kontrakcije ili ekspanzije te postoji li opasnost od teške recesije ili inflacije. Kada ekonomisti žele utvrditi razinu ekonomskog razvoja neke zemlje, promotrit će BDP po stanovniku.

Bruto domaći proizvod (BDP) najopsežnija je mjera ukupne proizvodnje roba i usluga neke države. To je zbroj dolarske vrijednosti potrošnje (C), bruto investicija (I), državnih izdataka za robe i usluge (G) i neto izvoza (X) ostvarenih u državi tijekom dane godine.
Prikazan simbolima, BDP izgleda ovako:

$$BDP = C + I + G + X$$

BDP se koristi u razne svrhe, ali najvažnija je mjerenje ukupnih rezultata neke ekonomije." (Samuelson i Nordhaus, 2011: 386-387)

Prema Mankiwu (2006: 505), formula BDP-a (koju autor označava s Y) se sastoji od istih komponenata uz promjenu oznake neto izvoza koja se prikazuje kao NX.

U tom kontekstu, Mankiw (2006: 505-506) s C označava osobnu potrošnju koja se odnosi na potrošnju kućanstva na robe i usluge čiji je sastavni dio i potrošnja na obrazovanje.
Ulaganja ili investicijska potrošnja (I) se odnosi na kupovanje roba koje će se koristiti u budućnosti za proizvodnju drugih roba i usluga te uključuje kupnju kapitalne opreme, zaliha i nekretnina u sklopu kojih je i kupovanje novoga stambenog prostora. S G je specificirana državna potrošnja koja obuhvaća kupnju roba i usluga mjesnih, državnih i federalnih vlasti te uključuje plaće državnih službenika i troškove javnih radova. Neto izvoz (NX) je razlika potrošnje stranaca na domaće proizvedenu robu (izvoz) i domaće potrošnje na stranu robu (uvoz). Pojam 'neto' unutar izraza 'neto izvoz' ukazuje na činjenicu da se uvoz oduzima od izvoza i to zato što je uvoz roba i usluga sastavni dio nekih drugih komponenti BDP-a.

Bruto domaći proizvod (BDP) se nerijetko upotrebljava „kao mjera za ukupnu veličinu gospodarstva, dok se izvedeni pokazatelji, kao što je BDP po stanovniku (po glavi stanovnika) – na primjer, u eurima ili prilagođen razlikama u razini cijena (što se izražava u standardima kupovne moći, PPS) – često upotrebljavaju za usporedbu životnih standarda ili za praćenje ekonomske konvergencije ili divergencije u Europskoj uniji (EU). Veći BDP po stanovniku implicira viši životni standard.
Nadalje, na temelju kretanja određenih sastavnica BDP-a i povezanih pokazatelja, kao što su pokazatelji gospodarskog proizvoda, uvoza i izvoza, domaće (privatne i javne) potrošnje ili ulaganja te podaci o raspodjeli prihoda i štednje, mogu se dobiti korisne informacije o glavnim

pokretačima gospodarske aktivnosti, koje se mogu upotrijebiti za izradu, praćenje i ocjenjivanje konkretnih politika EU-a.“ (Eurostat, 2020f)

U sljedećoj tablici prikazan je bruto domaći proizvod po stanovniku od 2008. do 2018. godine po državama članicama EU-a.

Tablica 8. BDP po stanovniku od 2008. do 2018. godine po državama članicama EU-a

(iznosi iskazani u €)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	$\bar{x}$
Austrija	36.280	34.830	35.390	36.300	36.390	36.180	36.130	36.140	36.430	37.090	37.810	36.270
Belgija	33.640	32.700	33.330	33.460	33.490	33.490	33.870	34.360	34.690	35.210	35.580	33.984
Bugarska	5.140	4.990	5.050	5.300	5.350	5.400	5.530	5.790	6.050	6.310	6.550	5.587
Cipar	24.680	23.550	23.400	22.900	21.780	20.400	20.240	21.040	22.360	23.120	23.770	22.476
Češka	15.500	14.690	15.020	15.310	15.170	15.160	15.480	16.290	16.670	17.490	17.980	15.887
Danska	45.700	43.220	43.840	44.240	44.170	44.410	44.890	45.630	46.720	47.360	48.260	45.313
Estonija	12.640	10.830	11.150	12.010	12.430	12.640	13.060	13.330	13.650	14.440	15.090	12.843
Finska	37.330	34.150	35.080	35.810	35.140	34.660	34.390	34.460	35.320	36.390	36.880	35.419
Francuska	31.310	30.250	30.690	31.210	31.160	31.170	31.320	31.540	31.770	32.380	32.860	31.424
Grčka	22.560	21.530	20.320	18.500	17.240	16.800	17.040	17.080	17.110	17.410	17.780	18.488
Hrvatska	11.470	10.630	10.500	10.500	10.300	10.280	10.310	10.630	11.100	11.560	11.990	10.843
Irska	38.600	36.300	36.770	36.840	36.740	37.010	39.920	49.510	49.930	53.890	57.780	43.026
Italija	28.230	26.590	26.930	27.020	26.090	25.480	25.420	25.640	26.020	26.490	26.740	26.423
Latvija	9.990	8.710	8.500	9.200	9.700	10.030	10.310	10.740	11.030	11.560	12.140	10.174
Litva	10.110	8.710	9.030	9.790	10.300	10.780	11.250	11.590	12.040	12.720	13.310	10.875
Luksemburg	81.880	76.900	79.160	79.310	77.240	78.030	79.490	81.300	82.880	82.550	83.470	80.201
Mađarska	10.500	9.810	9.900	10.110	10.010	10.230	10.690	11.130	11.410	11.930	12.560	10.753
Malta	15.960	15.450	15.920	16.080	16.380	16.930	18.080	19.590	20.260	20.990	21.750	17.945
Nizozemska	39.810	38.160	38.470	38.880	38.340	38.180	38.580	39.170	39.810	40.730	41.450	39.235
Njemačka	32.320	30.580	31.940	33.200	33.280	33.330	33.920	34.130	34.610	35.380	35.720	33.492
Poljska	8.910	9.070	9.390	9.860	10.020	10.170	10.510	10.920	11.260	11.820	12.460	10.399
Portugal	17.260	16.710	16.990	16.720	16.110	16.050	16.260	16.620	17.010	17.650	18.150	16.866
Rumunjska	6.730	6.410	6.190	6.350	6.510	6.760	7.020	7.320	7.720	8.320	8.740	7.097
Slovačka	12.600	11.890	12.540	12.980	13.200	13.270	13.620	14.270	14.550	14.970	15.540	13.585

Slovenija	19.190	17.570	17.750	17.870	17.360	17.160	17.620	17.990	18.540	19.430	20.170	18.241
Španjolska	24.200	23.100	23.040	22.770	22.080	21.840	22.210	23.080	23.760	24.410	24.880	23.215
Švedska	40.100	38.030	39.950	40.920	40.380	40.510	41.180	42.580	42.920	43.430	43.760	41.251
UK	30.940	29.420	29.750	29.960	30.200	30.660	31.220	31.700	32.050	32.460	32.700	31.005
$\bar{x}$	25.128	23.742	24.143	24.407	24.163	24.179	24.627	25.485	25.988	26.696	27.353	

Izvor: izrada autorice prema podacima sa Eurostata (2020_g).

Analizom podataka u tablici, može se uočiti da je pad BDP-a po stanovniku u 2009. godini u gotovo svim promatranim državama uzrokovan Velikom recesijom. Nadalje, većina promatranih država uspjela je do 2018. godine ostvariti i veću vrijednost BDP-a po stanovniku no u 2008. godini, što je vidljivo i prema prosječnim vrijednostima po godinama. Ako se uzmu u obzir prosječne vrijednosti izračunate prema državama, uvjerljivo najveći iznos BDP-a po stanovniku ima Luksemburg.

„Ciljevi makroekonomske politike jesu:

1. visoka i rastuća razina nacionalne proizvodnje
2. visoka zaposlenost s niskom nezaposlenosti
3. stabilnost ili blagi rast razine cijena.“ (Samuelson i Nordhaus, 2011: 375)

„Od svih makroekonomskih pokazatelja, pojedinci najizravnije osjećaju utjecaj zaposlenosti i nezaposlenosti. Ljudi žele dobiti dobro plaćen posao bez predugog traženja i čekanja, žele sigurnost i povlastice. Makroekonomski gledano, to su ciljevi *visoke zaposlenosti* koja je naličje *niske nezaposlenosti*. Stopa nezaposlenosti postotak je nezaposlene radne snage, odnosno ista mjeri udio radne snage koji traži posao, a ne može ga pronaći. Radna snaga uključuje sve zaposlene i one nezaposlene koji traže posao. Nezaposleni koji ne traže posao nisu dio radne snage.“ (Samuelson i Nordhaus, 2011: 373)

Svaka zajednica ima svoje izazove i mogućnosti, ovisno o različitim čimbenicima koji djeluju na samu zajednicu. Iz tog razloga, definicija gospodarskog razvoja ovisit će o zajednici u kojoj osobe žive. Ali, ako se pogleda šira slika, može se reći kako ekonomski razvoj čine programi, politike ili aktivnosti koje nastoje poboljšati gospodarsku dobrobit i kvalitetu života zajednice. U Ekonomskom leksikonu (2011: 248) gospodarski razvoj je definiran kao „proces gospodarskog rasta koji je ujedno praćen promjenama ekonomske i socijalne strukture društva, poboljšanjem kvalitete života i standarda te preraspodjelom dohotka i društvene moći. Teorija gospodarskog razvoja bavi se istraživanjem međuovisnosti ekonomskih varijabli koje određuju

dugoročni potencijalni razvoj neke države, što znači maksimalni dugoročni porast realnog nacionalnog dohotka (i dohotka po stanovniku).“

Uz BDP *per capita,* kao jednog od najvažnijih pokazatelja gospodarskog razvoja, pokazatelji koji se često koriste u analizama su i stopa zaposlenosti, stopa nezaposlenosti, rast populacije, profesionalna struktura radne snage, urbanizacija, potrošnja po stanovniku, infrastruktura i društveni uvjeti.

Kada se govori o profesionalnoj strukturi radne snage, ponajprije se treba navesti podjela gospodarske djelatnosti. Ista se dijeli na primarne, sekundarne i tercijarne djelatnosti. U literaturi se može pronaći dodatna podjela na kvartarne (djelatnosti koje stvaraju znanje) i kvintarne djelatnosti (djelatnosti kojima se ostvaruju moderne poslovne usluge). Primarne djelatnosti uključuju izravno uklanjaju resurse iz zemlje, ali ne i preradu. Općenito, oni uključuju poljoprivredu, rudarstvo i ribarstvo. Sekundarne djelatnosti uključuju pretvaranje resursa u gotove proizvode. To su prerađivačke djelatnosti. Tercijarne djelatnosti obuhvaćaju uslužni sektor gospodarstva. One uključuju maloprodaju, prijevoz, obrazovanje, bankarstvo, itd. Kako se zemlje razvijaju, struktura zanimanja radne snage se mijenja. U najmanje razvijenim zemljama većina ljudi bavi se primarnim aktivnostima. U zemljama s visokim dohotkom većina je ljudi uključena u tercijarni sektor.

Urbanizacija je postotak stanovništva zemlje koje živi u urbanim područjima. Urbana područja općenito označavaju gradove s 2500 ili više ljudi. Općenito, kako se zemlje razvijaju, urbanizacija raste.

Potrošnja po stanovniku dobar je pokazatelj razvoja. Generalno, što je zemlja bogatija, njeni građani više troše.

Pod infrastrukturom se podrazumijevaju urbana središta, prometne mreže, komunikacije, sustavi distribucije energije, farme, tvornice, rudnici i objekti kao što su škole, bolnice, itd.

Društveni uvjeti uključuju stopu pismenosti, životni vijek, zdravstvenu njegu, smrtnost dojenčadi i sl.

Tragom navedenog, za potrebe analize hipoteze H1 u diseratciji je korišten BDP *per capita* kao ključni pokazatelj gospodarskog razvoja. Nerijetko se u literaturi može pročitati kako su najrazvijenije zemlje one s najvećim BDP-om po stanovniku. Jasno je, međutim, da BDP po stanovniku ne daje cijelu sliku o razvoju zemlje. BDP po stanovniku izračunava se dijeljenjem BDP-a s brojem stanovnika. To ne govori ništa o tome kako se prihodi raspodjeljuju ili troše. Rast BDP-a po stanovniku mogao bi biti rezultat rasta dohotka bogatijih skupina u društvu, pri čemu prihodi siromašnijih skupina ostaju uglavnom nepromijenjeni.

Iako se u analizama upravo BDP po stanovniku koristi kao najčešća varijabla putem koje se mjeri gospodarski rast, zbog navedenog ograničenja, u disertaciji se kroz hipoteze H1.1 te H.1.2. u odnos stavljaju varijable (udio privremenog zapošljavanja i zapošljavanja na nepuno radno vrijeme) sa stopom zaposlenosti, odnosno varijable (udio rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće) sa stopom nezaposlenosti koje su također pokazatelji gospodarskog razvoja.

5.2. Institucije i zakonodavni okvir tržišta rada EU-a

Europska unija, kao složena politička struktura, je nastala na temelju Ugovora o Europskoj Uniji (EU) potpisanog u Maastrichtu 1992. godine, a koji je stupio na snagu 1. studenog 1993. godine. Unatoč širokom opsegu svojih područja djelovanja i raznolikosti postupaka donošenja odluka, Unija ima jedinstveni institucionalni okvir čija je zadaća dosljedno upravljati svim svojim politikama.

Institucije Unije su, prije svega, institucije Zajednice. Ovisno o dotičnom području djelatnosti, iste institucije imaju različite ovlasti i djeluju u skladu s različitim postupcima donošenja odluka.

Prema Bušelić (2017: 55), potrebno je uzeti u obzir i uskladiti gospodarske, socijalne i ekonomske politike s politikom tržišta rada kako bi se odredio institucionalni okvir djelovanja tržišta rada.

„Zakoni koji reguliraju radne odnose, a posebno kolektivno pregovaranje, predstavljaju značajan institucionalni faktor koji utječe na nadnice, zaposlenost i alokaciju resursa.“ (McConell i Brue, 1944: 314-315 navedeno u Bušelić, 2017: 55)

Politikama Europske unije posljednjih desetljeća nastoji se postići visok stupanj zaposlenosti i snažna socijalna zaštita, poboljšanje uvjeta za život i rad te zaštita socijalne kohezije.

Europska unija ima za cilj promicanje društvenog napretka i poboljšanje životnih i radnih uvjeta svih naroda Unije.

Što se tiče radnog prava, EU dopunjuje inicijative politike koje su poduzele pojedine zemlje EU postavljanjem minimalnih standarda. U skladu s Ugovorom - posebno člankom 153. - donosi zakone (direktive) koji postavljaju minimalne zahtjeve za:

- uvjete rada i zapošljavanja
- informiranje i savjetovanje radnika.

Pojedine zemlje EU-a odlučile su minimalnu razinu zaštite povećati i unaprijediti. Iako Europska direktiva o radnom vremenu, primjerice, daje radnicima pravo na godišnji plaćeni dopust od 20 dana, mnoge su se zemlje odlučile za izdašnije pravo u korist radnika.
Provjeravanje ugrađenosti direktiva u nacionalno zakonodavstvo i sustavno praćenje njihovog izvršavanja prati Europska komisija. Ako Europska komisija utvrdi kako zemlja članica nije pravilno ugradila direktivu u nacionalno zakonodavstvo, može odlučiti o pokretanju prekršajnog postupka. Na taj način osigurava da sva prava iz direktive budu uključena i dostupna u nacionalnom pravu. Za kontrolu pravilnog provođenja zakonskih normi zaduženi su inspekcije i sudovi. Stoga, kada god se pojavi problem tumačenja radnog spora, predmet se može uputiti Sudu pravde Europske unije. Europski sud potom daje nacionalnom sudu odgovore koji su mu potrebni za rješavanje spora. (European Commission, 2021_k)

S više od 240 milijuna radnika u Europskoj uniji, prava EU-a iz radnog prava izravno pogoduju velikom broju građana i imaju pozitivan utjecaj na jedno od najvažnijih i opipljivijih područja njihova svakodnevnog života.
EU radno pravo također koristi poslodavcima i društvu EU-a u cjelini:

- ✓ pruža jasan okvir prava i obveza na radnom mjestu
- ✓ osigurava zdravstvenu zaštitu radne snage
- ✓ promiče održivi gospodarski rast.

Štoviše, radno pravo EU-a ide paralelno s jedinstvenim tržištem. Slobodan protok roba, usluga, kapitala i radnika mora biti popraćen pravilima radnog prava kako bi se osiguralo pošteno tržišno natjecanje. (European Commission, 2021_k)
Sa svojim prijedlozima, EU ima i vodeću ulogu u međunarodnoj suradnji u području tržišnog natjecanja te nastoji promicati najbolju praksu. EU je jedan od osnivača Međunarodne mreže tržišnog natjecanja (ICN). (Europa, 2021_b)
Politika tržišnog natjecanja Europske unije ima za cilj zaštititi učinkovito funkcioniranje tržišta od narušavanja tržišnog natjecanja, bilo da isto potječe iz država članica (krivo usmjerena državna potpora), tržišnih dionika (nekorektno jednostrano ili koordinirano ponašanje) ili spajanja koja bi značajno pridonijela ometanju učinkovitog natjecanja. Navedeno se provodi provedbom pravila tržišnog natjecanja, napose kontrolom udruživanja (trustovi/karteli) i kontrolom državnih potpora.
Međutim, natjecanje nije samo sebi svrha. Ono doprinosi tehnološkom razvoju i inovacijama, boljem izboru proizvoda i usluga, nižim cijenama, većoj kvaliteti i većoj produktivnosti u gospodarstvu u cjelini. Politika tržišnog natjecanja Europske unije aktivno doprinosi širim

ciljevima Komisije, poput jačanja radnih mjesta, rasta i ulaganja, povezanog jedinstvenog digitalnog tržišta, otporne energetske unije s perspektivnom politikom klimatskih promjena, dubljeg i pravednijeg unutarnjeg tržišta s ojačanom industrijskom bazom te snažniju i pošteniju Ekonomsku i monetarnu uniju. (European Commission, 2017_b: 5)

5.2.1. Institucije, agencije i partneri na tržištu rada EU-a

Na tržište rada Europske unije, osim zakonodavne regulacije, utječe i niz institucija. No unatoč progresivnoj ekonomskoj integraciji u Europi, kao i brzim tehnološkim promjenama, nacionalni aranžmani institucija tržišta rada i socijalne politike i dalje su vrlo raznoliki.
Iz tog razloga, Europska unija surađuje s i unutar Međunarodne organizacije rada - ILO[16]-a, Organizacije za ekonomsku suradnju i razvoj - OECD[17]-a, Ujedinjenim narodima - UN[18]-a, kao i sa i unutar Skupine od dvadeset ministara financija i guvernera središnjih banaka - G20[19], Skupine G7[20] i drugih međunarodnih organizacija i foruma kako bi:

- ✓ promicala dostojanstven rad za sve
- ✓ promicala socijalnu dimenziju globalizacije
- ✓ provodila vanjsku dimenziju europskih politika.

EU je razvila dugogodišnji strateški odnos s Međunarodnom organizacijom rada s kojom provodi zajedničke projekte. U sinergiji promiču dostojanstven rad i agendu održivog razvoja do 2030. godine. Suradnja EU-a i ILO-a usmjerena je na promicanje temeljnih načela i radnog prava, uključujući trgovinu, kao i druga područja socijalne politike.
EU je također u potpunosti uključena u G7. Prvi službeni sastanak ministara rada i zapošljavanja G7 (zajedno s ministrima razvojne politike) dogodio se 2015. godine pod njemačkim predsjedavanjem G7. Inicijative G7 u socijalnim pitanjima uključuju:

- *Vision Zero Fund*, za pomoć u poboljšanju dostojanstvenog rada i zaštite na radu u globalnim lancima opskrbe, za što Komisija pruža financijsku potporu
- *G7 Future of Work Forum*, kako bi razgovarali o budućnosti rada

[16] ILO – Međunarodna organizacija rada (engl. *International Labour Organization*)
[17] OECD - Organizacija za ekonomsku suradnju i razvoj (engl. *Organisation for Economic Co-operation and Development*)
[18] UN – Ujedinjeni narodi (engl. *United Nations*)
[19] G20 – Skupina od dvadeset ministara financija i guvernera središnjih banaka (engl. *Group of Twenty Finance Ministers and Central Bank Governors*)
[20] G7 - Skupina G7 (svjetski ekonomski vrh) (engl. *The Group of Seven*)

- Ministarske sastanke i naknadne obveze u tehničkim skupinama, uključujući novu *Radnu skupinu za zapošljavanje G7*, gdje DG EMPL[21] priprema sudjelovanje i doprinose EU-a.

Europska unija je punopravna članica G20. Ministri zapošljavanja G20 okupili su se prvi put 2010. godine u Washingtonu. Inicijative G20 u socijalnim pitanjima uključuju:

- *cilj G20 za sudjelovanje žena*, kako bi se poboljšala participacija žena u radnoj snazi
- *cilj mladih,* smanjiti koncentraciju rizične mladeži.

Godišnje rasprave u radnim skupinama i između visokih dužnosnika odvijaju se također u okviru Radne skupine za zapošljavanje (EWG), gdje DG EMPL predstavlja EU. EWG prati provedbu *planova zapošljavanja svojih članova G20, uključujući one EU*. (European Commission, 2021$_i$)

Europska komisija surađuje sa širokim rasponom agencija i partnera u svrhu:

- organiziranja javnih konzultacija radi traženja stavova prije poduzimanja glavnih političkih inicijativa
- pomaganja nacionalnim vladama u koordiniranju njihovih napora u stvaranju radnih mjesta, osiguravanju mirovina održivim i rješavaju siromaštva i socijalne isključenosti
- suradnje s međunarodnim organizacijama i partnerskim zemljama u promicanju dostojnog rada
- ostvarivanja bliskog kontakta s predstavnicima europskih sindikata i poslodavcima - "socijalnim partnerima". Postigli su velik broj sporazuma na europskoj razini, od kojih su neki transformirani u obvezujuće zakonodavstvo.
- suradnje s nacionalnim vlastima u upravljanju sredstvima EU-a, posebno Europskim socijalnim fondom
- suradnje s nevladinim organizacijama iz socijalnog sektora
- povezivanja sa stručnjacima iz zemalja EU-a putem raznih tehničkih odbora
- suradnje s:
    a) Europskim nadzornim tijelom za rad (ELA)
    b) Europskom zakladom za poboljšanje životnih i radnih uvjeta (EUROFOUND)
    c) Europskom agencijom za sigurnost i zdravlje na radu (EU-OSHA)
    d) Europskim centrom za razvoj strukovnog obrazovanja (CEDEFOP)

[21] DG EMPL = Generalna uprava za zapošljavanje, socijalna pitanja i uključivanje (engl. *Directorate-General for Employment, Social Affairs and Inclusion*)

e) Europskom zakladom za osposobljavanje (ETF). (European Commission, 2021_a)

5.2.2. Zakon o radu Europske unije

Zakon o radu EU-a definira prava i obveze radnika i poslodavca te obuhvaća:

- radne uvjete - radno vrijeme, rad s nepunim radnim vremenom i na određeno vrijeme, raspoređivanje radnika
- informiranje i savjetovanje radnika o kolektivnim otkazima, transferima tvrtki itd.

Europska unija stvorila je *Europski centar stručnosti (ECE) u području radnog prava, zapošljavanja i politika tržišta rada* 2016. godine.

Iz perspektive radnog prava, ciljevi Europskog centra stručnosti, pored ostalih, su i:

- pomoć Komisiji u njezinoj ulozi osiguravanja ispravne primjene prava EU-a u svim državama članicama i nadziranje reforme radnog zakonodavstva kao dio procesa Europskog semestra u kontekstu strategije EU 2020
- ojačati sposobnost Komisije da može predvidjeti bilo koja pitanja i nejasnoće koje bi mogle proizaći iz primjene direktiva EU-a i analizirati potencijalna pravna pitanja i učinak presuda Europskog suda pravde
- poboljšati svijest i potaknuti javnu raspravu o aktualnim pitanjima od interesa za radno pravo i zakonodavstvo EU-a.

Centar stručnosti pokriva pravne, regulatorne, ekonomske i političke aspekte zapošljavanja i tržišta rada, uključujući reforme u 28 država članica, zemljama Europskog gospodarskog prostora (EEA), zemljama kandidatima i potencijalnim kandidatima koji ispunjavaju uvjete za sudjelovanje na osovini napretka *Programa Europske unije za zapošljavanje i socijalne inovacije (EaSI)*. (European Commission, 2021_k)

EaSI je instrument financiranja na razini EU-a za promicanje visoke razine kvalitetnog i održivog zapošljavanja, koji jamči primjerenu i pristojnu socijalnu zaštitu, borbu protiv socijalne isključenosti i siromaštva te poboljšanje uvjeta rada. Za razdoblje 2021. - 2027., program EaSI postat će dio *Europskog socijalnog fonda Plus (ESF+)*. (European Commission, 2021_h)

ESF+ glavni je instrument EU-a za ulaganje u ljude s ciljem izgradnje socijalnije i uključivije Europe. ESF+ financira provedbu načela iz Europskog stupa za socijalna prava kroz akcije u

području zapošljavanja, obrazovanja i vještina te socijalne inkluzije. (European Commission, 2021b)

5.2.2.1. Direktive o radnim uvjetima i o radnom vremenu

Direktive o transparentnim i predvidljivim radnim uvjetima i o radnom vremenu izvorno datiraju s početka 1990-ih, ali su revidirane 2019. godine u svjetlu promjena vezanih uz radne odnose.

Direktiva o transparentnim i predvidljivim radnim uvjetima

Direktiva 2019/115213 Europskog parlamenta i Vijeća od 20. lipnja 2019. o transparentnim i predvidljivim radnim uvjetima (Official Journal of the European Union, 2019) utvrđuje minimalne standarde i prava radnika kako bi se povećala predvidljivost i transparentnost u zapošljavanju. Direktiva revidira prethodnu „Direktivu o pisanoj izjavi“[22] i ima za cilj ispraviti njene slabosti u pogledu osobnog i materijalnog opsega. Prethodna je direktiva dopuštala izuzeće određenih kategorija radnika (na primjer povremeni radnici). Također je državama članicama dala mogućnost definiranja na koga se direktiva odnosi.

Slijedom toga, Komisija je 2017. predložila novu direktivu jer su nedavni trendovi u svijetu rada prouzročili više nestabilnosti i nedostatka predvidljivosti u nekim radnim odnosima. Nova se direktiva u uvodnim izjavama poziva na načela Europskog stupa socijalnih prava: svi radnici imaju pravo na pravedan i jednak tretman u vezi s radnim uvjetima, pristupom socijalnoj zaštiti i osposobljavanju (načelo 5); radnici imaju pravo biti pisano obaviješteni o svojim pravima i obvezama na samom početku zaposlenja te na informacije i zaštitu u slučaju otkaza (načelo 7). Stoga, nova direktiva nudi minimalnu univerzalnu zaštitu za sve radnike u EU-u, 'uključujući one u kratkoročnim i povremenim radnim odnosima'. Također, sadrži neka osnovna prava poput prava na razumno probno razdoblje. (Szpejna i Boudalaoui-Buresi, 2020: 10)

Direktiva o radnom vremenu

Direktiva 2003/88 / EC20 Europskog parlamenta i Vijeća od 4. studenoga 2003. o određenim aspektima organizacije radnog vremena (Official Journal of the European Union, 2003) objedinjuje izvornu Direktivu o radnom vremenu 93/104/EC21 iz 1993. i afirmira potrebu primjerenog razdoblja odmora i odgovarajuće pauze svim radnicima širom EU-a. Svrha je

[22] 91/533/EEZ: Direktiva Vijeća od 14. listopada 1991. o obvezi poslodavca da obavijesti radnike o uvjetima koji se primjenjuju na ugovor o radu ili radni odnos

direktive utvrditi „minimalne sigurnosne i zdravstvene zahtjeve za organizaciju radnog vremena“ (članak 1.) s obzirom na to da „posebni uvjeti rada mogu imati štetne učinke na sigurnost i zdravlje radnika“. Postavlja maksimalno ograničenje za tjedno radno vrijeme i ograničava duljinu noćnih razdoblja rada. I Europski stup socijalnih prava (Načelo 10) i Povelja o temeljnim pravima Europske unije u članku 31. odnose se na prava radnika na radne uvjete koji poštuju njihovo zdravlje i sigurnost na radu. Uz to, članak 31. Povelje predviđa pravo na „ograničenje maksimalnog radnog vremena, na dnevni i tjedni odmor i na godišnje plaćeno odsustvo“. (Szpejna i Boudalaoui-Buresi, 2020: 12) Pravni temelj direktive je članak 137. stavak 2. Ugovora o EZ-u (trenutni članak 153. stavak 2. TFEU[23]-a).

Godine 2004. predstavljen je prijedlog za izmjenu tadašnje direktive s ciljem uvođenja apsolutne maksimalne granice tjednog radnog vremena od šezdeset i pet sati, kao i definicije „vremena dežurstva”. Međutim, nije se mogao postići konsenzus o definiciji dežurstva i primjenjuje li se direktiva na radnika ili na ugovor. Slijedom toga, svaka država članica može slobodno provoditi direktivu u pogledu ovih aspekata. To pokreće raspravu o potrebi revizije postojećeg instrumenta kako bi se osigurala njegova jedinstvena primjena u EU-u. (Szpejna i Boudalaoui-Buresi, 2020: 12)

5.2.2.2. Direktive o nestandardnim oblicima zaposlenja

Nestandardni oblici zaposlenja konzistentan su dio europskih tržišta rada posljednjih desetljeća. S jedne strane, pomažu poslodavcima boriti se s naglim oscilacijama u potrebama za radnom snagom. S druge strane, privremeni položaji znače manje stabilnosti u okviru zaposlenja i dohotka te nesigurnost u pogledu budućnosti radnika. (Babos, 2014: 39)

Prema Godišnjem pregledu zapošljavanja i socijalnih kretanja u Europi Europske komisije za 2019. godinu, rad s nepunim radnim vremenom u 2018. godini iznosio je 19,2 % ukupne zaposlenosti, a oko 5 % svih radnika nedobrovoljno je zaposleno na nepuno radno vrijeme.

Privremeni ugovori zaposlenika iznosili su 12,1 % od ukupnog broja zaposlenih u 2018. godini, od kojih je većina također prisilna. Tri direktive, koje su nastale prije stupanja na snagu Lisabonskog ugovora 2009. godine, pružaju zaštitu radnicima zaposlenima na nestandardnim ugovorima (ugovori o radu na određeno vrijeme, ugovor o radu na nepuno radno vrijeme, ugovor o radu koji se sklapa s poduzećem za privremeno zapošljavanje) koji su postali obilježje niza sektora i zanimanja. Direktive prepoznaju potrebu za približavanjem životnih i radnih

[23] TFEU = Ugovor o funkcioniranju Europske unije (engl. *Treaty on the Functioning of the European Union*)

uvjeta radnika zaposlenih putem nestandardnih ugovora s ugovorima radnika koji su zaposleni na neodređeno vrijeme. Stoga im je cilj osigurati jednak tretman i zaštitu od diskriminacije. Direktive omogućuju državama članicama definirati ugovor o radu ili radni odnos u skladu sa svojim nacionalnim zakonom i praksom. (Szpejna & Boudalaoui-Buresi, 2020: 15)

Direktiva o radu na nepuno radno vrijeme

Direktiva utvrđuje sljedeća načela i obveze:

• Što se tiče uvjeta zaposlenja, postupanje s radnicima koji rade na nepuno radno vrijeme ne može biti nepovoljnije od radnika koji su zaposleni na puno radno vrijeme samo zato što rade na nepuno radno vrijeme, osim ako različito postupanje nije opravdano objektivnim razlozima (načelo nediskriminacije). (točka 4.1)

• Ako je to opravdano objektivnim razlozima, države članice nakon savjetovanja sa socijalnim partnerima u skladu s nacionalnim pravom, kolektivnim ugovorima ili praksi i/ili socijalni partneri mogu, gdje je to primjereno, uvjetovati pristup određenim uvjetima zapošljavanja duljinom staža, trajanjem rada ili visinom primanja. (klauzula 4.4)

• obveza utvrđivanja i uklanjanja pravnih ili administrativnih prepreka koje ograničavaju privremene mogućnosti rada (klauzula 5)

• odbijanje premještanja radnika sa punoga na nepuno radno vrijeme ili obrnuto ne predstavlja razlog za prestanak radnog odnosa (točka 5.2)

• poslodavci bi trebali razmotriti zahtjeve radnika za premještanjem iz punog u nepuno radno vrijeme (i obrnuto) ili za povećanje radnog vremena (točka 5.3 a, b)

• poslodavci bi trebali olakšati pristup radu s nepunim radnim vremenom u organizaciji i pružiti odgovarajuće informacije o mogućnostima rada na nepuno radno vrijeme i puno radno vrijeme (točka 5.3 c, d)

• poslodavci bi trebali olakšati mogućnosti za stručno osposobljavanje kako bi se osigurale „mogućnosti za razvoj karijere i profesionalna mobilnost“ (točka 5.3 d). (Szpejna & Boudalaoui-Buresi, 2020: 16)

Bušelić (2017: 93-94) navodi kako su glavni razlozi za poticanje i stvaranje poslova s nepunim radnim vremenom fleksibilnost tržišta rada, fleksibilnost zaposlenika tijekom radnog vijeka i fleksibilnost poduzeća. Fleksibilnost tržišta rada je značajna u kontekstu omogućavanja ponovnog ulaska na tržište rada dugoročno nezaposlenim osobama. Bitna je i iz razloga što doprinosi smanjenju troškova za isplatu potpora nezaposlenima te utječe na sprječavanje daljnjeg propadanja ljudskog kapitala pojedinca tijekom neaktivnosti.

Kroz poslove s nepunim radnim vremenom mladi imaju mogućnost ući na tržište rada i steći radno iskustvo, a osobe koje su u mirovini stječu mogućnost bavljenja plaćenim zaposlenjem. U najvećem omjeru u tim poslovima participiraju žene. Ova činjenica vezana je uz njihove kućanske odgovornosti te su sredstvo koje omogućava ženama ponovni ulaz na tržište rada dok brinu o djeci.

Kada se radi o fleksibilnosti poduzeća, zagovaratelji poslova na nepuno radno vrijeme ističu kako zaposleni na pola radnog vremena imaju nižu stopu apsentizma, višu motivaciju i produktivnost od radnika s punim radnim vremenom, što uvelike doprinosi ekonomskoj efikasnosti unutar poduzeća. Ipak, neka poduzeća nisu voljna uvoditi ugovore na pola radnog vremena jer ih je teže administrirati u vidu pružanja kontinuiteta i kvalitete.

Rodgers (2007: 7) ističe kako je radnicima potrebna fleksibilnost kako bi iskoristili nove prilike na tržištu rada, a to analogno ima implikacije na dizajn institucija za zaštitu - jer je pretpostavka da će najbolji način za povećanje sigurnosti biti povećanje prenosivosti prava između radnih mjesta.

<u>Direktiva o radu na određeno vrijeme</u>

„Direktiva predviđa sljedeća načela, mjere i obveze:

• prema radnicima koji su zaposleni na određeno vrijeme neće se postupati manje povoljno od radnika sa stalnim radnim odnosom samo zato što rade na određeno vrijeme, osim ako različito postupanje nije opravdano objektivnim razlozima (načelo nediskriminacije) (klauzula 4)

• mjere za sprečavanje zlouporabe koje proizlaze iz upotrebe uzastopnih ugovora o radu na određeno vrijeme, poput objektivnog opravdanja za obnavljanje takvih ugovora, maksimalnih ograničenja trajanja uzastopnih ugovora na određeno vrijeme i broja obnavljanja (odredba 5)

• poslodavci su dužni radnicima na određeno vrijeme pružiti informacije o slobodnim radnim mjestima dostupnim u njihovoj organizaciji (klauzula 6)

• poslodavci su dužni omogućiti pristup odgovarajućim mogućnostima osposobljavanja kako bi se poboljšale vještine radnika na određeno vrijeme, razvoj karijere i profesionalna mobilnost (klauzula 6)

• mjere informiranja i savjetovanja (klauzula 7).“ (Szpejna & Boudalaoui-Buresi, 2020: 17)

Zemlje članice EU-a moraju provesti barem jednu od sljedećih mjera u svojim nacionalnim zakonima kako bi spriječile zlouporabu uzastopnih ugovora na određeno vrijeme:

- objektivni razlozi za obnavljanje ugovora na određeno vrijeme
- maksimalno ukupno trajanje uzastopnih ugovora na određeno vrijeme

- maksimalan broj obnavljanja ugovora na određeno vrijeme. (Europa, 2020a)

Direktiva o poduzećima za privremeno zapošljavanje

• „uvjeti rada i zapošljavanja (definirani u direktivi) za radnike zaposlene putem poduzeća za privremeno zapošljavanje bi, za vrijeme trajanja njihova ustupanja poduzeću korisniku, trebali biti najmanje jednaki uvjetima koji bi na te radnike bili primjenljivi da ih je na isto radno mjesto izravno zaposlilo poduzeće korisnik. Načelo jednakog postupanja odnosi se i na trudnice i dojilje, na jednak tretman muškaraca i žena i na bilo koju akciju borbe protiv diskriminacije po raznim osnovama, poput spola, rase ili etničkog podrijetla, vjere, invaliditeta, dobi i seksualne orijentacije (načelo jednakog postupanja) (članak 5.)

• privremenim radnicima treba pružiti iste mogućnosti kao i ostalim radnicima u organizaciji kako bi našli stalno zaposlenje te bi trebali sukladno tome biti obaviješteni o svim otvorenim slobodnim radnim mjestima (članak 6.1)

• radniku koji je zaposlen putem agencije za privremeno zapošljavanje nije zabranjeno sklapanje ugovora o radu ili radnog odnosa s korisničkim poduzećem nakon završetka privremenog zaposlenja (članak 6.2)

• privremenim radnicima (agencije za privremeno zapošljavanje) ne mogu naplatiti nikakve naknade za zapošljavanje (članak 6.3)

• radnicima iz agencija za privremeno zapošljavanje pod istim će se uvjetima odobriti pristup kolektivnim objektima u korisničkoj tvrtki (poput menze ili ustanova za čuvanje djece), također dostupnim radnicima koji su izravno zaposleni u toj tvrtki, osim ako je to objektivno opravdano (članak 6.4)

• države članice promiču dijalog između socijalnih partnera kako bi se povećala obuka i dostupnost skrbi o djeci za privremene radnike (članak 6.5).“ (Szpejna i Boudalaoui-Buresi, 2020: 18-19)

5.3. Aktivne politike tržišta rada EU-a

Politike tržišta rada (LMP) složeni su skup pravila uspostavljenih s ciljem osiguravanja ravnoteže između potražnje i ponude na tržištu rada. Kroz LMP bi se također trebali podržati zaposlenici u vremenima nepovoljnih ekonomskih uvjeta na način da im se pruža socijalna zaštita u obliku naknada za nezaposlenost te kroz aktivne politike tržišta rada (ALMP) razvijene za poboljšanje vještina, kao i osiguravanje poštenih plaća i primjerenih radnih uvjeta. Istodobno, zakonodavstvo u području zaštite zaposlenja (EPL) trebalo bi osigurati dovoljno

fleksibilne planove zapošljavanja kako bi poslodavci mogli prilagoditi plaće i zaposlenost u slučaju nepovoljnih ekonomskih šokova. Previše zaštitni EPL sprječava tvrtke da prilagode svoje troškove rada, što rezultira većom stopom neplaćanja, produljenim ekonomskim oporavkom i još većom stopom nezaposlenosti. (Fadejeva, 2019)

Ključno je pitanje na koji način se država treba interferirati u aktivnosti na tržištu rada kako bi postigla ravnotežu između ekonomske učinkovitosti i socijalne sigurnosti. (Južnik Rotar & Krsnik, 2020: 2)

Da bi poboljšali funkcioniranje tržišta rada, kreatori politika trebaju riješiti neusklađenost tržišta rada, segmentaciju tržišta rada i osmisliti politike zapošljavanja usmjerene na integraciju određenih skupina na tržište rada. Aktivne politike tržišta rada javne su intervencije koje su izričito usmjerene na skupine osoba s poteškoćama na tržištu rada. Te politike uključuju javne službe za zapošljavanje ili druge javno financirane usluge za osobe koje traže posao. Aktivna podrška zapošljavanju uključena je u Europski stup socijalnih prava (Eurofound, 2021) te podrazumijeva:

- povećavanje motivacije i poticaja za traženje zaposlenja
- poboljšanje spremnosti za posao i pomoć u pronalaženju odgovarajućeg posla
- širenje mogućnosti zapošljavanja.

Provedbom ovih ključnih elemenata treba upravljati učinkovito i dobro koordinirati tržište rada te socijalne institucije i politike. Stalno praćenje i procjena utjecaja politika i programa neophodni su za jačanje učinkovitosti i uspješnosti politika u odgovoru na potrebe različitih skupina. OECD provodi niz aktivnosti kako bi pomogao zemljama ojačati politike tržišta rada i omogućiti kvalitetno zapošljavanje osobama koje traže posao te drugim skupinama izvan radne snage. (OECD, 2021_a)

Standardna klasifikacija politika tržišta rada koju slijede OECD i/Eurostat razlikuje takozvane "aktivne" mjere (npr. pomoć u traženju posla, osposobljavanje, otvaranje novih radnih mjesta u javnom sektoru i subvencionirano zapošljavanje u privatnom sektoru) i "pasivne" mjere (osiguranje za slučaj nezaposlenosti i pripadajuće socijalne naknade koje se isplaćuju nezaposlenima). Te su aktivne i pasivne mjere u središtu svake „strategije uključivanja“. (Martin, 2015: 3)

Politike tržišta rada obuhvaćaju niz financijskih i praktičnih intervencija koje mogu pomoći ljudima kada se suoče s poteškoćama na tržištu rada. Cilj im je zaposliti nezaposlene i neaktivne osobe i pomoći ljudima na nekvalitetnim ili nesigurnim poslovima kako bi pronašli bolje mogućnosti zapošljavanja.

Politike tržišta rada raznolike su i uključuju mehanizme traženja posla, obuku, poticaje za osnivanje poduzeća i socijalnu pomoć (naknade za nezaposlenost). Skup ovih politika svrstava se u jednu skupinu kao "aktivne mjere" ili politike uključivanja na tržište rada i podrazumijevaju obuku, poticaje za zapošljavanje, potpomognuto zapošljavanje, rehabilitaciju i izravno otvaranje novih radnih mjesta. (European Commission, 2015)

Javni izdaci na aktivne politike tržišta rada prikazani su u narednom grafikonu (grafikon 2.) te se značajno razlikuju u odabranim državama članicama.

(podaci prikazani u % od BDP-a)

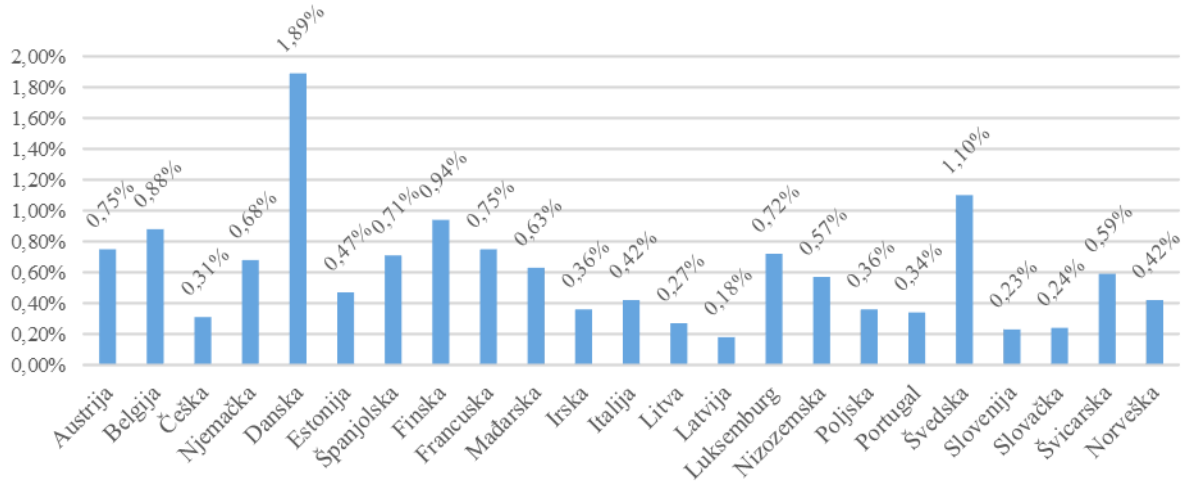

Grafikon 2. Javni izdaci za aktivne politike tržišta rada u 2018. godina za odabrane zemlje
Izvor: izrada autorice prema podacima iz OECD.Stat (2021c).

Na grafikonu 2., na kojem su prikazani javni izdaci kao postotak od BDP-a, može se vidjeti da najveće javne izdatke za aktivne politike tržišta rada izdvajaju skandinavske zemlje (Danska 1,89 %, Švedska 1,1 % te Finska 0,94 %).

Budući da je krajnji cilj aktivnih politika smanjiti ukupnu nezaposlenost i/ili povećati zaradu, očiti pristup procjeni njihove učinkovitosti je nastojanje uspostavljanja robusnih ekonometrijskih odnosa između ključnih makroekonomskih agregata kao što su nezaposlenost ili stvarne plaće i raznih mjera kroz izdatke za aktivne politike tržišta rada. (Martin, 2000: 89)

Cilj strategija aktivne politike tržišta rada je potaknuti nezaposlene na aktivniju potragu za poslom i održavanje većeg kontakta s tržištem rada. Takve se strategije kreću od pokušaja pružanja učinkovitije pomoći u traženju posla nezaposlenima i praćenja njihove aktivnosti traženja s jedne strane do obveze nezaposlenih u sudjelovanju u aktivnim programima ili u obrazovanju i osposobljavanju koje će im biti od koristi u budućem zaposlenju. (Martin, 2000: 103)

Krajnji cilj mjera ALMP-a je povećati mogućnosti zapošljavanja tražitelja posla ili, preciznije, povećati njihove izglede za pronalaženje i zadržavanje plaćenog zaposlenja ili povećati njihovu sposobnost zarade u srednjem i dugom roku. To promiče mnogo širi cilj poboljšanja usklađenosti slobodnih radnih mjesta i nezaposlenih na tržištu rada.

Europska mreža javnih službi za zapošljavanje obično podržava stav da je uspješna integracija na tržište rada uvjerljiv pokazatelj pružanja dobre podrške osobama koje traže posao korištenjem različitih usluga, uključujući mjere ALMP-a. Međutim, teško je obično se složiti oko suprotnog scenarija u kojem neuspjela integracija na tržište rada može biti uzrokovana pogrešnim, nedovoljnim i/ili neadekvatnim uslugama (uključujući mjere ALMP-a). Nesumnjivo, vanjski čimbenici, poput ekonomskog razvoja i razvoja tržišta rada, zakonodavstva, političkih odluka, proračuna itd. igraju značajnu ulogu u određivanju ishoda na tržištu rada. To znači da se *a priori* može isključiti činjenica da je pozitivan ishod na tržištu rada mogao izostati, čak i ako su usluge koje pruža PES[24] (uključujući ALMP) bile odgovarajuće i primjerene. Ovdje se može postaviti pitanje: što predstavlja odgovarajuću i adekvatnu uslugu i što karakterizira dobre mjere ALMP-a? Da bi se odgovorilo na ova pitanja, dobre ALMP mjere bi se trebale dvojako okarakterizirati. Prvo, kao mjere koje povećavaju vjerojatnost integracije na tržište rada, i drugo, kao mjere koje su visokokvalitetne u smislu njihovih rezultata za osobe koje traže posao. (European Commission, 2019: 4-5)

Na slici 3. su prikazane intervencije politika tržišta rada. LMP intervencije grupirane su u tri glavne vrste: LMP usluge, LMP mjere i LMP potpore, a zatim su razvrstane u osam kategorija prema vrsti akcije.

[24] PES – javne službe za zapošljavanje (engl. *public employment services*)

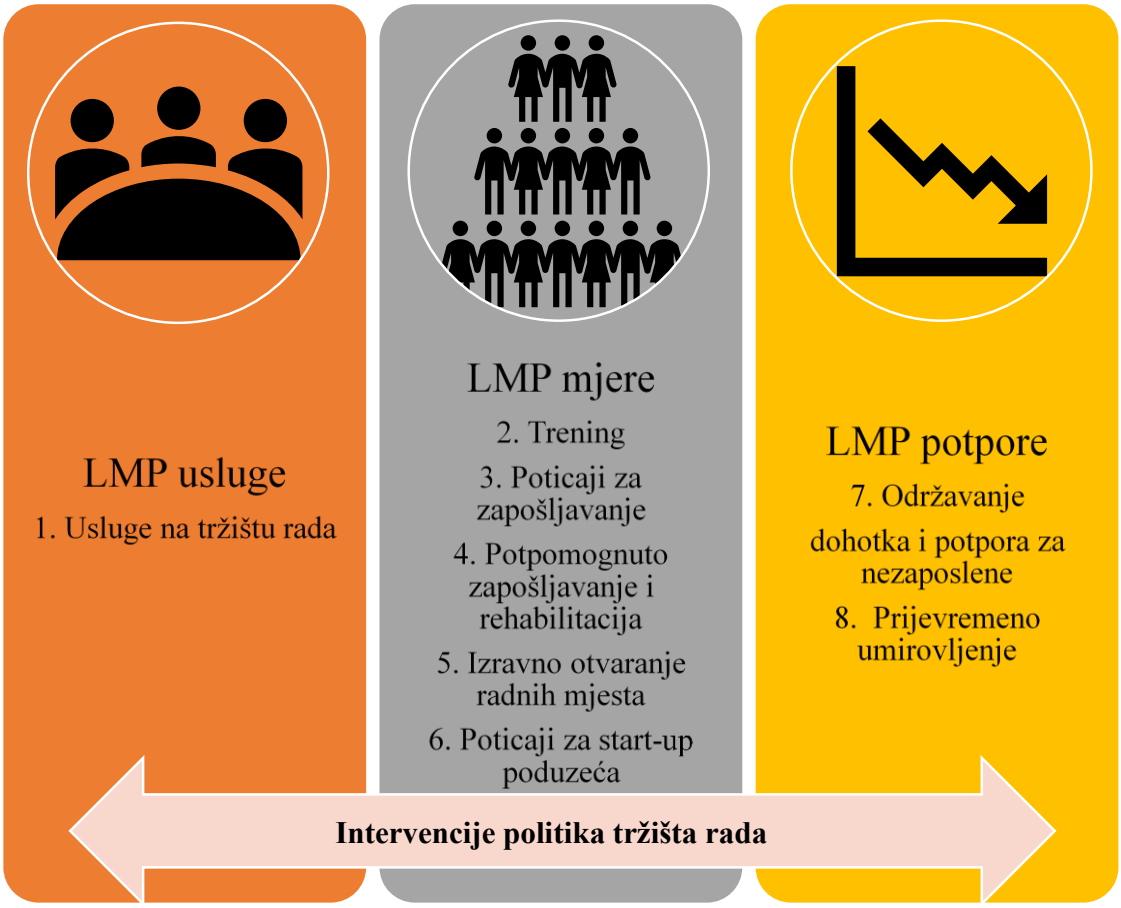

Slika 3. Intervencije politika tržišta rada
Izvor: izrada autorice prema podacima sa Eurostat-a (2018).

Usluge i mjere LMP-a okarakterizirane su kao aktivne politike tržišta rada (ALMP), a financijska potpora kao pasivna politika tržišta rada. Usluge se odnose na intervencije na tržištu rada gdje su glavne aktivnost sudionika povezane s traženjem posla, dok se mjere odnose na aktivnosti koje predstavljaju puno radno vrijeme ili značajnu honorarnu aktivnost sudionika tijekom određenog vremenskog razdoblja s ciljem poboljšanja strukovnih kvalifikacija sudionika ili intervencija u vidu poticaja za poduzimanje akcija ili osiguravanje radnog mjesta (uključujući samozapošljavanje). U suštini, ALMP se smatra sredstvom za borbu protiv cikličke i strukturne nezaposlenosti i promicanja zapošljavanja. (Eichhorst & Konle-Seidl, 2016: 7)
Europska komisija u poglavlju aktivnih mjera tržišta rada (2017: 12) ističe nekoliko instrumenata koji služe pri anticipativnom djelovanju na rizike dugotrajne nezaposlenosti. U tom aspektu naglasak je stavljen na kombinaciju mjera aktivacije te prilagodbu institucijskih okvira gospodarskim uvjetima. Jedan od bitnijih instrumenata je zasigurno savjetovanje i pomoć pri traženju zaposlenja što uključuje niz mogućih vrsta potpore, kao što su strukovno osposobljavanje, pomoć pri traženju zaposlenja, motivacijski tečajevi te potpora društva.

Jednako značajni te u nekim slučajevima neophodni instrumenti u sklopu aktivnih mjera su subvencije poslodavcima, programi izravnog zapošljavanja i osposobljavanje koje nerijetko ima najveće pozitivne dugoročne učinke, ali je skupo.

Javne službe za zapošljavanje, kako navodi Europska komisija (2017: 13), imaju ključnu ulogu u ponovnom uključivanju nezaposlenih na tržište rada te je za njihov rad nužan dovoljan broj članova osoblja propisno osposobljenih u područjima kojima se povećava kvaliteta usluga, kao što su diskriminacija, kvalitetna radna mjesta i postupanje u osjetljivim slučajevima. Pri tome takve službe trebaju imati dobro osmišljen sustav evaluacije i praćenja zato što nude integrirane usluge koje se mogu djelotvorno povezati s drugim državnim uslugama, posebno s onima koje se odnose na obrazovanje, zdravstvo, stanovanje i drugim socijalnim uslugama.

5.4. Zapošljavanje i socijalna uključenost

„Uredbom (EU) br. 1296/2013 Europskog parlamenta i Vijeća od 11. prosinca 2013. se uspostavio Program za zapošljavanje i socijalne inovacije Europske unije kako bi se osigurao nastavak i razvoj aktivnosti koje se provode na temelju Odluke br. 1672/2006/EZ Europskog parlamenta i Vijeća od 24. listopada 2006., Uredbe (EU) br. 492/2011 Europskog parlamenta i Vijeća, Provedbene odluke Komisije 2012/733/EU i Odluke br. 283/2010/EU Europskog parlamenta i Vijeća koja je uspostavila Europski mikrofinancijski instrument za zapošljavanje i socijalnu uključenost.“ (Službeni list Europske unije, 2013: 238)

Ciljevi programa su:

- odrediti i analizirati broj inovativnih rješenja i povećati njihove praktične primjene na području socijalne politike u cilju pružanja pomoći
- državama članicama osigurati podlogu za povećanje učinkovitosti njihovog tržišta rada te dodatno poboljšavanje njihovih politika socijalne zaštite i uključenosti.

U vodećim inicijativama strategije Europa 2020., Europskoj platformi protiv siromaštva i socijalne isključenosti i Uniji inovacija, socijalne su inovacije efikasne za suočavanje s društvenim izazovima koji nastaju zbog starenja stanovništva, siromaštva, nezaposlenosti, novih obrazaca rada i životnih stilova te očekivanja državljana u pogledu socijalne pravde, obrazovanja i zdravstva. Programom se također djeluje u smjeru poboljšanja socijalnih inovacija kao odgovora na nedovoljno zadovoljene socijalne potrebe na području borbe protiv siromaštva i socijalne isključenosti u smislu promicanja visoke razine kvalitetnog i održivog zapošljavanja, jamčenja primjerene socijalne zaštite koja djeluje protiv siromaštva, poboljšanja

radnih uvjeta i pristupa ranjivih skupina osposobljavanju, uzimajući u obzir ulogu regionalnih i lokalnih tijela.

Napredak prema socijalno i okolišno održivom razvoju u Europi zahtijeva predviđanje i razvoj novih vještina i sposobnosti koje vode do poboljšanja uvjeta za stvaranje radnih mjesta, kvalitete zapošljavanja i radnih uvjeta kroz popratno obrazovanje, tržište rada i socijalnih politika u vezi s promjenom industrije i usluga. Program stoga doprinosi promicanju stvaranja kvalitetnih i održivih „zelenih" i „bijelih" radnih mjesta kao i onih u sektoru informacijskih tehnologija. (Službeni list Europske unije, 2013: 239)

Zelena radna mjesta, odnosno „zeleni ovratnici odnose se na radnike koji obavljaju zelene poslove. Oni obuhvaćaju veoma različit spektar poslova. Program Ujedinjenih naroda za okoliš u te poslove ubraja rad u poljoprivredi, istraživanje i razvoj, administrativne i uslužne djelatnosti koje doprinose unaprjeđenju kvalitete okoliša." (UN Global Compact, 2016 navedeno u Bušelić: 2017: 98)

Opća definicija bijelog ovratnika podrazumijeva osobu koja radi u uredu za uredskim stolom te nema doticaja s fizičkim radom. Pojam bijeli ovratnik prvi je put primijenjen u kontekstu osoba koje su obavljale administrativne poslove. Međutim, pojam bijeli ovratnik je postupno proširen kako bi uključio svakoga u uredskom okruženju čiji posao zahtijeva administrativne ili menadžerske dužnosti. Pandemija koronavirusa donijela je pojmu bijeli ovratnik novu konotaciju. Kako su zemlje provodile politiku ostanka kod kuće, mnogi su ljudi morali raditi svoj posao na daljinu. Radniku bijelog ovratnika je ovaj zadatak bio relativno lak – njihov se posao općenito može obaviti na daljinu jer nije specifičan za mjesto.

Obrazovanje ima značajan utjecaj na zapošljavanje. (OECD, 2012: 30) Obrazovanje je važno, kako za sadašnjost, pružajući pojedincima znanja i vještine kroz koje u potpunosti i učinkovito mogu sudjelovati u društvu, tako i za budućnost jer pomaže u širenju znanstvenih i kulturnih saznanja. Razina do koje su se odrasli obrazovali često se koristi kao pokazatelj razine ljudskog kapitala - vještina dostupnih stanovništvu i radnoj snazi. (OECD, 2012: 12)

U narednim tablicama (tablica 9., 10. i 11.) dan je prikaz stope zaposlenosti prema stupnju obrazovanja (nisko, srednje i visoko obrazovanje) od 2008. do 2018. godine u zemljama Europske unije.

Tablica 9. Stopa zaposlenosti osoba s niskim stupnjem obrazovanja (20 - 64 godine) u zemljama EU-a od 2008. do 2018. godine

(podaci prikazani u *%)*

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	$\bar{x}$
Austrija	55,7	54	54,9	55,3	54,7	53,9	53,1	53,1	53,9	53,9	55,6	**54,4**
Belgija	49,1	47,7	48,4	47,3	47,1	46,8	46,6	45,6	45,6	45,9	45,6	**46,9**
Bugarska	46,5	45	39,8	36,7	36,2	36,9	38,6	39	39,2	44,4	46,2	**40,8**
Cipar	64,1	64,9	66,8	65,1	57,8	54,9	54,6	55,1	56,8	57	61,6	**59,9**
Češka	44,8	42,5	41,6	40,4	38,6	40,4	41,6	40,2	43,7	49,2	50,9	**43,1**
Danska	67	63,9	61,1	60,5	58,6	57,9	58,2	57,6	59,7	59,4	59,4	**60,3**
Estonija	58,6	47	44,2	48,4	49,4	56,9	59,4	57,7	61,8	65,7	65,7	**55,9**
Finska	58,8	55,8	53,9	54,1	53,9	52,2	51,7	50,8	52	51,3	52,9	**53,4**
Francuska	57	55,6	55	55,2	54,9	53,6	52,5	51,4	50,5	51,9	52,2	**53,6**
Grčka	60,4	59,8	57,8	53,5	48	45,8	46,5	48,1	48,1	49,2	49,9	**51,6**
Hrvatska	47,6	48,3	46,2	43,3	40,7	38,5	37,8	39,3	37,9	34,7	37,2	**41**
Irska	56,7	50	46,8	44,6	43	46	46,5	48,8	49,6	50,5	51,5	**48,5**
Italija	52,1	50,7	49,9	50,1	50	48,8	48,7	49,4	50,3	51	51,7	**50,2**
Latvija	57	45,8	45,1	46,7	50,3	49	50	53,2	54,8	56,7	57,5	**51,5**
Litva	42,1	36,2	29,6	31,8	35,2	37,1	42	42,7	42,3	44,1	46,9	**39,1**
Luksemburg	59,8	58,9	58,5	58,6	60,1	58,6	57,3	58,4	56,4	56,4	58,9	**58,4**
Mađarska	37,6	35,9	36,1	36,2	36,9	38,1	44,3	47,1	50,7	53,9	55,7	**43**
Malta	49,5	48,3	48,9	50,2	51,2	53	54,6	55,9	58,1	59,2	62,2	**53,7**
Nizozemska	62,7	62,3	61,1	62	61,9	60,3	58,7	59,8	60,7	61,2	62,6	**61,2**
Njemačka	55,9	55,7	56,1	57,4	57,8	58,3	58	58,5	58,9	59,6	60,7	**57,9**
Poljska	42,3	41	39,2	38,7	38,9	37,6	38,2	39,8	39,5	40,8	42	**39,8**
Portugal	71,6	68,6	67,6	65,2	62,2	60,8	62,2	63,5	64,7	67,7	69,6	**65,8**
Rumunjska	53,6	53,7	55,3	51,4	53,1	53,6	55	53,3	52,3	54,7	55,2	**53,7**
Slovačka	31	29	28,6	29,6	29,5	30,3	31,6	33,2	35,9	37,3	36,4	**32**
Slovenija	54,8	53,2	50,5	45,8	46,4	44,6	47,4	48	45,5	49,3	50,8	**48,8**
Španjolska	59,4	53,7	52,5	51,5	48,3	47,2	48,2	50,6	52,9	54,6	56,6	**52,3**
Švedska	66,2	63,3	62,8	63,7	62,9	61	61	60,9	61	61,8	62,3	**62,4**
Ujedinjeno Kraljevstvo	59	57,2	55,5	55,6	56,4	56,8	58,8	59,7	62,1	63,6	65,1	**59,1**
$\bar{x}$	54,3	51,7	50,5	50,0	49,4	49,2	50,1	50,7	51,6	53,0	54,4	

Izvor: izrada autorice prema podacima sa Eurostata. (2020d).

Prema Međunarodnoj standardnoj klasifikaciji obrazovanja (ISCED 2011) osobe s niskim stupnjem obrazovanja su definirane kao one koje imaju manji od osnovnoškolskog, odnosno osnovnoškolski i niži srednjoškolski stupanj obrazovanja (ISCED 0, 1 ili 2).

Iz tablice 9. je vidljivo kako je stopa zaposlenosti osoba s prethodno navedenim stupnjem obrazovanja u 2018. godini u prosjeku 55,8 %, što je 0,3 postotna boda manje nego u 2008. godini (56,1 %). Najmanja stopa zaposlenosti osoba s niskim stupnjem obrazovanja je u sljedećim državama: Slovačka, Hrvatska i Poljska. Ako se promotre prosječne vrijednosti stope zaposlenosti osoba s niskim stupnjem obrazovanja po državama, najvišu stopu imaju Portugal (65,8 %) i Švedska (62,4 %).

Tablica 10. Stopa zaposlenosti osoba s srednjim stupnjem obrazovanja (20 - 64 godine) u zemljama EU od 2008. do 2018. godine

(podaci prikazani u %)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	$\bar{x}$
Austrija	76,1	75,6	76,1	76,1	76,2	76,7	75,1	74,9	75,1	75,7	76,6	**75,8**
Belgija	70,1	68,8	69,1	68,9	68,5	68,6	67,2	67,2	67,7	67,8	69	**68,4**
Bugarska	74,2	71,6	66,7	64,8	64,5	64,7	66,3	68,3	68,9	72,8	73,9	**68,8**
Cipar	76,1	74,3	73,2	71	68,7	64,6	64,6	64,2	64,8	68,5	71,6	**69,2**
Češka	73,6	72	71,2	71,7	72,5	73,1	74,2	76	77,9	79,4	80,7	**74,8**
Danska	80,7	77,4	76,8	76,7	76	76,3	76,3	77,4	77,6	78,6	79,6	**77,6**
Estonija	76,5	67,7	64,6	70	70,8	70,7	71,9	74,8	74,7	76,8	78,2	**72,4**
Finska	75,4	72,4	71,7	72,5	72,6	71,5	71	70,4	70,9	71,4	73,4	**72,1**
Francuska	72,6	71,5	71	70,2	69,9	69,5	68,9	69,3	69,6	69,7	70,3	**70,2**
Grčka	63,3	62,4	60,6	56,3	51,4	48,7	49,2	51,1	52,5	54,1	55,5	**55**
Hrvatska	66,5	65	62,6	60,7	58,3	57,2	58,5	59,8	61,1	64,1	65,1	**61,7**
Irska	74,8	67,8	63,9	62,2	62,3	63,3	65	66,2	68,8	69,6	71,3	**66,8**
Italija	69,2	67,8	67,1	66,4	65,5	63,9	64	64,2	65,1	65,4	65,7	**65,8**
Latvija	75,5	65,2	61,8	63,3	63,8	66,4	68,4	69,4	69,1	71,1	73,3	**67,9**
Litva	69,6	63	58,8	61	62,8	64	65,6	67,2	68,5	69,7	71,9	**65,6**
Luksemburg	66,4	66,6	67,3	65,5	66,7	66,2	67,1	67	65,9	68,3	68,1	**66,8**
Mađarska	64,1	62,3	61,8	61,9	63,1	64,5	67,8	69,9	72,5	74,2	74,9	**67**
Malta	75,3	75,5	75,6	73,6	76,8	77,8	78,6	78,1	79,1	80,5	81,4	**77,5**
Nizozemska	79,6	79,6	78,7	78,5	78,3	76,8	76,6	77,2	78	78,8	79,7	**78,3**

Njemačka	74,2	74,1	74,9	76,3	76,8	77,3	78,1	78,4	79,3	80	80,7	**77,3**
Poljska	64,1	63,6	62,7	62,9	62,6	62,4	63,7	64,7	66,3	67,6	68,7	**64,5**
Portugal	69,9	70,1	69,8	69,8	67	67,2	69,2	70,6	72	74,9	76,3	**70,6**
Rumunjska	64,5	63,3	64,8	64,5	65,1	64,6	66,2	66	66,2	68,7	69,9	**65,8**
Slovačka	71	67,9	65,9	66,2	66,5	66,4	67,6	69,3	71,5	73	74,5	**69,1**
Slovenija	73,3	71,2	69,7	67,4	67,1	65,8	66	66,9	68,3	71,5	73,7	**69,2**
Španjolska	70,6	65,7	64	62,3	60,1	58,3	59,1	60,8	62,3	63,4	64,3	**62,8**
Švedska	82	79,3	78,9	80,4	80,4	81	80,9	81,4	82,1	83	83,4	**81,2**
Ujedinjeno Kraljevstvo	77,8	75,6	75	75,6	75,2	75,6	76,9	77,3	77,7	78,1	78,2	**76,6**
$\bar{x}$	**72,4**	**69,9**	**68,7**	**68,5**	**68,2**	**68,0**	**68,7**	**69,6**	**70,5**	**72,0**	**73,2**	

Izvor: izrada autorice prema podacima sa Eurostata. (2020d).

Osobe sa srednjim stupnjem obrazovanja prema Međunarodnoj standardnoj klasifikaciji obrazovanja (ISCED 2011) su definirane kao one koje imaju više srednjoškolsko obrazovanje i obrazovanje nakon srednjoškolskog koje nije ni više niti visoko obrazovanje (ISCED 3 i 4). Iz tablice 10. je vidljivo kako je stopa zaposlenosti osoba sa srednjim stupnjem obrazovanja u 2018. godini u prosjeku 74,1 %, što je 18,3 postotna boda više nego stopa zaposlenosti osoba s niskim stupnjem obrazovanja u 2018. godini (tablica 9.). Najmanja stopa zaposlenosti osoba sa srednjim stupnjem obrazovanja je u sljedećim državama: Grčka, Španjolska i Hrvatska. Ako se promotre prosječne vrijednosti stope zaposlenosti osoba sa srednjim stupnjem obrazovanja po državama, najvišu stopu imaju Švedska (81,2 %) i Nizozemska (78,3 %).

Tablica 11. Stopa zaposlenosti osoba s visokim stupnjem obrazovanja (20 - 64 godine) u zemljama EU od 2008. do 2018. godine

(podaci prikazani u %)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	$\bar{x}$
Austrija	85,3	85,2	84,6	85,3	86,2	85,3	83,6	83,5	84,3	84,8	84,7	**84,8**
Belgija	83	81,9	81,9	82	81,8	81	82	81,8	82,2	82,2	83,5	**82,1**
Bugarska	86,1	85,5	82,7	81,2	81,1	80,7	81,7	84	84,2	85,5	86,1	**83,5**
Cipar	86,5	84,5	82,7	81,2	78,8	76,3	77,3	78,3	78,3	79,1	80,8	**80,3**
Češka	83,2	82	81	81,1	81,2	82,5	82,2	82,6	83,4	84,2	85,6	**82,6**
Danska	87,8	85,9	84,9	85,1	85,3	85,4	84,9	85,2	85	85,5	86,1	**85,6**
Estonija	85,3	81,9	78,4	79,1	81,4	82,2	83,2	85,2	84	85,5	85,2	**82,9**

Finska	85,6	84,4	84	84,3	84,2	83,8	83,3	82,9	82,9	84,4	86,2	**84,2**
Francuska	81,4	80,7	80,9	81	81,4	81,3	81,1	81,5	82,4	82,9	82,8	**81,6**
Grčka	82	81,5	78,8	74	70,3	68,2	67,6	67,9	69,6	70,8	73,3	**73,1**
Hrvatska	83,1	82,2	80,2	77,4	76,5	75,7	78,4	78,7	79,7	81,5	81,5	**79,5**
Irska	85,4	81,7	80,3	80,1	79,8	80,3	80,5	81,9	82,6	84,2	84,7	**82**
Italija	78,5	77,1	76,5	77,1	76,7	75,9	75,5	76,3	77,5	78,2	78,7	**77,1**
Latvija	87	82,7	80,1	83,4	85,3	84,2	83,4	85,1	86,5	86,9	88,9	**84,9**
Litva	87,6	85,7	85,3	87,2	87	87,6	88,4	88,7	90,4	90,1	90,6	**88,1**
Luksemburg	83,6	83,8	83,8	83,7	83,6	82,9	83	83,3	83,8	83,9	83,7	**83,6**
Mađarska	79,2	77,9	77,5	78,5	78,5	78,8	80,8	82,1	84,4	84,3	85,1	**80,6**
Malta	86	83,8	83,6	86,2	86,8	88,2	87,6	88,1	89	90,5	90,7	**87,3**
Nizozemska	86,6	86,4	86,1	86,3	86,7	87	86,8	87,5	87,5	87,9	88,6	**87**
Njemačka	85,7	86,3	86,8	87,8	87,7	87,6	87,7	87,8	87,9	88,1	88,5	**87,4**
Poljska	83,7	83,7	82,5	82,2	82,1	82,3	83,9	85	85,8	86,8	87,6	**84,1**
Portugal	84,6	84,1	82,8	81	78,7	76,9	79,4	80,4	81,8	83,6	85,5	**81,7**
Rumunjska	85,7	84,1	83,4	83,1	82,5	82,6	82,5	85,3	86,2	87,9	88,4	**84,7**
Slovačka	83,8	80,3	78	76,7	74,8	74,7	75,6	76,5	77,3	78,5	79,3	**77,8**
Slovenija	87,5	88,1	86,6	85,5	84,2	82,4	82	83,1	84	86,2	88	**85,2**
Španjolska	82	79,3	77,9	76,9	75,2	74,1	75,4	76,7	77,9	79,4	80,1	**77,7**
Švedska	87,7	86,6	86,3	86,9	87	87,3	87,4	87,7	88,1	88,1	88,6	**87,4**
Ujedinjeno Kraljevstvo	85,4	84,4	84,1	82,7	83,2	83,9	84,4	84,8	85	85,1	85,4	**84,4**
$\bar{x}$	**84,6**	**83,3**	**82,2**	**82,0**	**81,7**	**81,4**	**81,8**	**82,6**	**83,3**	**84,1**	**84,9**	

Izvor: izrada autorice prema podacima sa Eurostata (2020_d).

Prema Međunarodnoj standardnoj klasifikaciji obrazovanja (ISCED 2011), osobe s visokim stupnjem obrazovanja su definirane kao one koje imaju više i visoko obrazovanje (ISCED 5, 6, 7 ili 8), odnosno kraće više i visoko obrazovanje (ISCED 5); dodiplomski studij ili jednakovrijedni stupanj obrazovanja (ISCED 6); magisterij ili jednakovrijedni stupanj obrazovanja (ISCED 7); doktorat ili jednakovrijedni stupanj obrazovanja (ISCED 8).

Iz tablice 11. je vidljivo kako je stopa zaposlenosti osoba s visokim stupnjem obrazovanja u 2018. godini u prosjeku 84,9 %, što je 11,7 postotna boda više nego stopa zaposlenosti osoba sa srednjim stupnjem obrazovanja u 2018. godini (tablica 10.), a čak 30,5 postotna boda više nego stopa zaposlenosti osoba s niskim stupnjem obrazovanja u 2018. godini (tablica 9.). Najviša stopa zaposlenosti osoba s visokim stupnjem obrazovanja u 2018. godini je u sljedećim

državama: Malta s 90,7 % te Litva s 90,6 %. Ako se promotre prosječne vrijednosti stopa zaposlenosti osoba s visokim stupnjem obrazovanja po državama od 2008. do 2018. godine, najviše stope imaju Litva s 88,1 % te Njemačka i Švedska s 87,4 %.

Na idućem grafikonu prikazana je stopa zaposlenosti osoba s niskim, srednjim i visokim stupnjem obrazovanja u zemljama EU-a u 2018. godini

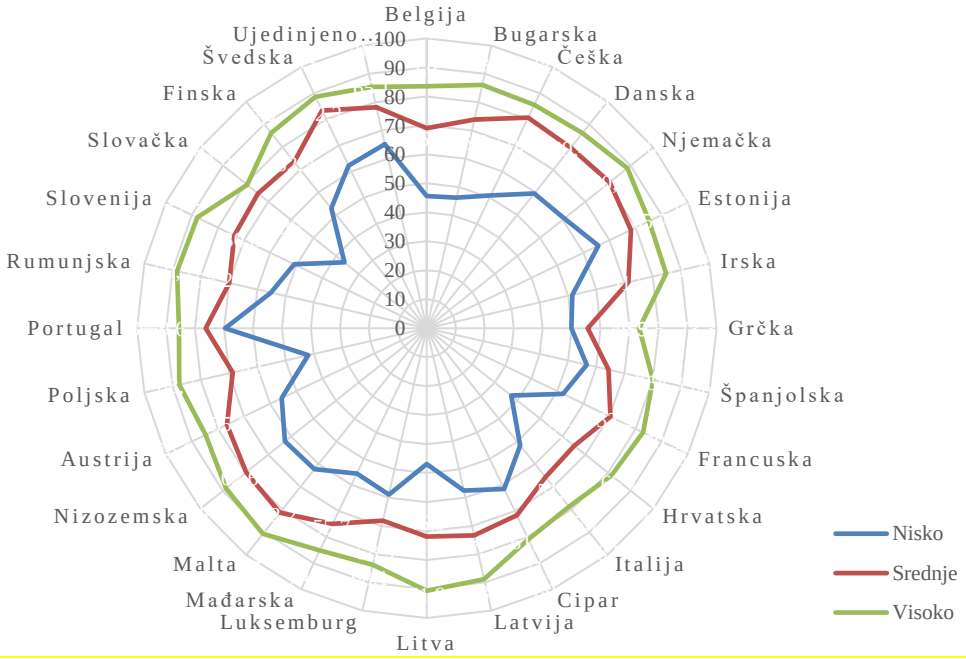

Grafikon 3. Stopa zaposlenosti osoba (20 - 64 godine) s niskim, srednjim i visokim stupnjem obrazovanja u zemljama EU-a u 2018. godini
Izvor: izrada autorice prema podacima iz tablica 8., 9. i 10. (Eurostat, 2020)

Iz grafikona 3. je vidljivo da je najviša stopa zaposlenosti osoba s niskim stupnjem obrazovanja u Portugalu (65,8 %), potom u Estoniji (65,7 %) i u Ujedinjenom Kraljevstvu (65,1 %). Ako se uzme u obzir ukupna zaposlenost po zemljama promatrana kroz stope zaposlenosti, podaci za Švedsku i Nizozemsku prikazuju korelaciju sa stopama zaposlenosti osoba sa srednjim stupnjem obrazovanja u tim državama. Naime, najviše stope zaposlenosti imaju upravo Švedska sa 77,4 % i Nizozemska sa 77,2 %. Zanimljiv podatak je vezan uz Portugal koji ima navišu stopu zaposlenosti osoba s niskim stupnjem obrazovanja, ali ako se promotri ukupna zaposlenost u toj zemlji, Portugal se nalazi na sredini niza sa stopom zaposlenosti od 69,7 %. Švedska (83,4 %) i Malta (81,4 %) imaju najveću stopu zaposlenosti osoba sa srednjim stupnjem obrazovanja. Najveća stopa zaposlenosti osoba sa visokim stupnjem obrazovanja je u Malti (90,7 %) te u Litvi (90,6 %).

Iz perspektive socijalne uključenosti, posebno je važno pratiti kretanje broja osoba s niskom razinom obrazovnog postignuća, s obzirom na ulogu i utjecaj istog na buduće životne šanse i rizik od siromaštva i socijalne isključenosti. Uz prethodno navedeno, trebalo bi voditi računa i o mjeri u kojoj je pristup obrazovanju strukturiran prema socioekonomskom statusu osobe u kontekstu poboljšanja socijalne dimenzije visokog obrazovanja i utvrđivanja čimbenika koji doprinose slabijem uključivanju osoba s nižim socioekonomskom statusom u visoko obrazovanje. (Atkinson i suautori, 2002: 131-134)

Zapošljavanje nije samo važno zbog potencijalnog doprinosa smanjenju siromaštva. Sudjelovanje na tržištu rada važno je sredstvo socijalne integracije: u individualiziranom društvu nedostatak posla predstavlja opasnost od socijalne isključenosti i odvojenosti od prevladavajućeg životnog stila i kulture u društvu. Stoga je jasno zašto je „socijalna uključenost jedan je od deklariranih ciljeva Europske unije (EU).“ (Atkinson i suautori, 2005: 17)

Prema tradicionalnoj sociološkoj teoriji, temelji socijalne kohezije sastoje se u uzajamnoj međuovisnosti koja se stvara radom. Kako rad podrazumijeva suradnju s drugima i za druge, radom osoba postaje svjesna međusobne ovisnosti u tom vidu te postaje uključena u šire i apstraktnije društvene odnose, pri čemu se postavljaju temelji socijalne kohezije i solidarnosti. (Atkinson i suautori, 2002: 137-138)

Inkluzija implicira visoku razinu socijalne kohezije te utječe ne samo na pristup pojedinca institucijama (što bi podrazumijevalo „promicanje inkluzivne ekonomije“), već i na uvjerenja i stavove pojedinca u vezi s pristupom institucijama i očekivanim povratom (kroz optimizam ili pesimizam) ulaganja u socijalni kapital. Stoga se inkluzija može konceptualizirati na dva načina: prvo, inkluzija utječe na nečija uvjerenja (i opažene poticaje) u vezi s uspjehom investicija i socijalnog kapitala. Drugo, uključivanje utječe na ograničenja i resurse s kojima se pojedinac suočava u odlučivanju utječući na uvjerenja u vezi s pristupom institucijama (npr. financijskim, obrazovnim itd.). Kao takva, inkluzija utječe na način na koji pojedinci percipiraju prinos od ulaganja u različite oblike kapitala (npr. ljudski i socijalni). U inkluzivnoj ekonomiji pojedinci imaju bolje poticaje za ulaganje u socijalni kapital, zauzvrat podižući zalihe socijalnog kapitala i razinu socijalne kohezije. S druge strane, u ekonomijama koje su u manjoj mjeri inkluzivne, što se očituje, među inim, u nejednakim mogućnostima pristupa tržištu te socijalnoj zaštiti, postoje nedostatni poticaji za ulaganje u socijalni kapital. To rezultira niskim zalihama socijalnog kapitala, a time i niskom razinom socijalne kohezije (Oxoby, 2009: 1137-1138)

Integracija je ostala glavna komponenta sociološke analize, a socijalizacija je posebno identificirana kao proces kroz koji ljudi stječu stavove, vrijednosti i uloge koji im omogućuju

funkcioniranje u društvu. Osoba koja djeluje predmet je društvene kvalitete s obzirom na četiri komponente – četverokuta koji je ujedno i polje djelovanja. Drugim riječima, svaka je komponenta međusobno logično povezana i istodobno ima središnji fokus koji ih čini međusobno isključivima. Društvene uloge ili odnosi bitni su za djelovanje pojedinaca u obliku samorealizacije ili stvaranja kolektivnih identiteta. (Walker, Wigfield, 2004: 9)

U modelu socijalne kvalitete, socijalna kohezija odnosi se na strukturu ili izgradnju društvenih odnosa, dok je fokus socijalne uključenosti na pristupu i razini integracije u tim odnosima.

Beck, van der Maesen i Walker (2001: 346) sugeriraju da se socijalna kohezija odnosi na socijalnu integraciju u Lockwoodovom modelu, dok se socijalna uključenost odnosi na odnose između aktera i sustava ili podsustava, kao što je prikazano na slici 4.

Slika 4. Socijalna kohezija i socijalna uključenost
Izvor: izrada autorice prema Walker, Wigfield, 2004: 10 navedeno u Beck, van der Maesen and Walker, 2001: 346)

Koncept politike socijalne uključenosti se može sažeti kako slijedi:

- zajamčen pristup svim osnovnim resursima, pravima i socijalnim uslugama potrebnim za sudjelovanje u društvu i promicanje sudjelovanja na tržištu rada
- uključivanje u proces politike svih relevantnih aktera i razina vlasti
- borba protiv ekstremnih oblika isključenja i isključenja najmarginaliziranijih ljudi i grupa. (Barca, 2009: 6)

Kada se navodi termin socijalna isključenost, treba istaknuti kako osobe s invaliditetom spadaju u skupinu koja je u najnepovoljnijem položaju u EU-u. Na sljedećem grafikonu prikazan je jaz u zaposlenosti osoba s invaliditetom prema spolu, dobi i obrazovanju u Europskoj uniji u 2011. i 2016. godini.

(podaci prikazani kao postotna razlika u stopi zaposlenosti ljudi s invaliditetom i bez invaliditeta)

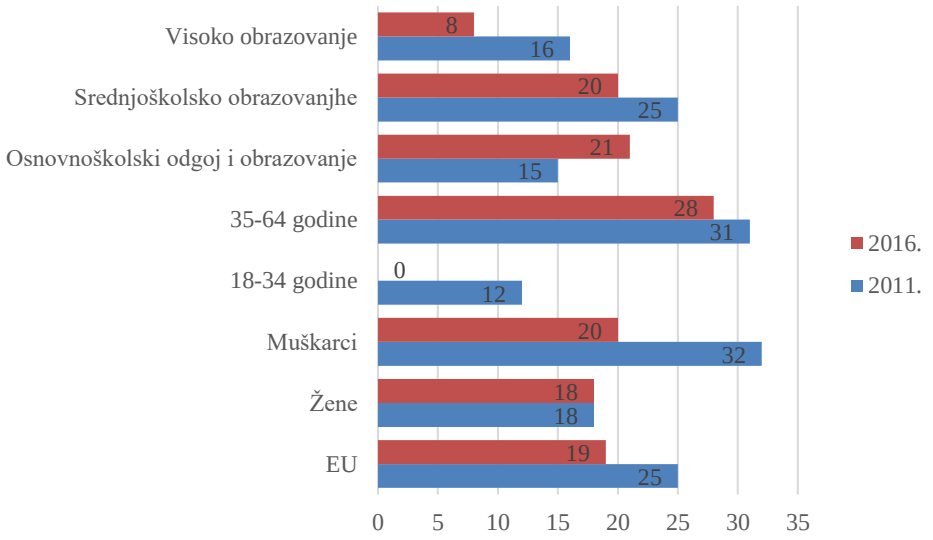

Grafikon 4. Jaz u zaposlenosti osoba s invaliditetom prema spolu, dobi i obrazovanju u Europskoj uniji u 2011. i 2016. godini.
Izvor: izrada autorice prema Eurofoundu (2018: 6)

Jaz u zaposlenosti osoba s invaliditetom, koja se odnosi na postotnu razliku u stopi zaposlenosti ljudi s invaliditetom i bez invaliditeta, smanjio se (grafikon 4). Najveće poboljšanje vidljivo je u dobnoj skupini od 18 do 34 godine, gdje jaz u zaposlenosti s invaliditetom više ne postoji, a zabilježen je i veliki pad među muškom populacijom. Istodobno, grafikon 4. pokazuje rastuću razliku u EU-u između osoba s invaliditetom koje imaju različito obrazovanje. Iako se jaz u zapošljavanju prepolovio među ljudima koji su završili visoko obrazovanje, povećao se za 6 postotnih bodova među onima koji imaju samo osnovno obrazovanje. (Eurofound, 2018: 7)

Europska komisija koristi koncepte socijalne uključenosti i socijalne isključenosti kao suprotnosti. Razvijanjem mjera politike za jačanje socijalne uključenosti europskih građana, Komisija želi pokušati smanjiti socijalnu isključenost i iskorijeniti siromaštvo. Da bi postigla te ciljeve, Komisija je utvrdila ozbiljne čimbenike rizika koji povećavaju opasnost od siromaštva. Spomenuti su: dugotrajna nezaposlenost; dugoročno življenje s malim primanjima; nekvalitetno zapošljavanje; loše kvalifikacije i rano napuštanje škole; odrastanje u obitelji

ranjivoj na socijalnu isključenost; invaliditet; loše zdravlje; zlouporaba droga i alkoholizam; život u području s višestrukim nedostacima; beskućništvo i nesigurno stanovanje; imigracija; etničko podrijetlo i rizik od rasne diskriminacije. (Walker, Wigfield, 2004: 20)

Skupina kojoj bi se također trebala posvetiti pažnja u aspektu socijalnog uključivanja je - mlade osobe koje nisu niti zaposlene, niti u obrazovnom procesu ili osposobljavanju (od 15-24 godine). U sljedećoj tablici prikazani su kao postotak od ukupnog stanovništva u istoj dobnoj skupini na razini Europske unije u razdoblju od 2008. do 2018. godine.

Tablica 12. Mlade osobe od 15. do 24. godine koje nisu zaposlene niti su u obrazovnom procesu ili osposobljavanju, na razini EU-27 od 2008. do 2018. godine

(podaci prikazani u %)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	$\bar{x}$
Austrija	7,4	8,2	7,4	7,3	6,8	7,3	7,7	7,5	7,7	6,5	6,8	7,3
Belgija	10,1	11,1	10,9	11,8	12,3	12,7	12,0	12,2	9,9	9,3	9,2	11
Bugarska	17,4	19,5	21,0	21,8	21,5	21,6	20,2	19,3	18,2	15,3	15,0	19,2
Cipar	9,7	9,9	11,7	14,6	16,0	18,7	17,0	15,3	16,0	16,1	13,2	14,4
Češka	6,7	8,5	8,8	8,3	8,9	9,1	8,1	7,5	7,0	6,3	5,6	7,7
Danska	5,2	6,5	6,9	7,2	7,3	6,6	6,4	7,0	6,7	7,6	7,7	6,8
Estonija	8,7	14,5	14,0	11,6	12,2	11,3	11,7	10,8	9,1	9,4	9,8	11,2
Finska	7,8	9,9	9,0	8,4	8,6	9,3	10,2	10,6	9,9	9,4	8,5	9,2
Francuska	10,5	12,7	12,7	12,3	12,5	11,2	11,2	12,0	11,9	11,4	11,1	11,8
Grčka	11,4	12,4	14,8	17,4	20,2	20,4	19,1	17,2	15,8	15,3	14,1	16,2
Hrvatska	11,6	13,4	15,7	16,2	16,6	19,6	19,3	18,1	16,9	15,4	13,6	16
Irska	13,9	18,3	19,4	19,1	19,2	16,4	15,3	14,3	12,6	10,9	10,1	15,4
Italija	16,6	17,6	19,0	19,7	21,0	22,2	22,1	21,4	19,9	20,1	19,2	19,9
Latvija	11,8	17,5	17,8	16,0	14,9	13,0	12,0	10,5	11,2	10,3	7,8	13
Litva	8,8	12,1	13,2	11,8	11,2	11,1	9,9	9,2	9,4	9,1	8,0	10,3
Luksemburg	6,2	5,8	5,1	4,7	5,9	5,0	6,3	6,2	5,4	5,9	5,3	5,6
Mađarska	11,5	13,6	12,6	13,2	14,8	15,5	13,6	11,6	11,0	11,0	10,7	12,6
Malta	8,3	9,9	9,5	10,2	10,8	9,9	10,3	10,5	8,8	8,6	7,3	9,5
Nizozemska	3,9	5,0	4,8	4,3	4,9	5,6	5,5	4,7	4,6	4,0	4,2	4,7
Njemačka	8,4	8,8	8,3	7,5	7,1	6,3	6,4	6,2	6,7	6,3	5,9	7,1
Poljska	9,0	10,1	10,8	11,5	11,8	12,2	12,0	11,0	10,5	9,5	8,7	10,6

Portugal	10,2	11,2	11,4	12,6	13,9	14,1	12,3	11,3	10,6	9,3	8,4	11,4
Rumunjska	11,6	13,9	16,6	17,5	16,8	17,0	17,0	18,1	17,4	15,2	14,5	16
Slovačka	11,1	12,5	14,1	13,8	13,8	13,7	12,8	13,7	12,3	12,1	10,2	12,7
Slovenija	6,5	7,5	7,1	7,1	9,3	9,2	9,4	9,5	8,0	6,5	6,6	7,9
Španjolska	14,3	18,1	17,8	18,2	18,6	18,6	17,1	15,6	14,6	13,3	12,4	16,2
Švedska	7,8	9,6	7,7	7,5	7,8	7,5	7,2	6,7	6,5	6,2	6,0	7,3
$\bar{x}$	9,9	11,8	12,2	12,3	12,8	12,8	12,3	11,8	11,1	10,4	9,6	

Izvor: izrada autorice prema podacima sa Eurostat-a (2020$_i$).

Mladi koji se obrazuju uključuju one osobe koje pohađaju izvanredno ili redovno obrazovanje, ali isključuju one u neformalnom obrazovanju i u obrazovnim aktivnostima vrlo kratkog trajanja. Zapošljavanje je definirano prema smjernicama OECD-a/ILO-a i obuhvaća sve osobe koje su tijekom referentnog tjedna radile najmanje jedan sat za plaću ili osobe koje nisu bile na poslu tijekom referentnog tjedna, ali su imale posao s kojeg su privremeno bile odsutne. Stoga, NEET[25] mogu biti ili nezaposlene ili neaktivne mlade osobe i koje nisu uključene u obrazovanje ili osposobljavanje. Mlade osobe koje nisu niti zaposlene, niti se obrazuju ili se školuju, riskiraju postati socijalno isključeni - pojedinci s dohotkom ispod granice siromaštva i kojima nedostaju vještine za poboljšanje njihove ekonomske situacije. (OECD, 2020$_b$)

Ako se u tablici 12. promotre prosječne vrijednosti mladih osoba od 15. do 24. godine koje nisu zaposlene niti su u obrazovnom procesu ili osposobljavanju prikazane u postotku, zabrinjavajuća je činjenica da je evidentan pad prosječnih vrijednosti nakon 2013. godine te se trend nastavlja do 2018. godine u kojoj taj postotak iznosi 9,6 %, što je za 3,2 postotna boda manje nego u 2013. godini.

„Stopa NEET-ova za mlade osobe (od 15. do 24. godine) uključena je u pregled socijalnih pokazatelja kao glavni pokazatelj i stoga je od središnje važnosti za ostvarivanje stupa socijalnih prava.“ (Europska komisija, 2017 navedeno u European Commision, 2017$_c$: 6)

Iz tablice 12. je vidljivo kako je u Italiji najveći postotak mladih osoba od 15. do 24. godine koje nisu zaposlene niti su u obrazovnom procesu ili osposobljavanju. U 2013. godini taj postotak iznosi čak 22,2 %. Zemlje koje također bilježe visoku stopu mladih osoba koje su nezaposlene i koje nisu u sustavu obrazovanja ili osposobljavanja su: Irska, Grčka, Španjolska, Hrvatska, Rumunjska i Bugarska. S druge strane, u Nizozemskoj je taj postotak najniži te u 2008. godini on iznosi 3,9 %.

[25] NEET = mlade osobe od 15. do 24. godine koje nisu zaposlene niti su u obrazovnom procesu ili osposobljavanju

Ako se u zadnjoj promatranoj godini (2018. godini) usporedi najviši (Italija 19,2 %) i najniži (Nizozemska 4,2 %) postotak mladih osoba koje su nezaposlene i koje nisu u sustavu obrazovanja ili osposobljavanja, može se uočiti razlika od čak 15 postotnih bodova, što ukazuje na potrebu aktivacije i održive integracije mladih osoba u Italiji i drugim državama članicama sa sličnim udjelima.

U mnogim državama članicama za rješavanje navedene problematike potrebno je reformirati njihove propise o tržištu rada te njihove sustave za osposobljavanje, traženje posla i obrazovanje. One jedino tako mogu očekivati znatno poboljšanje prijelaza iz škole na posao i zapošljivosti mladih osoba. (European Commision, 2017$_c$: 13)

5.5. Nezaposlenost kao socijalni rizik na tržištu rada EU-a

Za države članice EU-a karakteristične su regionalne razlike na njihovim tržištima rada, a osobito se to ogleda u regionalnim razlikama u nezaposlenosti. Te su razlike znak nedostatka fleksibilnosti unutar i između tržišta rada u pogledu nedovoljne mogućnosti prilagodbe. (Buettner, 2007: 288)

Nezaposlenost je izraz koji se odnosi na pojedince koji su dio radne snage, ali su trenutno bez odgovarajućeg posla te aktivno traže isti. Obično mjerena stopom nezaposlenosti, koja dijeli broj nezaposlenih s ukupnim brojem ljudi u radnoj snazi, nezaposlenost služi kao jedan od pokazatelja ekonomskog statusa zemlje. Uz nezaposlene, dio radne snage čine i zaposlene osobe.

Zaposlene osobe su one osobe koje su starije od 15 godina te se mogu svrstati u jednu od sljedećih kategorija:

(a) osobe koje su tijekom referentnog tjedna radile najmanje jedan sat za plaću, dobit ili dobitak

(b) osobe koje nisu bile na poslu tijekom referentnog tjedna, ali su imale posao ili posao iz kojeg su privremeno odsutne.

Ova je definicija primjenjiva na zaposlenike, samozaposlene osobe i obiteljske radnike. (European Parliament, 2021)

Nezaposlenu osobu Eurostat, prema smjernicama Međunarodne organizacije rada, definira kao osobu u dobi od 15. do 74. godine (u Italiji, Španjolskoj, Ujedinjenom Kraljevstvu, Islandu, Norveškoj: 16. do 74. godine) koja je:

- bez posla tijekom referentnog tjedna

- dostupna za početak rada u sljedeća dva tjedna (ili je već našla posao koji će početi raditi u sljedeća tri mjeseca)
- u procesu aktivnog traženja zaposlenja u nekom trenutku tijekom posljednja četiri tjedna. (Eurostat, 2010)

Kroz aktivne politike tržišta rada, EU nastoji pomoći nezaposlenim osobama da u što kraćem vremenskom periodu stupe u radni odnos.

ILO definira metode koje se mogu koristiti za pronalaženje posla, a iste mogu uključivati:

- kontaktiranje Javnog zavoda za zapošljavanje i registracija ili kontaktiranje privatne agencije u istu svrhu
- izravna prijava poslodavcima
- traženje pomoći prijatelja ili rodbine
- objava oglasa ili odgovor na oglas (u novinama)
- provjera dostupnosti poslova na radnim mjestima, oglasnim pločama farmi, tvornica, na tržnici ili drugim mjestima okupljanja
- traženje zemlje, zgrade, strojeva ili opreme za osnivanje vlastitog poduzeća
- traženje dodatnih financijskih sredstava
- podnošenje zahtjeva za dozvole i licence itd. (OECD, 2003)

5.5.1. Stope nezaposlenosti

Odnos između gospodarskog rasta i nezaposlenosti nerijetko ukazuje na postojanje korelacije između stope gospodarskog rasta i smanjenja stope nezaposlenosti. Povećanje stope rasta povećava stopu zaposlenosti ili smanjuje stopu nezaposlenosti.

Odnos između gospodarskog rasta i nezaposlenosti eksperimentalno je proučavan u ekonomskoj literaturi na temelju onoga što je poznato kao Okunov zakon, koji pokazuje kako postoji obrnuto proporcionalan odnos između promjene stope rasta (BDP) i promjene stope nezaposlenosti. Okun je uspio dokazati postojanje recipročne korelacije između nezaposlenosti i gospodarskog rasta. Zaključio je kako je smanjenje nezaposlenosti za 1 % produkt povećanja bruto domaćeg proizvoda za 2 % i obrnuto, a kada dođe do povećanja bruto domaćeg proizvoda, postignuto je povećanje zaposlenosti.

Teorijska osnova odnosa koje je Okun istraživao temelji se na činjenici da povećanje radne snage mora dovesti do proizvodnje više dobara i usluga. Okun je ustanovio da se stopa

nezaposlenosti smanjivala u godinama kada je realna stopa rasta bila visoka, dok je stopa nezaposlenosti rasla u godinama kada je realna stopa rasta bila niska ili čak negativna.
Na tragu navedenog, a na temelju procjene Soylu, Çakmak i Okura (2018) te Efriantia i sur. (2018), ističe se kako sve veći gospodarski rast u bilo kojoj zemlji donosi ogroman porast BDP-a i produktivnosti rada koji mogu biti učinkoviti za stvaranje prilika za zapošljavanje u zemlji. Chand, Tiwari i Phuyal (2017) također zagovaraju činjenicu da rastuće gospodarstvo može doprinijeti brzom rastu radne snage i da će u konačnici smanjiti stopu nezaposlenosti u zemlji.

Stopa nezaposlenosti je postotak nastao omjerom broja nezaposlenih i radne snage ukupno. To je pokazatelj koji općenito raste ili opada uslijed promjenjivih ekonomskih uvjeta, umjesto da ih predviđa. Kada je gospodarstvo u lošem stanju, a radnih mjesta malo, može se očekivati porast stope nezaposlenosti. Kad gospodarstvo raste zdravom stopom i ima relativno puno radnih mjesta, može se očekivati da će stopa nezaposlenosti pasti.
Osim stope nezaposlenosti, prema Bušelić (2014: 91-93), postoje i mjerenja stope nezaposlenosti u ekvivalentima punog radnog vremena pri čijem su izračunu pripadnici radne snage ponderirani ovisno o tome rade li ili traže zaposlenje uz puno ili skraćeno radno vrijeme, a ponderi su prosječni sati rada nepoljoprivrednih radnika ostvareni u odgovarajućoj godini. U slučaju izračunavanja stope iskorištenosti potencijalne količine rada, potrebno je u omjer staviti broj zaposlenih i radno sposobnih osoba, što se množi s omjerom efektivnog i potencijalnog radnog vremena.
Izgubljeni sati rada su omjer izgubljenih i potencijalnih radnih sati, pri čemu se izgubljeni radni sati definiraju kao ponuđeni sati rada plus radni sati izgubljeni zbog nedobrovoljnog kraćeg rada, a potencijalni radni sati su zbroj ostvarenih i izgubljenih sati. Indeks težine nezaposlenosti ukazuje na prosječan broj dana nezaposlenosti radnika tijekom godine kada bi prosječna nezaposlenost tijekom godine, mjerena kao umnožak prosječne godišnje stope nezaposlenosti i prosječnog trajanja nezaposlenosti u danima, bila raspoređena na sve osobe unutar radne snage. Mjeriti se mogu i dezagregirana stopa nezaposlenosti te ponderirana stopa nezaposlenosti koja se još naziva Perryjeva metoda. Njome se nezaposlenima i pripadnicima radne snage dodjeljuju ponderi, ovisno o spolno-dobnoj skupini, koji odražavaju razlike u prosječno ponuđenom radnom vremenu i razlike u produktivnosti među tim skupinama. Bušelić (2014: 93) navodi da se u kontekstu stope nezaposlenosti mogu mjeriti i prirodne stope nezaposlenosti te odnos stope nezaposlenosti i potencijalnog *outputa*, tzv. prethodno istaknuti Okunov zakon koji mjeri odnos stope nezaposlenosti i jaza između potencijalnog i aktualnog bruto domaćeg proizvoda. To je ujedno i prva verzija koja se naziva i »jaz« verzija. Za razliku od »jaz« verzije, Okun navodi

kako postoji i »razlika« verzija koja povezuje promjenu proizvodnje s promjenom stope nezaposlenosti. Okun je taj odnos okarakterizirao kao posljedicu poslodavca koji prilagođava razinu zaposlenosti, a kao odgovor na fluktuacije u agregatnoj potražnji. Prema Okunu, u uvjetima gdje postoji relativno stabilno sudjelovanje na tržištu rada, promjena zaposlenosti bi zauzvrat rezultirala sličnim kretanjem stope nezaposlenosti.

Veliki broj empirijskih istraživanja posvećen je upravo Okunovom zakonu. U nastavku su navedena neka od njih. Economou i Psarianos (2016: 275) su na temelju analize podataka za 13 zemalja Europske unije, od drugog tromjesečja 1993. do prvog kvartala 2014. godine došli do zaključka kako je učinak promjena proizvodnje na stope nezaposlenosti slabiji za zemlje s povećanim izdacima za zaštitu tržišta rada i postojaniji za zemlje s niskom zaštitom tržišta rada. Njihova analiza pruža dokaz da povećana zaštita tržišta rada ublažava štetne učinke smanjenja stope rasta proizvodnje na nezaposlenost. Herwartz i Niebuhr (2011) su dijagnosticirali značajne varijacije rasta nezaposlenosti među zemaljama EU-a i unutar samih zemalja. Analizom podataka dolaze do zaključka kako varijanca Okunovih koeficijenata pokazuje da razlike u rastu same po sebi ne mogu objasniti regionalne razlike u nezaposlenosti. Jednako tako, zaključuju kako postoje sustavne razlike u uspješnosti tržišta rada između urbanih i ruralnih regija u Europi.

Butkus i Seputiene (2019) primjenjuju »jaz« verziju Okunova zakona s ciljem procjene osjetljivosti stope nezaposlenosti mladih. S obzirom na ravnotežnu nezaposlenost, njihova analiza ne pokazuje da je viša stopa tipičnija za određeni spol, ali, uspoređujući ukupnu nezaposlenost, rezultati do kojih su došli ukazuju kako mladi ljudi obaju spolova imaju višu stopu nezaposlenosti, čak i kada gospodarstvo funkcionira na svojoj potencijalnoj razini.

Marconi, Beblavý i Maselli (2015) također analiziraju stopu nezaposlenosti mladih i rasta BDP-a te dolaze do zanimljivih rezultata temeljenih na analizi podataka u periodu od 2002. do 2014. za 30 zemalja (EU28, Island i Norvešku). Oni su, za razliku od Butkus i Seputiene, kategorizirali mlade te promatrali njihovu nezaposlenost u odnosu na gospodarski rast. Naime, rezultati njihove analize pokazuju kako nezaposlenost mladih (od 15. do 24. godine) nije značajno osjetljivija na gospodarski rast od nezaposlenosti u početnoj radnoj dobi (25-31 u kategoriji od 25. do 64. godine). Međutim, u usporedbi s nezaposlenošću u početnoj radnoj dobi, nezaposlenost tinejdžera (od 15 do 19 godina) relativno je malo osjetljiva, dok je nezaposlenost mladih (20-24) snažnije povezana s gospodarskim rastom.

Dixon, Lim i van Ours (2016) se osvrću na vezu Okuna između uočenih stopa nezaposlenosti i proizvodnih jazova. U odnos uključuju učinak institucija tržišta rada, kao i učinke dobi i spola. Njihova empirijska analiza temelji se na 20 zemalja OECD-a u razdoblju od 1985. do 2013.

godine. Zaključuju da je udio radnika na određeno vrijeme (koji uključuje visok i sve veći udio mladih radnika) odigrao ključnu ulogu u objašnjavanju promjena Okunovog koeficijenta (utjecaj proizvodnog jaza na stopu nezaposlenosti) tijekom vremena. Okunov koeficijent ne razlikuje se samo za mlade, osobe srednjih godina i starije radnike, već se s godinama smanjuje. Ovi rezultati se razlikuju od rezultata Marconia, Beblavýa i Masellia jer iz perspektive politike, u ovoj analizi, slijedi da povećanje gospodarskog rasta neće imati samo željeni rezultat smanjenja ukupne stope nezaposlenosti, već će imati i distribucijski učinak smanjenja nezaposlenosti mladih.

Jedna od ključnih prednosti Okunovog zakona je njegova jednostavnost u konstataciji da će se smanjenje nezaposlenosti od 1 % dogoditi kada gospodarstvo bude raslo približno 2 % brže od očekivanog. Međutim, oslanjanje na njega za konkretna predviđanja o nezaposlenosti, s obzirom na trendove gospodarskog rasta, ne funkcionira u praksi uvijek, kao što je prethodno navedeno. Da Okunov zakon u kraćim razdobljima može varirati u svojim istraživanjima potvrđuju Schnabel (2002), McKinsey (2011) te Meyer and Tasci (2012).

Mayes i Viren (2002) navode kako asimetrija u Okunovom zakonu može biti rezultat neusklađenosti između poslova i nezaposlenosti u različitim regijama i sektorima na tržištu rada. Jardin i Gaétan (2012) koriste fleksibilniji Kernel semiparametrijski pristup na panel podacima za 16 europskih zemalja te u svom istraživanju potvrđuju nelinearnost u prosječnom Okunovom zakonu svih tih zemalja.

Na promjene u Okunovom zakonu mogu utjecati ekonomsko stanje zemlje, uključujući proces smanjenja visoke stope nezaposlenosti i financijske krize, kao što je bila u 2008. godini.

Također, treba istaknuti kako postoji koincidencija koja implicira nepovezanost nezaposlenosti i ekonomskih čimbenika, a uzrok navedenome je neučinkovito i nepotpuno iskorištavanje radnih mjesta, što direktno utječe na potražnju za proizvodima. O neiskorištenim resursima još je davne 1946. pisao i Domar navodeći kako neuspjeh gospodarstva da raste potrebnom stopom stvara neiskorištene kapacitete i nezaposlenost. Domar je kroz svoja istraživanja pokušao pronaći stopu rasta kojom se gospodarstvo mora širiti kako bi ostalo u kontinuiranom stanju pune zaposlenosti. Jednak pristup ekonomici rasta imao je i Harrod (1939) koji je nastojao istražiti može li funkcija stvaranja prihoda od ulaganja biti kompatibilna s funkcijom stvaranja kapaciteta. Model koji su razvili Harrod i Domar bio je najčešći pristup gospodarskom rastu do pojave Solowljevog modela rasta.

Solow (1956) je model rasta Harroda i Domara kritizirao zbog njihovog stajališta kako je, čak i dugoročno, ekonomski sustav u najboljem slučaju uravnotežen u okviru neznatnog

ravnotežnog rasta. U središtu Solowljevog modela rasta, za razliku od Harrod-Domarova modela je neoklasična funkcija agregatne proizvodnje. Solow je dokazao da je puna zaposlenost u funkciji uravnoteženog rasta moguća pod širokim rasponom uvjeta, ako su rad i kapital zamjenjivi u proizvodnji, umjesto da budu ograničeni na fiksni omjer kako pretpostavljaju Harrod i Domar.

5.5.2. Uzroci i vrste nezaposlenosti

Nezaposlenost može biti uzrokovana različitim razlozima koji dolaze i sa strane potražnje, odnosno poslodavaca i strane ponude, odnosno radnika.

Smanjenje potražnje može biti uzrokovano visokim kamatnim stopama, globalnom recesijom ili financijskom krizom. Sa strane ponude, najveći učinak imaju frikcijska nezaposlenost i strukturna zaposlenost.

Samuelson i Nordhaus (2011: 598-599) navode da se prema vrstama nezaposlenosti razlikuju ravnotežna nezaposlenost i neravnotežna nezaposlenost. Razlika između ravnotežne i neravnotežne nezaposlenosti je u tome što se ravnotežna nezaposlenost odnosi na situacije u kojima osobe dobrovoljno postanu nezaposlene, kada se sele s jednoga posla na drugi ili ulaze na tržište rada ili pak izlaze s njega. Ona se ponekad naziva i frikcijskom nezaposlenošću ili dobrovoljnom jer je ona produkt ljudskog odabira. S druge strane, neravnotežna nezaposlenost se javlja u slučajevima kada postoje kvalificirani radnici koji su spremni raditi uz postojeću nadnicu, a ne mogu pronaći posao. Neravnotežna nezaposlenosti može biti strukturna – koja ukazuje na nesklad između ponude i potražnje za radnicima te ciklička – u okolnostima kada je cjelokupna potražnja za radom niska.

Jacobson, Vredin i Warne (1998: 69) navode kako je nezaposlenost povezana s razinom realnih plaća u smislu da višak ponude rada gotovo po definiciji odražava činjenicu da su realne plaće iznad svojih tržišnih razina. Međutim, realne plaće nisu fiksne, a posebno one uporno rastu tijekom vremena kako se potražnja za radnom snagom povećava, zahvaljujući tehničkom napretku. Kratkoročno gledano, realne plaće mogu se premalo (ili previše) prilagoditi raznim šokovima, što dovodi do fluktuacija u nezaposlenosti. Eriksson (2005) ističe kako je razina nezaposlenosti pod snažnim utjecajem šokova na tržištu rada i promjena u monopolnoj situaciji na tržištu proizvođača. Autor navedeno tumači kao znakove rigidnosti na švedskom tržištu rada jer bi ti šokovi, bez rigidnosti, trebali rezultirati promjenama plaća umjesto nezaposlenosti. Christopoulos i Le´on-Ledesma (2010: 80) pojašnjavaju kako niska elastičnost realnih plaća na

šokove nezaposlenosti može biti rezultat nekonkurentnih tržišta rada gdje se zapošljavanje, a ne realne plaće, prilagođavaju šokovima potražnje za radnom snagom.

U svom istraživanju, Lavoie (2001: 167) navodi kako u Kaleckianovoj verziji post-Keynesijanskog modela zapošljavanja, više realne plaće pogoduju višim razinama zaposlenosti, a u varijanti koja se bavi rastom i distribucijom, više realne plaće mogu pogodovati višim stopama gospodarskog rasta.

Keynes je 1939. godine pisao o relanim nadnicama u svom djelu „Relativna kretanja realnih plaća i outputa“ u kojem je naveo kako u određenom stanju organizacije, opreme i tehnike, stvarna plaća koju zaradi jedinica rada ima jedinstvenu (obrnutu) korelaciju s opsegom zaposlenosti. Do istovjetnog zaključka u svojoj analizi dolaze i Habanabakize, Meyer i Oláh (2019) koji navode kako realne plaće negativno utječu na dugoročne stope apsorpcije zaposlenosti. Još je 1962. godine Okun istaknuo kako je nezaposlenost reverzibilno povezana s gospodarskim rastom, a više razine gospodarskog rasta pozitivno su povezane s otvaranjem radnih mjesta. Prachowny (1993) se na prethodno navedeno nadovezuje navodeći kako na ovaj odnos utječu i druge varijable, poput ponude rada, plaća i produktivnosti. Ball i Moffittm (2001) također ističu kako su u raznim istraživanjima koja analiziraju odnos nezaposlenosti i gospodarskog rasta dodane varijable produktivnost i realne plaće. Klein (2012) je analizirao radno okruženje u Južnoj Africi tijekom i nakon financijske krize 2008. U istraživanju dolazi do zaključka da je otvaranje radnih mjesta ograničeno kada realne plaće rastu brže od produktivnosti rada. Sawyer (2002) je istraživao odnos između inflacije, zaposlenosti, plaća i kapitalnih ulaganja. Zaključuje kako rastuća agregatna potražnja pokreće odnos između realne plaće i zaposlenosti te da ulaganja igraju glavnu ulogu u stvaranju prilika za zapošljavanje.

Korelaciju između nezaposlenosti i produktivnosti analizirao je Barnichon (2010). Otkrio je kako tehnološki šokovi ili utjecaji mogu dovesti do pozitivnog odnosa između nezaposlenosti i produktivnosti, a netehnološki šokovi, kao što je agregatna potražnja, uzrokuju negativan odnos. Meager i Speckesser (2011) navode kako postoji jaka veza između produktivnosti i plaća, a javna politika ima ograničen utjecaj na taj odnos. Kada su povećanja plaća brža od rasta produktivnosti, to ima negativan učinak na gospodarstvo, ali će se odnos uvijek pokušati pomaknuti u ravnotežu zbog međunarodne konkurencije. U istraživanju je utvrđeno da bi umjerenost u razini plaća mogla omogućiti otvaranje radnih mjesta.

Iako na kretanje realnih plaća utječe niz ekonomskih čimbenika, Gregg, Machin i Fernández-Salgado (2014: 413) naglašavaju kako na ograničavanje razine realnih plaća veliki utjecaj ima veća nezaposlenost koja na navedeno djeluje trojako. Prvo, u vremenima visoke nezaposlenosti, radnici imaju smanjen prostor za traženje viših plaća zbog manje dostupnosti boljih

alternativnih ponuda od strane drugih poslodavaca. Drugo, budući da radnici strahuju od gubitka posla kada postoji mnogo konkurenata protiv kojih se moraju natjecati kako bi dobili zamjenski posao, oni mogu ustupiti plaću kako bi zadržali isti. Konačno, pri otvaranju novih radnih mjesta mnogo je potencijalnih kandidatima te si tvrtke mogu osigurati dobro kvalificiranu radnu snagu uz niže plaće nego u boljim vremenima. Dearden, Reed i Van Reenen (2006) u svom istraživanju dolaze do zaključka kako je obuka radnika u industriji u Velikoj Britaniji imala značajan utjecaj na poboljšanu produktivnost i dovela do povećanja plaća. Conti (2005) također analizira ovaj odnos, ali na razini Italije. Njegovo istraživanje pokazuje slične rezultate vezane uz obuku koja je dovela do značajnog povećanja produktivnosti, ali kretanja u plaćama nisu otkrivena. Lazear (2006) u svom istraživanju ističe čimbenike kao što su fleksibilni radni propisi, razvoj poduzetništva i stalni razvoj vještina koji, kako navodi, mogu dovesti do povećanja produktivnosti.

Zaključno, ovo specifično područje proučavanja nudi zanimljive empirijske nalaze koji će u nastavku biti sumirani:

- Plaće i produktivnost trebale bi imati pozitivnu korelaciju.
- Ako plaće rastu brže od produktivnosti, učinak je negativan i na otvaranje radnih mjesta i na gospodarstvo.
- Kada se lokalna potražnja poveća, pritisak na plaće raste, kao i potražnja za radnom snagom, a također je slučaj da, kada dođe do umjerenosti u razini plaća, otvaranje novih radnih mjesta postaje mogućnost.
- Gledano iz perspektive radnih i drugih propisa, isti negativno utječu na otvaranje radnih mjesta.
- Viša razina vještina dovodi do poboljšane produktivnosti i viših plaća, dok prevelika ponuda radne snage dovodi do nižih plaća.

5.5.3. Dugotrajna nezaposlenost

Dugotrajna nezaposlenost odnosi se na ljude koji su nezaposleni 12 mjeseci ili više. Stopa dugotrajne nezaposlenosti pokazuje udio dugotrajno nezaposlenih među svim nezaposlenima. Dugotrajna nezaposlenost uzrokuje značajan mentalni stres i materijalnu ugrozu onima koji su pogođeni njome i njihovim obiteljima. Ona je također od posebne važnosti za kreatore politike jer visoke stope dugotrajne nezaposlenosti ukazuju na to da tržišta rada djeluju neučinkovito. Ovaj se pokazatelj mjeri kao postotak nezaposlenih. (OECD, 2021b)

Rješavanje problema dugotrajne nezaposlenosti ključni je izazov Komisijine strategije za zapošljavanje i rast kojoj je cilj olakšavanje otvaranja novih, održivih radnih mjesta u EU-u.
U veljači 2016. godine, Vijeće je usvojilo prijedlog Komisije za preporuku o integraciji dugotrajno nezaposlenih na tržište rada.
U travnju 2019. godine, Komisija je usvojila izvješće o provedbi preporuke Vijeća u kojem se ocjenjuje ostvareni napredak. Preporuka Vijeća iznosi tri ključna koraka:

- poticanje registracije dugotrajno nezaposlenih u zavodima za zapošljavanje
- pružanje dubinske procjene svakom registriranom dugotrajno nezaposlenom pojedincu kako bi se utvrdile njihove potrebe i potencijal najkasnije u 18 mjeseci nezaposlenosti
- ponuda ugovora o uključivanju na tržište rada svim registriranim dugotrajno nezaposlenima najkasnije u roku od 18 mjeseci. (European Commission, 2021l)

To će dovesti do pojednostavljenog i boljeg pristupa podršci onima koji duži vremenski period ne rade.
Ugovor o uključivanju na tržište rada trebao bi se sastojati od prilagođenih planova za vraćanje dugotrajno nezaposlenih na posao. Ovisno o postojećim uslugama u svakoj državi članici, može sadržavati:

- ✓ mentorstvo
- ✓ pomoć u traženju posla
- ✓ daljnje obrazovanje i osposobljavanje
- ✓ potporu u vidu stanovanja, prijevoza, djece i usluga njege ili rehabilitacije.

Države članice obvezale su se na aktivno sudjelovanje i partnerstvo s poslodavcima koji bi trebali biti više uključeni u proces povratka na posao za dugotrajno nezaposlene. (European Commission, 2021l)

U tablici 13. prikazana je dugotrajna nezaposlenost prema spolu kao postotak aktivnog stanovništva od 15. do 74. godine na razini Europske unije u razdoblju od 2008. do 2018. godine.

Tablica 13. Dugotrajna nezaposlenost prema spolu kao postotak aktivnog stanovništva na razini Europske unije u razdoblju od 2008. do 2018. godine

(podaci prikazani u %)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	$\bar{x}$
EU-28	**2,6**	**3,0**	**3,8**	**4,1**	**4,6**	**5,1**	**5,0**	**4,5**	**4,0**	**3,4**	**2,9**	**3,9**
Austrija	1,0	1,2	1,2	1,2	1,2	1,3	1,5	1,7	1,9	1,8	1,4	1,4
Belgija	3,3	3,5	4,0	3,5	3,4	3,9	4,3	4,4	4,0	3,5	2,9	3,7
Bugarska	2,9	3,0	4,7	6,3	6,8	7,4	6,9	5,6	4,5	3,4	3,0	5
Cipar	0,5	0,6	1,3	1,6	3,6	6,1	7,7	6,8	5,8	4,5	2,7	3,7
Češka	2,2	2,0	3,0	2,7	3,0	3,0	2,7	2,4	1,7	1,0	0,7	2,2
Danska	0,5	0,6	1,4	1,8	2,1	1,8	1,7	1,6	1,2	1,2	1,0	1,4
Estonija	1,7	3,7	7,6	7,1	5,5	3,8	3,3	2,4	2,1	1,9	1,3	3,7
Finska	1,2	1,4	2,0	1,7	1,6	1,7	1,9	2,3	2,3	2,1	1,6	1,8
Francuska	2,9	3,3	3,9	3,9	4,2	4,5	4,5	4,6	4,6	4,2	3,8	4
Grčka	3,7	3,9	5,7	8,8	14,5	18,5	19,5	18,2	17,0	15,6	13,6	12,6
Hrvatska	5,3	5,1	6,6	8,4	10,2	11,0	10,1	10,2	6,6	4,6	3,4	7,4
Irska	1,7	3,5	6,9	8,8	9,2	8,0	6,6	5,3	4,2	3,0	2,1	5,4
Italija	3,0	3,4	4,0	4,3	5,6	6,9	7,7	6,9	6,7	6,5	6,2	5,6
Latvija	1,9	4,5	8,8	8,8	7,8	5,7	4,6	4,5	4,0	3,3	3,1	5,2
Litva	1,3	3,3	7,4	8,0	6,6	5,1	4,8	3,9	3,0	2,7	2,0	4,4
Luksemburg	1,6	1,2	1,3	1,4	1,6	1,8	1,6	1,9	2,2	2,1	1,4	1,6
Mađarska	3,6	4,2	5,5	5,2	5,0	4,9	3,7	3,1	2,4	1,7	1,4	3,7
Malta	2,6	2,9	4,1	3,9	3,8	3,5	2,9	2,7	2,4	2,0	1,8	3
Nizozemska	1,2	1,1	1,3	1,6	1,9	2,5	2,9	3,0	2,5	1,9	1,4	1,9
Njemačka	3,9	3,5	3,3	2,8	2,4	2,3	2,2	2,0	1,7	1,6	1,4	2,5
Poljska	2,4	2,5	3,0	3,6	4,1	4,4	3,8	3,0	2,2	1,5	1,0	2,9
Portugal	3,6	4,2	5,7	6,2	7,7	9,3	8,4	7,2	6,2	4,5	3,1	6
Rumunjska	2,4	2,2	2,4	2,9	3,0	3,2	2,8	3,0	3,0	2,0	1,8	2,6
Slovačka	6,6	6,5	9,2	9,2	9,4	10,0	9,3	7,6	5,8	5,1	4,0	7,5

Slovenija	1,9	1,8	3,2	3,6	4,3	5,2	5,3	4,7	4,3	3,1	2,2	3,6
Španjolska	2,0	4,3	7,3	8,9	11,0	13,0	12,9	11,4	9,5	7,7	6,4	8,6
Švedska	0,8	1,1	1,6	1,5	1,5	1,4	1,4	1,5	1,3	1,2	1,1	1,3
Ujedinjeno Kraljevstvo	1,4	1,9	2,5	2,7	2,7	2,7	2,2	1,6	1,3	1,1	1,1	1,9
$\bar{x}$	2,4	2,9	4,2	4,7	5,1	5,5	5,3	4,8	4,1	3,4	2,7	
M_e	2,1	3,15	5,15	5,8	7	8	7,8	6,9	5,6	4,35	3,55	

Izvor: izrada autorice prema podacima s Eurostata (2021_c).

Ako se u tablici 13. promotri europski prosjek, dugotrajna nezaposlenost prema spolu, kao postotak aktivnog stanovništva, iznosila je 3,9 %, uzimajući u obzir prosjek vrijednosti dugotrajne nezaposlenosti na osnovi jedanaest navedenih godina.

Grčka ima najvišu stopu dugotrajne nezaposlenosti, čak 12,6 % u prosjeku od ukupne dugotrajne nezaposlenosti u promatranih jedanaest godina, slijede ju Španjolska s 8,6 % i Hrvatska sa 7,4 %.

Najmanju dugotrajnu nezaposlenost ima Švedska s 1,3 % u prosjeku od ukupne dugotrajne nezaposlenosti u promatranih jedanaest godina, zatim Danska i Austrija s 1,4 % u prosjeku od ukupne dugotrajne nezaposlenosti u promatranom razdoblju.

Medijan u 2018. godini iznosi 3,55, što ukazuje na to da pola elemenata niza ima vrijednost jednaku ili veću vrijednosti medijana.

Nezaposlenost je nesumnjivo među glavnim izazovima s kojima se danas u Europi suočavaju i kreatori politike i društvo u cjelini. Postala je srž političke agende država članica EU-a, potičući ključne reforme ili barem opsežne rasprave o njima, u smislu odredbi o tržištu rada i širih socijalnih politika.

Slijedom ovog europskog trenda, mogu se primijetiti sve veće intervencije u promicanju fleksibilnih i kratkoročnih ugovora, nužnosti usmjeravanja nezaposlenih na dostupna radna mjesta i posljedičnih odredbi za prilagođavanje uloga glavnih stupova socijalne skrbi. (Baglioni i suautori, 2014: 87-88)

Politički odgovori na nezaposlenost razlikuju se među državama, a europske zemlje pokazuju važne razlike u stupnju intervencije javnog sektora u pitanjima socijalne sigurnosti, posebno u pogledu nezaposlenosti i programa tržišta rada. (Giugni i suautori, 2009: 10)

„Određene su države članice, na primjer, u skladu s Preporukom Vijeća počele potporu nezaposlenima više prilagođavati pojedincima, zbog čega je potrebna izrada sporazuma o integraciji na tržište rada u kojima se potpora prilagođava pojedinačnim potrebama uz jasna prava i obveze koje trebaju ispuniti nezaposleni i tijela koja pružaju potporu. Neke su države

članice eksternalizirale usluge službi za zapošljavanje za dugotrajno nezaposlene, a neke su dugotrajno nezaposlenima počele nuditi veći broj programa osposobljavanja.“ (European Commission, 2017a: 15)

Iz prethodno navedenog, može se apostrofirati činjenica da države članice u posljednje vrijeme stavljaju naglasak na postizanje djelotvorne koordinacije aktivnih politika tržišta rada i dodjele naknada za nezaposlenost te politika čiji je cilj učiniti „rad financijski isplativijim” kako bi se provodile dosljedne strategije aktivacije. „Sudjelovanjem u aktivnim politikama tržišta rada može se pridonijeti smanjenju dugotrajne nezaposlenosti, što je bitno iz razloga što dugotrajno nezaposlene osobe s vremenom teže pronalaze zaposlenje, imaju manja primanja i manje prilika za razvoj karijere. Zbog stalno visoke razine dugotrajne nezaposlenosti, na nacionalnoj su razini ugroženi opći ciljevi politike zapošljavanja, smanjena je mogućnost dodjele odgovarajućih poslova odgovarajućim osobama i narušena je profesionalna i geografska mobilnost.“ (European Commission, 2017_a: 3)

5.5.4. Diskriminacija na tržištu rada

Raznolikost među stanovništvom Europske unije prepoznaje se kao jedan od njegovih najdragocjenijih potencijala. Međutim, zbog te različitosti mnogi stanovnici još uvijek doživljavaju nejednak tretman. Borba Europe za jednake mogućnosti dobila je poticaj usvajanjem Zakona o jednakosti (2000) od EP[26]-a i Vijeća te Akcijskim programom Zajednice za borbu protiv diskriminacije koji je Komisija usvojila 2001. godine. Pravo na jednakost predstavlja opće pravo priznato širokim spektrom međunarodno dogovorenih instrumenata ljudskih prava, kao što je Opća deklaracija o ljudskim pravima. (Glaude, 2007: 1)

Antidiskriminacijski propisi Europske unije su među najopsežnijim na svijetu. Prethodno navedenim zakonom i Akcijskim programom se zabranjuje diskriminacija na radnom mjestu na temelju rasnog ili etničkog podrijetla, vjere ili uvjerenja, invaliditeta, dobi ili spolne orijentacije – čime se promiče ravnopravnost žena i muškaraca na radnom mjestu. Što se tiče rasnog i etničkog porijekla, ovaj se zakon proteže i na druge aspekte svakodnevnog života, kao što su obrazovanje i socijalne usluge.

Međutim, pozivanje na jednaka prava i donošenje zakona za njihovo promicanje i zaštitu nije dovoljno kako bi se osiguralo da svi u praksi uživaju jednake mogućnosti. Stoga je 2007. proglašena Europskom godinom jednakih mogućnosti za sve. To je bila inicijativa koja je vodila

[26] EP = Europski parlament

ka boljoj strategiji kojom se nastoji dati zamah borbi protiv diskriminacije u EU-u. Cilj ove inicijative bio je upoznati ljude s njihovim pravima, slaviti raznolikost i promicati jednake mogućnosti za sve ljude u Europskoj uniji. (Eurobarometer, 2008: 2)

Diskriminaciju se može definirati kao „nedopušteno i neopravdano razlikovanje osoba na osnovu pojedinih karakteristika. Može se pojaviti u svim aspektima života, a očituje se na različite načine (npr. četvrti u kojima se nastanjuju pojedine skupine, dostupnost kvalitetnom obrazovanju i zdravstvenoj njezi). Diskriminacija se javlja i na tržištu rada i odnosi se na pristupačnost pojedinih skupina tržištu rada i njihovom nepovoljnom položaju na njemu.“ (Bušelić, 2014: 79)

To znači da iako radnici mogu biti jednako produktivni, s njima se ne postupa na jednak način. U kontekstu tržišta rada „diskriminacija se javlja kad tržište pruža različite mogućnosti sličnim pojedincima koji se razlikuju jedino po rasi, etničkoj skupini, spolu, dobi ili drugim osobnim karakteristikama. Diskriminacija odražava predrasude nekih ljudi prema određenim skupinama u društvu.“ (Mankiw, 2006: 420)

5.5.4.1. Oblici diskriminacije na tržištu rada

U modernim društvima diskriminacija poprima različite oblike, a odnosi se na razlikovanje pojedinaca prema kriterijima koji nisu relevantni za zapošljavanje i obavljanje samoga posla. Danas se najčešće odnosi na segregaciju pojedinaca na po njima štetno djelovanje. Preduvjet za postojanje diskriminacije je predrasuda, iako sve predrasude neće dovesti do diskriminacije. Diskriminacija na tržištu rada je vrednovanje osobnih karakteristika radnika koje nisu povezane s njihovom proizvodnošću (npr. spol, rasa, godine, nacionalnost, spolno opredjeljenje, vjeroispovijest). U ekonomskom smislu postoji kada su radnici pripadnici manjina ili žene – koje imaju iste sposobnosti, obrazovanje, staž i iskustvo kao i bijeli muški radnici – izloženi lošijim uvjetima u odnosu na zapošljavanje, dostupnost zanimanja, unaprjeđenje ili nadnice. (McConnell & Brue, 1994: 348 navedeno u Bušelić, 2014: 79)

Bušelić (2014: 79-81) navodi kako su osnovni tipovi diskriminacija na tržištu rada: diskriminacija prema osobinama radnika (spol, dob, nacionalnost, rasa, vjeroispovijest, spolno opredjeljenje), diskriminacija nadnicama, diskriminacija kod zapošljavanja, diskriminacija ljudskog kapitala i diskriminacija prema zanimanjima i poslovima.

Diskriminacija prema osobinama radnika, npr. predrasude o ulozi žene, spola ili boje kože prilikom zapošljavanja, ima korijene u društvenim shvaćanjima, kulturi i razvijenosti društva. Žene su uključene i u diskriminaciju nadnicama jer su znatno manje plaćene od muškaraca za

isti ili sličan posao, a razlike se jednako tako mogu pronaći i u visini njihovih plaća. Diskriminacija pri zapošljavanju se manifestira u vidu rase ili religije, primjerice kada su nezaposleni manjinske grupe. U kategoriju diskriminacije ljudskog kapitala se svrstavaju osobe koje nemaju pristup bolje plaćenom poslu ili nemaju priliku za napredovanje i dodatne obuke i/ili edukacije. Ovaj vid edukacije zamjetan je u situacijama u kojima se manje sredstava investira u obrazovanje i dodatno osposobljavanje određenih manjina nego u obrazovanje i obuku većinske rase. Diskriminacija prema zanimanjima ili poslovima dovodi do segregacije manjinskih grupa onemogućavajući im pristup bolje pozicioniranim radnim mjestima.

5.5.4.2. Teorije diskriminacije na tržištu rada i pokazatelji diskriminacije

Najrelevantniji teorijski pristupi diskriminaciji na tržištu rada obuhvaćeni su, prema Bušelić (2014: 81-82), Beckerovim modelom sklonosti diskriminaciji, modelom tržišne moći / modelom monopsona, statističkom diskriminacijom te modelom gomilanja. Beckerovim modelom sklonosti diskriminaciji se predviđa postojanje diskriminacije jer poslodavci ne žele zaposliti određenu grupu radnika i to će učiniti jedino ako su nadnice za ove radnike manje od onih uobičajeno isplaćenih. Model tržišne moći se odnosi na diskriminaciju cijena u kontekstu neisplaćivanja jednake plaće radnicima, odnosno poslodavac u ovom slučaju isplaćuje manje plaće radnicima čija je ponuda rada manje elastična. Samuelson & Nordhaus (2011: 262-263) pojašnjavaju kako se, u slučaju statističke diskriminacije, pojedince tretira na temelju prosječnoga ponašanja članova skupine kojoj pripadaju, a ne na temelju njihovih osobnih karakteristika. S druge strane, Bušelić (2014: 83) navodi kako se indeks segregacije može mjeriti modelom gomilanja jer se njime istražuju posljedice ograničenja određenih skupina u određenom broju zanimanja na temelju ponude i potražnje.

Autori McConnell & Brue (1994: 368) ističu važnost uvođenja određenih nediskriminacijskih faktora iz razloga što je u određenim situacijama teško utvrditi utjecaj diskriminacije na određenu manjinsku grupu te njihov socijalni i ekonomski položaj. Kao faktore navode svjesni izbor koji je posebno naglašeniji kod žena u vidu uloge majke, zatim participaciju i odluke o ljudskom kapitalu o kojem ovisi visina obrazovanja i usavršavanja te posljedično visina nadnice te heterogene poslove i sklonosti koji proizlaze iz uvjeta rada, statusa, rizika te razlika u mogućnostima koje se nude za povremene poslove i kraće radno vrijeme.

5.5.4.3. Segmentacija tržišta rada

Segmentirana tržišta rada su dvojna tržišta rada koja se sastoje od različitih podgrupa.
Prema Eurofoundu, segmentacija tržišta rada (LMS)[27] odnosi se na trajne razlike u uvjetima rada pojedinaca na tržištu rada koje se ne mogu pripisati samo razlikama u produktivnosti. U stvarnosti, to znači da dok neki radnici uživaju u stabilnoj i sigurnoj karijeri s dobrim izgledima za razvoj, drugi se suočavaju s nestabilnošću u zapošljavanju, nesigurnošću prihoda i lošim izgledima za karijeru.
Ova teorija objašnjava nejednakosti u mogućnostima i ustrajnosti siromaštva koji ostaju značajna obilježja većine modernih ekonomija.
Činjenica da neki pojedinci nisu u mogućnosti prijeći na bolje rangirane poslove, odnosno postojanje neperspektivnih karijera i imobilnosti, objašnjava i postojanje ustrajnosti siromaštva. Samuelson & Nordhaus (2011: 256-257) naglašavaju činjenicu da će znatna razlika u nadnicama postojati i u poslovnom okruženju savršene konkurencije u kojem osobe mogu lako prelaziti iz jednog zanimanja u drugo. Upravo su te razlike neophodne za održavanje razlika u troškovima obrazovanja ili obuke, u neprivlačnosti određenih zanimanja ili nagrada za jedinstvene talente. No, čak i nakon što se uzmu u obzir svi ti razlozi za razlike u nadnicama, još uvijek postoji znatan nesrazmjer u nadnicama. Osnovni je razlog tomu taj što su tržišta rada segmentirana na nekonkurentne skupine. Primjer se može pronaći u zanimanjima u kojima se osobe mogu specijalizirati te na taj način postati dijelom pojedinog podtržišta rada. Na taj način njihova zarada raste ili pada ovisno o ponudi i potražnji za kompetencijama koje posjeduju te prilikama u tom zanimanju ili sektoru. Razlika u nadnicama između pojedinih zanimanja upravo je rezultanta segmentacije nadnica.

5.6. Sigurnost u radnom i relevantnom socijalnom pravu na tržištu rada EU-a

„U teoriji fleksibilnosti tržišta rada socijalna sigurnost poima se kao protuteža fleksibilnosti, odnosno kao onaj čimbenik koji koncept fleksibilnosti preoblikuje u koncept fleksigurnosti.
U opisanom kontekstu socijalna sigurnost obuhvaća:

a) institucije tržišta rada kao što su sustavi osiguranja za vrijeme nezaposlenosti i javni sustav za zapošljavanje, zakonodavni okvir zakonske zaštite zaposlenja, minimalne plaće i politike tržišta rada

[27] LMS = segmentacija tržišta rada (engl. *Labour market segmentation*)

b) zakonsku zaštitu zaposlenja koja se odnosi na propise kojima se uređuju zapošljavanje i otkazivanje, plaćanje otpremnina, minimalni otkazni rokovi, administrativna ovjera otkaza, te obveza prethodnog informiranja i savjetovanja sa sindikatima i/ili za to ovlaštenim tijelima vlasti.“ (Kulušić, 2009: 139)

Socijalna zaštita i socijalna pomoć važni su elementi procesa socijalne uključenosti EU-a. Kulušić (2009: 140-141) ističe kako je pitanje socijalne sigurnosti u Europskoj zajednici jedno od pitanja kojemu se pridaje iznimno velika pozornost, koja je temeljena na osnovnim pravnim aktima toga područja te je sažeto u posebnu političku platformu pod motom „Socijalna Europa u globalnoj ekonomiji: zaposlenje i prilike svima“ sadržanu u posebnom strateškom dokumentu „Socijalni plan“. Tim dokumentom naglašava se nužnost socijalne zaštite svih oblika i svih građana EU-a kroz dodatne vrijednosti koju sustav socijalne sigurnosti stvara s ciljem moderniziranja Europskog socijalnog modela na načelima izgradnje povjerenja građana i uvođenje mjera za unapređenje sustava socijalne zaštite.

Programi i politike socijalne pomoći za suzbijanje siromaštva i isključenosti postoje u svim zemljama i središnji su elementi Nacionalnih akcijskih planova za socijalno uključivanje svake od zemalja EU-a. Iako beneficije socijalne pomoći na osnovi imovinskog stanja čine relativno mali udio u BDP-u i ukupnoj potrošnji na socijalnu zaštitu, oni su važan izvor prihoda onima koji ih primaju. (Ringold & Kasek, 2007: 43)

U sljedećoj tablici (tablica 14.) prikazani su ukupni izdaci za socijalnu zaštitu na razini EU-a u vremenskom intervalu od 11 godina.

Tablica 14. Ukupni izdaci za socijalnu zaštitu na razini EU-a u razdoblju od 2008. do 2018. godine

(podaci prikazani u € po stanovniku)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	x̄
EU-28	6.779,73	7.046,38	7.299,06	7.442,11	7.675,72	7.772,86	7.948,37	8.267,24	8.226,58	8.383,23	8.555,27	7.763,32
Austrija	9.734,25	10.207,17	10.479,78	10.654,12	11.023,09	11.323,28	11.619,38	11.896,04	12.219,77	12.353,78	12.719,74	11.293,67
Belgija	9.172,79	9.688,20	9.849,13	10.194,78	10.322,15	10.574,13	10.780,84	11.026,11	11.099,57	11.288,24	11.580,26	10.506,93
Bugarska	731,76	806,84	879,26	927,59	951,95	1.016,47	1.095,08	1.126,29	1.186,09	1.248,76	1.347,72	1.028,89
Cipar	4.242,63	4.411,32	4.368,05	4.682,79	4.713,14	4.802,11	4.127,41	4.226,84	4.322,72	4.333,33	4.465,08	4.426,86
Češka	2.780,00	2.861,71	2.998,05	3.135,00	3.139,27	3.027,18	2.926,74	3.028,74	3.150,55	3.357,36	3.662,70	3.097,03
Danska	13.382,68	14.346,42	14.921,55	14.892,81	15.319,84	15.891,85	16.183,22	16.192,73	16.046,28	16.308,24	16.391,28	15.443,35
Estonija	1.813,43	1.990,27	1.944,88	1.962,82	2.036,36	2.132,05	2.273,47	2.530,47	2.738,23	2.889,05	3.209,16	2.320,02
Finska	9.156,43	9.841,35	10.223,45	10.549,13	11.111,31	11.641,37	12.002,67	12.260,59	12.524,69	12.543,06	12.732,95	11.326,09
Francuska	9.562,75	9.973,12	10.215,20	10.444,26	10.802,71	11.020,76	11.183,47	11.316,20	11.481,90	11.692,30	11.886,08	10.870,8
Grčka	4.987,91	5.308,69	5.264,56	5.090,86	4.865,75	4.352,04	4.265,99	4.258,43	4.284,91	4.224,12	4.234,30	4.648,87
Hrvatska	2.097,68	2.202,41	2.233,83	2.199,61	2.221,59	2.197,89	2.237,00	2.312,06	2.440,13	2.564,75	2.734,06	2.312,82
Irska	8.526,83	9.058,40	9.228,80	9.150,34	9.107,83	8.905,96	8.814,85	8.927,38	8.997,64	9.267,66	9.507,76	9.044,86
Italija	7.405,48	7.670,25	7.809,69	7.872,98	7.936,70	7.938,93	7.980,72	8.094,51	8.158,59	8.280,50	8.454,85	7.963,93
Latvija	1.355,86	1.472,81	1.549,39	1.504,17	1.556,17	1.660,53	1.715,96	1.839,72	1.935,91	2.049,56	2.304,00	1.722,19
Litva	1.627,64	1.786,91	1.730,54	1.757,64	1.823,76	1.820,52	1.912,93	2.013,82	2.085,11	2.253,50	2.573,34	1.944,16
Luksemburg	16.339,19	17.358,68	17.870,51	18.136,02	18.862,11	19.764,45	20.127,83	20.196,02	20.039,51	20.844,65	22.329,10	19.260,73
Mađarska	2.405,73	2.137,42	2.225,83	2.196,33	2.135,23	2.138,26	2.121,01	2.176,76	2.222,34	2.354,49	2.421,86	2.230,48

Malta	2.725,13	2.928,70	3.100,37	3.124,73	3.284,18	3.415,99	3.587,69	3.680,41	3.803,47	3.925,90	3.968,55	3.413,19
Nizozemska	10.277,40	10.964,65	11.285,56	11.633,75	11.920,29	12.115,43	12.165,78	12.171,07	12.264,48	12.627,01	12.964,54	11.853,63
Njemačka	8.471,64	9.186,72	9.417,39	9.654,95	9.859,57	10.193,94	10.509,64	10.875,43	11.272,23	11.672,95	12.003,61	10.283,46
Poljska	1.857,77	1.690,54	1.874,38	1.867,74	1.930,43	2.030,33	2.087,64	2.197,08	2.359,64	2.491,94	2.584,41	2.088,35
Portugal	3.966,34	4.281,54	4.386,00	4.298,59	4.224,95	4.496,16	4.469,94	4.460,24	4.531,42	4.684,56	4.789,66	4.417,22
Rumunjska	977,15	998,72	1.083,57	1.085,15	1.022,57	1.073,65	1.114,33	1.179,35	1.263,93	1.416,34	1.576,89	1.162,88
Slovačka	1.927,03	2.193,17	2.285,56	2.332,32	2.420,74	2.506,73	2.594,14	2.649,43	2.743,82	2.828,91	2.952,90	2.494,07
Slovenija	3.937,99	4.210,18	4.322,33	4.409,55	4.358,77	4.349,12	4.360,44	4.472,39	4.551,12	4.707,66	4.866,13	4.413,24
Španjolska	5.205,15	5.689,25	5.715,80	5.801,42	5.662,98	5.679,88	5.668,43	5.733,29	5.713,95	5.842,86	6.051,73	5.705,89
Švedska	10.659,21	10.078,54	11.322,94	12.210,67	13.106,01	13.722,63	13.277,56	13.458,49	13.818,50	13.715,29	13.071,07	12.585,54
Ujedinjeno Kraljevstvo	8.249,51	7.880,15	8.496,06	8.644,00	9.490,34	9.156,33	9.729,03	11.084,96	9.592,01	9.395,12	9.360,11	9.188,87
$\bar{x}$	5.842,05	6.115,15	6.324,37	6.443,36	6.614,64	6.748,14	6.819,04	6.978,03	7.030,30	7.184,35	7.383,71	

Izvor: izrada autorice prema podacima s Eurostata (2021_f).

U tablici 14. jasno se vide najviši iznosi na godišnjoj razini raspoređeni za izdatke za socijalnu zaštitu na razini EU-a. Najviši iznos za izdatke za socijalnu zaštitu na razini EU-a omogućuje Luksemburg. Najniže izdatke za socijalnu zaštitu osigurava Rumunjska s prosječnih 1162,88 € godišnje. Ako se uzmu u obzir prosječne vrijednosti ukupnih izdataka za socijalnu zaštitu po godinama, može se uočiti uzlazni trend u povećanju izdataka koji u 2018. godini iznosi 7.383,71 €, što je za 26,39 % više nego u baznoj 2008. godini, a što ukazuje na progresivnost politika socijalne pomoći za suzbijanje siromaštva i isključenosti od Europske unije.

Oblici sigurnosti u radnom i relevantnom socijalnom pravu na tržištu rada obuhvaćaju:

1. „sigurnost radnog odnosa
2. sigurnost zaposlenja, odnosno zapošljivosti
3. sigurnost prihoda ili socijalnu sigurnost
4. kombinirana sigurnost koja omogućuje radniku kombiniranje svojega posla s drugim, posebno osobnim odgovornostima i obvezama uz plaćeni posao.“ (Učur, 2000: 17 i 39 navedeno u Kulušić: 2009: 146)

Sigurnost radnog odnosa

Sigurnost zaposlenja se može definirati kao zaštita radnika od posljedica gubitka posla. Gubitak posla može nastati tijekom gospodarskih kriza, kao dio restrukturiranja ili biti povezan s drugim raznim razlozima za otpuštanje. Porast nestandardnih poslova u posljednje vrijeme, kao što su privremeni ugovori, privremeni rad preko agencija, ugovori o djelu, samostalna samozapošljavanje, marginalni rad s nepunim radnim vremenom, povećao je zabrinutost radnika oko sigurnosti zaposlenja.

Cazes & Nesporova (2007: 7) navode kako zakonska zaštita zaposlenja u pitanju postizanja sigurnosti zaposlenja ili zapošljivosti, kao jedna od mjera socijalne zaštite koju diktira socijalna politika, igra ključnu ulogu. Zakonska zaštita zaposlenja obuhvaća norme koje se odnose na zapošljavanje i otkazivanje (engl. *hiring and firing*), osobito one kojima se uređuje nezakonit otkaz, prestanak radnog odnosa zbog gospodarskih razloga, visina i isplata otpremnina, minimalni otkazni rokovi, prethodno odobrenje otkaza od nadležnih tijela vlasti te obveza savjetovanja s predstavnicima sindikata ili tijelima uprave nadležnim za pitanja rada.

Sigurnost zaposlenja, odnosno zapošljivosti

Za sigurnost posla se može reći kako je to jamstvo da zaposlenik može zadržati svoj posao u doglednoj budućnosti uz minimalne utjecaje vanjskih čimbenika. „Sigurnost zaposlenja, odnosno zapošljivosti u značenju sigurnosti održanja u radnom odnosu, ali ne nužno s istim poslodavcem, vrlo je bitan čimbenik koncepta fleksigurnosti. Svrhu tog dijela politike predstavlja maksimalno moguće skraćivanje razdoblja između dva zaposlenja, te unaprjeđivanje osobina radnika koje mu omogućuju što je moguće brže ponovno zapošljavanje, pri čemu se osobito važnima čine aktivne mjere politike tržišta rada i sustav cjeloživotnog obrazovanja.“ (Kulušić: 2009: 148-49)

Sigurnost prihoda na tržištu rada

Prema Ozawi (2013), sigurnost prihoda je osiguranje minimalne razine dohotka pojedincima, obiteljima i kućanstvima, bez obzira na njihovo sudjelovanje u radnoj snazi. „U kontekstu koncepta fleksigurnosti, sigurnost prihoda predstavlja mjeru socijalne zaštite kojom se osobama u razdobljima nezaposlenosti do kojih dolazi tijekom njihovog radnog vijeka osiguravaju, u prvom redu, određeni prihodi.“ (Kulušić: 2009: 152)

„Uz sigurnost prihoda posredno ili neposredno vezuje se institut naknade za vrijeme nezaposlenosti i drugih prestacija po toj osnovi. Prestacije za vrijeme nezaposlenosti, kao dio ukupnosti mjera politike tržišta rada, koje se svrstavaju u, tzv. pasivne mjere politike tržišta rada, treba promatrati i u sklopu drugih mjera u radnim i socijalnopravnim odnosima, poput politike poreza i doprinosa, izdvajanja iz proračuna, režima mirovina, režima dječjeg dodatka, smanjivanja udjela zdravstvene potražnje u bruto-društvenom proizvodu, ali i u cjelini gospodarskih, političkih i drugih odnosa kao što je status javnih poduzeća, uvoz i izvoz, strane investicije i drugo, koristeći pritom iskustva drugih.“ (Učur, 2000: 223 navedeno u Kulušić: 2009: 152)

Kombinirana sigurnost na tržištu rada

„Sintagma kombinirana sigurnost u kontekstu fleksigurnosti odnosi se na sigurnost pojedinca koja mu omogućava kombiniranje plaćenog radnog odnosa s drugim oblicima aktivnosti i obveza.

Kombinirana sigurnost obuhvaća različite oblike izbivanja s posla, kao i pravo na obrazovanje i usavršavanje te rotiranje radnih mjesta. Kombinirana sigurnost pomaže stvaranju fleksibilnog tržišta rada omogućujući privremeno sudjelovanje u područjima života različitim od radnog odnosa i, potom, povratak u svijet rada. Primjeri koji su privukli najviše pozornosti u međunarodnim razmjerima su primjeri kombinirane sigurnosti razvijeni u Danskoj: rotiranje radnih mjesta, dopust za obrazovanje, rodiljni dopust te dopust za važne osobne potrebe.“ (Anderson & Mailand, 2005: 21)

Za razliku od danskog primjera, kriza zaposlenosti i nova struktura rada u određenim državama EU-a značajno utječu na sustave socijalne sigurnosti. Drugim riječima, „fleksibilna zaposlenost u konfliktu je sa sustavima socijalne sigurnosti, budući da su oni prilagođeni zaposlenosti s punim radnim vremenom. Primjera radi, u nekim zemljama minimalni pragovi za ostvarenje prava na socijalne naknade radnicima na atipičnim radnim mjestima ne omogućavaju „ulazak“ u sustav socijalnog osiguranja. Može se raditi o minimalnim dohocima, minimalnom broju sati

rada ili, pak, obveznom prethodnom plaćanju doprinosa. Sve to pred socijalnu politiku postavlja zadatak kritičkog sagledavanja sustava socijalne sigurnosti i njihove „fleksibilizacije“ kakva se već događa u samoj zaposlenosti. Novi oblici zaposlenosti postaju normalni pa je nužno preispitati programe socijalne sigurnosti u onim zemljama koje imaju minimalne pragove za pristup pravima na naknade jer bez nužnih promjena dolaze u pitanje sami temelji socijalne sigurnosti kao i postojećih fiskalnih sustava.“ (Puljiz i suautori, 2005: 265-266)

Preporuke EU-a za reduciranje uporabe naknada socijalne skrbi i pomoći nezaposlenim osobama, kako bi iz neaktivnog položaja u što kraćem roku prešle u aktivni, iziskuju reforme sustava naknada i poreza. Takve bi reforme pružile poticaj nezaposlenim radnicima u traženju posla i, konačno, poticaj za stupanje u radni odnos. To je osobito važno u segmentu poticanja niže kvalificiranih radnika, koji imaju tendenciju padanja u zamke socijalne skrbi i siromaštva. (Michaud, 2004: 4)

6. FLEKSIBILNOST TRŽIŠTA RADA EU-a

Fleksibilnost tržišta rada odnosi se na spremnost i sposobnost tržišta rada da odgovori na promjene u tržišnim uvjetima, uključujući promjene u potražnji za radnom snagom i stopi nadnica.

Fleksibilnost tržišta rada važan je aspekt funkcioniranja tržišta rada radi prilagođavanja ponude potražnji. Ona je ključna u okviru makroekonomije za uspješnost u vidu postizanja makroekonomskih ciljeva.

„Makroekonomska definicija fleksibilnosti tržišta rada je ona definicija koja se odnosi na brzinu prilagodbe tržišta rada vanjskim udarcima ili promjenjivim ekonomskim okolnostima pa fleksibilnost tržišta rada predstavlja stupanj do kojega se zaposlenost i/ili radno vrijeme (kvantitativna prilagodba) ili plaće (cjenovna prilagodba) prilagođuju ekonomskim promjenama.

Na mikro-razini iz perspektive poslodavaca fleksibilnost tržišta rada predstavlja situaciju u kojoj institucije tržišta rada bezrazložno ne priječe mogućnost poduzeća da prilagode veličinu, strukturu i trošak svoje radne snage kretanjima na tržištu, a iz perspektive radnika, fleksibilnost tržišta rada znači niži stupanj zaštite na radnome mjestu i stoga veću vjerojatnost gubitka radnoga mjesta, iako istodobno znači i veću mogućnost pronalaženja novoga posla.“ (Kulušić: 2009: 49 - 50)

Organizacije mogu izmijeniti svoj fond radne snage na temelju određenih čimbenika, kao što su zapošljavanje i otpuštanje zaposlenika, naknade i beneficije te radno vrijeme i uvjeti. Tvrtke, međutim, nemaju potpunu slobodu za primjenu fleksibilnog tržišta rada zbog zakona i politika koje štite zaposlenike i radni fond.

Upravo se u tome ogleda „nedostatak mikroekonomske fleksibilnosti koji predstavlja goruću zabrinutost za europske zemlje.“ (Burdin & Pérotin, 2019)

Fleksibilnost tržišta rada odnosi se na to koliko brzo poduzeće reagira na promjenjive uvjete na tržištu mijenjanjem svoje radne snage. Fleksibilno tržište rada omogućuje poslodavcima promjene zbog problema s ponudom i potražnjom, ekonomskog ciklusa i drugih tržišnih uvjeta. Ali o istinskom fleksibilnom tržištu rada može se govoriti samo u kontekstu ne postojanja striktnih propisa i zakonskih regulativa vezanih uz radnu snagu. U tom je slučaju poslodavac u mogućnosti odrediti plaće, otpustiti zaposlenike i promijeniti svoje radno vrijeme po vlastitom nahođenju. (Kenton, 2019)

Goudswaard & de Nantieul (2000: 42) navode kako se strategije fleksibilnosti tržišta rada razvijaju pod velikom prismotrom vanjskih razloga i pritisaka.

U kontekstu EMU[28]-a, Komisija je predstavila širok pregled glavnih vrsta fleksibilnosti koje omogućavaju tržištu rada reagirati na šokove na specifične načine i to u kontekstu: fleksibilnosti i diferencijacije plaća, geografske i profesionalne mobilnosti, funkcionalne fleksibilnosti i fleksibilnih radnih uvjeta, numeričke fleksibilnosti, otvaranja radnih mjesta u novim područjima i drugo. Provedba ovih različitih mjera „fleksibilnosti" razlikuje se u različitim državama članicama EU-a, ali evidentno je da su sve države vrlo aktivne u ovom području, uključujući važne promjene u prirodi kolektivnog pregovaranja, sustavima socijalnih naknada, obrazovanju i osposobljavanju, „aktivnim" politikama tržišta rada, shemama zaštite zaposlenja itd. (Urban & Velo, 2006: 588-589)

„Ubrzani razvoj tehnologija i inovacija, pojava društva znanja, procesi globalizacije i razvitak uslužnoga sektora prouzročili su u europskim gospodarstvima potrebu poduzimanja posebnog procesa strukturnih promjena još od sedamdesetih godina prošlog stoljeća. Promjene u gospodarstvu odrazile su se na promjene u društvu općenito: individualizacija socijalnih i ekonomskih odnosa, izraženija uloga aspiracije žena u svijetu rada, sve učestalija pojava novih obiteljskih odnosa (npr. obitelj s jednim roditeljem i kohabitacija) te veće prilike derivirane iz boljeg obrazovanja i zdravstva." (Kulušić: 2009: 39)

Schmid i Schommann (2003: 17) pojašnjavaju kako su se, kao posljedica svih tih čimbenika na tržištu rada, pojavili učinci u obliku primjena u sadržaju radnih odnosa koji su postali kompleksniji te oblika rada koji su postali raznolikiji i nepravilniji.

6.1. Politike i direktive EU-a o fleksibilnosti tržišta rada

Europska unija nastoji promicati društveni napredak te poboljšati životne i radne uvjete naroda Europe – to je navedeno i u preambuli Ugovora o funkcioniranju Europske unije. (European Commission, 2021$_k$)

Direktive radnog prava Europske unije donosile su se i mijenjale tijekom dugog vremenskog razdoblja (1997.-2019.), što znači da su neke od njih usvojene u skladu s prethodnim ugovorima, dok najnovije imaju Lisabonski ugovor kao pravnu osnovu. Većina direktiva usvojenih između 1997. i 2008. godine su kreirane kao odgovor na fleksibilizaciju tržišta rada i usmjerene su na uspostavljanje minimalnih standarda za jednak tretman radnika na različitim vrstama netipičnih ugovora (ugovorima na nepuno radno vrijeme, ugovorima na određeno vrijeme i ugovorima o privremenom zapošljavanju putem agencija). Kroz ostale direktive,

[28] EMU = Ekonomska i monetarna unija

uključujući najnovije, fokus je usmjeren na postavljanje minimalnih standarda za radne uvjete za sve radnike na temelju dogovorene definicije radnika (Direktiva o radnom vremenu, Direktiva o transparentnim i predvidljivim radnim uvjetima, Direktiva o ravnoteži između radnog i privatnog života).

Direktive su nastale prepoznavanjem potreba za približavanjem životnih i radnih uvjeta radnika s netipičnim ugovorima u odnosu na radnike koji imaju ugovore na neodređeno vrijeme. Stoga im je cilj osigurati jednak tretman i zaštitu od diskriminacije. (Boudalaoui-Buresi & Szpejna, 2020: 6)

Europskom strategijom zapošljavanja, koja je sastavni dio strategije rasta Europa 2020., željelo se postići otvaranje dodatnih i boljih radnih mjesta diljem Europske unije.

Bušelić (2017: 138-139) naglašava kako je za ovu strategiju od iznimne važnosti izmjena standardnih ugovora, odnosno kolektivnih ugovora i svih ostalih ugovora koje sklapaju poslodavac i radnik. Također, ističe se potreba za ukidanjem prepreka za rad agencija za privremeno zapošljavanje, posebice među državama članicama te nužnost povećanja pozitivne percepcije o privremenom radu i prilagodbe sustava socijalne zaštite u svrhu povećanja mobilnosti radnika.

Veći broj odredaba Europskog ugovora, kao vrela primarnoga europskoga prava, poglavito odredbe članaka 125.-127., navodi Kulušić (2009: 209), doista obvezuju relevantne čimbenike u Europskoj uniji da promiču prilagodljivost radnika i tržišta rada, kao i visoke stope zaposlenosti. Tako je promicanje fleksibilnosti i sigurnosti dobilo valjanu pravnu osnovu.

„Donošenje strategije Europa 2020. pokrenuto je 2010. sa svrhom stvaranja uvjeta za *pametan, održiv i uključiv rast i zapošljavanje*, na razini EU-a kao cjeline i na razini pojedinačnih država članica. U procesu donošenja Strategije dogovoreno je pet glavnih ciljeva za EU do kraja 2020. koji obuhvaćaju zapošljavanje, istraživanje i razvoj, klimatske promjene / energiju, obrazovanje, socijalnu uključenost i smanjenje siromaštva. Napredak u ostvarenju ciljeva strategije Europa 2020. potiče se i prati u okviru europskog semestra, EU-ova godišnjeg ciklusa koordinacije ekonomskih i proračunskih politika.“ (Maletić i suautori, 2019: 10)

Europska unija nastavlja s aktivnostima po pitanju implementacije mjera koje će pospješiti održivi razvoj. Treba naglasiti da je EU bila je jedna od nositelja Programa Ujedinjenih naroda za održivi razvoj do 2030. godine.

Iako su članice EU-a specifične u teritorijalnom, gospodarstvenom i socijalnom smislu, vidljiva je uzlazna konvergencija koja je rezultat politika EU-a te je evidentno kako su članice napredovale u zadnjem desetljeću po pitanju ispunjavanja prioriteta, ciljeva i inicijativa stretegije Europa 2020., što je temelj za kontinuirano djelovanje u okvirima održivog razvoja.

Na slici 5. je prikazana struktura strategije Europa 2020. - prioriteti, ciljevi te sedam inicijativa u okviru kojih Europska unija i nacionalna tijela moraju koordinirati svoje aktivnosti kako bi postigli zadane ciljeve.

STRATEGIJA EUROPA 2020.			
PRIORITETI	**Pametan rast**	**Održiv rast**	**Uključiv rast**
CILJEVI	✓ investiranje 3% BDP-a EU-a u istraživanje i razvoj ✓ postotak osoba koje rano napuste školovanje ispod 10% i najmanje 40% mlađe generacije sa stečenim tercijarnim stupnjem obrazovanja	✓ ispunjenje klimatsko – energetskih ciljeva	✓ zaposleno 75% populacije u dobi između 20 i 64 godine ✓ 20 milijuna manje ljudi u opasnosti od siromaštva
INICIJATIVE	✓ Digitalna agenda za Europu ✓ Unija inovacija ✓ Mladi u pokretu	✓ Učinkovito iskorištavanje resursa u Europi ✓ Industrijska politika za doba globalizacije	✓ Program za nove kvalifikacije i radna mjesta ✓ Europska platforma za borbu protiv siromaštva

Slika 5. Struktura strategije Europa 2020.
Izvor: izrada autorice prema Maletić i suautori, 2019: 12-13

„U okviru strategije Europa 2020 donesene su integrirane smjernice od kojih se četiri odnose na politiku zapošljavanja i tržište rada:

- povećanje participacije muškaraca i žena na tržištu rada, smanjenje strukturne nezaposlenosti i poticanje kvalitetnijih poslova
- razvijanje vještina radne snage koja će odgovarati potrebama tržišta rada i poticanje cjeloživotnog učenja

- poboljšanje kvalitete i performansi sustava obrazovanje i daljnjeg usavršavanja na svim razinama i povećanje sudjelovanja u tercijarnom obrazovanju
- poticanje socijalne uključenosti i suzbijanje siromaštva.“ (Kersan-Škabić, 2015: 356)

Prema Europskoj komisiji, uvođenje veće ugovorne fleksibilnosti, zajedno s aktivnim mjerama na tržištu rada i povećanjima cjeloživotnog učenja, promicat će zapošljavanje, smanjiti trajanje nezaposlenosti i poboljšati izglede osobama koje trentno nisu sudionici na tržištu rada.
Iako je najveći naglasak stavljen na reforme tržišta rada usmjerene na povećanje fleksibilnosti tržišta rada i potporu tranziciji radnika, Europska komisija također je povezala fleksigurnost s unutarnjom fleksibilnošću i radnim sustavima visokih performansi. Potonji navodno radnicima osigurava veću autonomiju i veću participaciju u donošenju odluka, kontinuiranu nadogradnju vještina te fleksibilne obrasce rada koji bi istima mogli omogućiti razumnu ravnotežu između poslovnog i privatnog života. (Wang & Heyes, 2017: 2-3)

Evidentne promjene u svijetu rada sa sobom donose i nove izazove za radno pravo. Prethodno navedeno se konkretno odnosi na globalizaciju, fleksibilizaciju i tehnološki razvoj kao središnje pokretače promjena. Također, 'četvrta industrijska revolucija' otvara nova pitanja u pogledu rada, ugovora o radu i inih regulativa.
Već se godinama ranije predviđala kriza tradicionalnog regulatornog modela. Tržišta rada su u tom smislu evoluirala te se na njima danas susreću novi načini rada. Ne samo da su fleksibilni oblici rada (rad na određeno vrijeme, rad s nepunim radnim vremenom, privremeno zapošljavanje) zauzeli značajnije mjesto pored standardnog oblika rada (ugovor o radu na neodređeno vrijeme), novi oblici rada, uključujući ugovore s nultim radnim vremenom, honorarni posao[29] i 'masovnu podršku'[30], dovode do daljnje fragmentacije tržišta rada i kazualizacije[31] radne snage, ostavljajući niz radnika izvan opsega zaštite radnog prava.
U svojoj rezoluciji o Europskom stupu za socijalna prava iz 2017. godine, Europski parlament pozvao je na primjerenu socijalnu zaštitu za sve radnike i sve oblike zapošljavanja, uključujući fleksibilne oblike zapošljavanja. (Hendrickx, 2019: 8)

[29] engl. *gig work*. *Gig worker* je osoba koja radi povremene poslove u pravilu u sektoru usluga kao nezavisni izvođač ili *freelancer*
[30] engl. *crowd-sourcing platforms – masovna podrška* ili *nabava iz mnoštva* što podrazumijeva dobivanje potrebnih usluga, ideja ili informacija od neodređene skupine ljudi
[31] Kazualizacija radne snage - proces u kojem se zapošljavanje transformira iz zaposlenja na neodređeno i puno radno vrijeme u povremene ili ugovorne pozicije

6.2. Vrste fleksibilnosti tržišta rada EU-a

Različiti oblici ugovora pojavili su se u odsustvu cjelovitije prilagodbe radnoga prava i kolektivnih ugovora te brzim razvitkom organizacije rada i društva općenito. (Commission of the uropean Communities, 2006: 7) Kulušić (2009: 127) ističe kako se uporište za ovakvu tvrdnju nalazi u podacima o raširenoj primjeni različitih inominantnih ugovora radnoga prava. Autorica navodi da su upravo inominantni, atipični, ako i fleksibilni tipični ugovori o radu odigrali pozitivnu ulogu omogućujući poslodavcima prilagodbu promjenjivim trendovima potražnje, stalno razvijajući tehnologiju i nove prilike za privlačenje i zadržavanje raznolike radne snage kroz postizanje bolje sukladnosti svojih potreba za radnom snagom i ponudom na tržištu rada.

„Ugovori o radu na određeno vrijeme, ugovori o radu s nepunim radnim vremenom, ugovori o radu na poziv, ugovori o radu bez radnog vremena, ugovori o radu za radnike zaposlene putem agencija za posredovanje, slobodnjački ugovori i dr. postali su redovitom praksom radnoga prava diljem Europe. Međutim, postoje dokazi o nekim nepoželjnim učincima povezanim s povećanom diversifikacijom pravnih oblika radnog angažiranja radnika, kao što je postojanje evidentnog rizika da dio radne snage bude uhvaćen u zamku niza sukcesivnih ugovora o radu za kratkotrajne poslove loše kvalitete i s neprikladnom socijalnom zaštitom, ostavljajući radnike u ranjivoj poziciji. Ipak, takvi poslovi mogu poslužiti kao mala vrata za ulazak na tržište rada.“ (Commission of the European Communities, 2006: 8)

Pod fleksibilnim oblicima zaposlenja, pojašnjava Kulušić (2009: 56), podrazumijevaju se pravni oblici u vidu ugovora o radu na određeno vrijeme (engl. *fixed-term, temporary* i *short-term concract*), ugovora o radu s nepunim radnim vremenom (engl. *part-time*), ugovora o privremenom zapošljavanju (engl. *agency work, freelance work, on-call employment, „zero“ hours contract, homeworking, teleworking*), višestrukog zapošljavanja (engl. *multiple job holding*) i ugovora građanskog prava, osobito ugovora o djelu (engl. *civil contracsts*), pri čemu se dva potonja često smatraju blisko vezanima uz prikriveni radni odnos i neformalno zapošljavanje.

„Pravne oblike u kojima se fleksibilnost očituje na razini poduzeća moguće je sistematizirati u četiri glavne skupine:

1. *fleksibilnost procesa rada* – poznata i kao zemljopisna fleksibilnost, kombinira kako eksterne tako i kvalitativne varijable fleksibilnosti
2. *fleksibilnost statusa zaposlenja* – poznata i kao numerička fleksibilnost, kombinira kako eksterne tako i kvantitativne varijable fleksibilnosti

3. *fleksibilnost radnog vremena* - poznata i kao vremenska fleksibilnost, kombinira kako interne tako i kvantitativne varijable fleksibilnosti
4. *fleksibilnost organizacije rada* - poznata i kao funkcionalna fleksibilnost, kombinira kako interne tako i kvalitativne varijable fleksibilnosti.“ (Kulušić: 2009: 57)

Relevantan primjer funkcionalne fleksibilnosti je rotacija poslova. Rotacija poslova je pristup menadžmentu u kojem se zaposlenici premještaju između dvaju ili više zadataka ili poslova u redovitim vremenskim intervalima kako bi bili izloženi svim vertikalama organizacije. Ovdje se radi o unaprijed planiranom pristupu s ciljem testiranja vještina i kompetencija zaposlenika kako bi se osobe smjestile na pravo mjesto. Proces služi i menadžmentu i zaposlenicima. Pomaže menadžmentu u otkrivanju talenta zaposlenika. S druge strane, „rotacija posla omogućava zaposlenicima dobivanje iskustva u obavljanju različitih vrsta specijaliziranih poslova te širenje znanja i osiguravanje raznolikog iskustva.“ (Požega, 2012: 229)

Kulušić (2009: 59) navodi kako se interes poslodavaca u fleksibilizaciji tržišta rada osobito očituje kroz učinke kojima fleksibilni oblici mogu pomoći poslodavcima kako bi se suočili s tim pritiscima. Fleksibilni oblici rada poslodavcima mogu omogućiti maksimiziranje učinaka dostupne radne snage, poboljšati kvalitetu usluge kupcima, povećati produktivnost, reducirati izostanke s posla, bolovanja i stres, privući širi krug kandidata za rad s nepunim radnim vremenom, zadržati cijenjene radnike, povećati angažman radnika, moral i odanost te svakako povećati sposobnost poduzeća da se nosi s promjenama uz pomoć inovacija i kreativnosti radnika.

6.2.1. Fleksibilnost procesa rada

Fleksibilnost procesa rada i/ili geografska fleksibilnost predstavlja kombinaciju eksternih i kvalitativnih varijabli, a dolazi u vidu podugovaranja[32], izmještanja djelatnosti[33] i samozapošljavanja. (Goudswaard & de Nantieul, 2000: 21)

6.2.1.1. Podugovaranje

Podugovaranje je oblik vanjske kvalitativne fleksibilnosti, navodi Kulušić (2009: 113), kod kojega se kao pravno sredstvo koristi neki od ugovora obveznog prava u namjeri da se dobije odrađen, gotov posao[34].

[32] engl. *subcontracting*
[33] engl. *outsourcing*
[34] engl. „*to get the job done*“

Podugovaranje se odnosi na proces sklapanja ugovornog sporazuma s vanjskom osobom ili tvrtkom za obavljanje određene količine posla.

Podugovaranje, kao oblik fleksibilnosti procesa rada, ima svoje pozitivne i negativne strane. Angažiranje pravih podizvođača nudi tvrtki mnoge prednosti koje se u konačnici mogu razviti u strateške prednosti u odnosu na konkurenciju. Podizvođači mogu donijeti dodatne vještine i pozitivan stimulans na radnom mjestu na učinkovitiji i fleksibilniji način od zapošljavanja više zaposlenika.

Unatoč spomenutom, Voudouris (2004: 131) navodi kako su troškovi obuke i problemi nadzora najutjecajniji čimbenici koji objašnjavaju korištenje podugovaranja kao fleksibilnog oblika rada, dok je niska učestalost specijaliziranih zadataka glavni čimbenik koji utječe na korištenje neovisnih izvođača i često pribjegavanje podizvođačima.

6.2.1.2. Ugovori s nultim radnim vremenom

Ugovori s nultim radnim vremenom[35] predstavljaju jedan od oblika vanjske kvantitativne fleksibilnosti. Nazivaju se još i povremeni ugovori. To su takvi angažmani u kojima subjekti pristaju biti dostupnima za rad kako i kada je potrebno, ali se ne ugovara nikakvo određeno trajanje radnoga vremena. Ugovori s nultim radnim vremenom mogu biti fleksibilna opcija i za poslodavce i za radnike. To je savršena opcija za studente koji trebaju fleksibilno radno vrijeme zbog svog rasporeda nastave ili osobe koje žele i imaju mogućnosti raditi više poslova u isto vrijeme. S aspekta poslodavca, taj ugovor podrazumijeva uštedu novca jer će tvrtke time platiti radnike koji su im potrebni samo za određene segmente posla.

S druge strane, navedeni ugovor o radu radniku ne osigurava zajamčen broj radnih sati. To znači da radnik može raditi različit broj sati iz tjedna u tjedan. Radnici imaju pravo prihvatiti ili odbiti te sate, ali ako odluče ne raditi, neće biti plaćeni.

Kulušić (2009: 105) navodi kako se subjektima koji su radno angažirani temeljem nekog od mogućih oblika ugovora o radu s nultim radnim vremenom, kao što su „*stand-by-time*“, „*on-call-time*“ i „*downtime*“, uz ispunjenje određenih pretpostavki, jamči isplata najmanje minimalne plaće određene nacionalnim propisima o minimalnoj plaći.

[35] engl. „*zero hours contract*“

6.2.1.3. Samozapošljavanje

Samozapošljavanje se može smatrati drugom glavnom dimenzijom fleksibilnosti. (Hölscher, Perugini & Pompei, 2011: 275)

Kulušić (2009: 106-107) navodi kako je samozapošljavanje, kao jedan od oblika vanjske kvantitativne fleksibilnosti, moguće promatrati bilo kao strategiju pojedinca za preživljavanje za one koji ne mogu pronaći nikakve druge načine za zaradu i prihod ili kao dokaz o posjedovanju poduzetničkog duha i želje biti nekome nadređen.

U cijeloj je Europi, prema Hatfieldu (2015: 33), samozapošljavanje značajan izvor poslova – kako za one koji imaju poteškoća s pristupom poslovima zaposlenika, tako i za one koji zahtijevaju veći stupanj kontrole nad time kada i gdje rade. Jednako tako, samozapošljavanje i poduzetništvo su identificirani kao ključni pokretači gospodarskog rasta.

Iz tog razloga, Europska unija nastoji povećati udio samozaposlenih kroz različite mjere, kao što su smanjenje poreza i socijalnih prepreka ovom obliku gospodarske aktivnosti.

U tablici 15. prikazan je broj samozaposlenih osoba na razini Europske unije u razdoblju od 2008. do 2018. godine u tisućama. Brojke se odnose na žensku i mušku populaciju od 20. do 64. godine svih razina obrazovanja.

Tablica 15. Samozaposlene osobe na razini Europske unije u razdoblju od 2008. do 2018. godine

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	$\bar{x}$
EU-28	31.076,0	30.787,0	30.867,2	30.556,7	30.573,6	30.302,7	30.555,5	30.428,3	30.518,2	30.366,7	30.209,0	30.567,4
Austrija	428,8	434,5	444,6	434,7	432,6	441,5	439,0	446,0	447,1	441,9	438,1	439,0
Belgija	559,2	577,3	578,8	572,5	582,5	614,8	593,5	619,0	613,1	597,5	593,2	591,0
Bugarska	360,2	356,4	344,0	316,9	303,3	324,0	335,9	329,4	319,2	330,4	323,7	331,2
Cipar	62,6	60,5	58,3	56,7	51,2	53,0	54,1	45,4	43,0	42,1	45,6	52,0
Češka	750,8	769,4	806,3	824,1	842,3	800,7	831,1	804,6	810,2	821,5	822,4	807,6
Danska	225,2	232,3	215,4	213,1	211,7	207,5	204,9	207,6	206,3	198,4	195,3	210,7
Estonija	48,7	46,9	45,0	48,2	49,9	52,7	52,9	56,9	58,0	61,9	65,7	53,3
Finska	292,8	303,4	294,5	296,2	298,8	292,3	298,9	298,9	294,0	278,2	284,2	293,8
Francuska	2.520,5	2.597,7	2.742,5	2.775,2	2.733,8	2.697,2	2.833,2	2.817,3	2.875,2	2.863,4	2.911,8	2.760,7
Grčka	1.284,3	1.283,3	1.258,0	1.194,2	1.129,1	1.094,2	1.068,6	1.060,1	1.063,1	1.081,1	1.089,1	1.145,9

Hrvatska	293,9	287,6	293,5	278,9	243,6	228,5	206,9	201,0	184,6	167,2	165,1	231,9
Irska	322,0	305,6	285,5	275,3	268,4	279,6	283,2	284,5	288,0	283,5	281,6	287,0
Italija	5.175,4	5.018,8	5.033,6	5.002,0	4.972,6	4.864,3	4.828,3	4.802,3	4.764,7	4.667,8	4.643,0	4.888,4
Latvija	86,5	85,2	82,0	84,4	87,1	90,4	90,2	100,2	101,6	102,0	95,8	91,4
Litva	141,3	131,2	110,7	109,9	119,2	132,5	136,0	140,7	146,9	141,4	142,7	132,0
Luksemburg	12,4	15,8	15,6	17,1	18,7	18,5	19,0	21,3	23,2	23,7	20,6	18,7
Mađarska	443,5	446,0	436,4	425,9	418,6	408,4	420,2	426,0	431,9	421,9	428,9	428,0
Malta	21,2	21,2	22,3	21,4	21,9	23,4	24,0	25,8	27,9	31,3	32,0	24,8
Nizozemska	1.071,7	1.096,5	1.112,0	1.115,4	1.131,6	1.178,4	1.198,2	1.222,8	1.255,6	1.280,5	1.299,4	1.178,4
Njemačka	3.887,5	3.946,6	3.910,2	3.995,3	3.996,6	3.886,6	3.818,6	3.769,1	3.729,0	3.665,9	3.551,4	3.832,4
Poljska	2.852,3	2.859,3	2.840,2	2.861,5	2.827,5	2.773,1	2.785,4	2.831,6	2.807,5	2.789,1	2.806,0	2.821,2
Portugal	906,1	867,9	810,3	745,5	721,0	708,3	659,9	623,5	607,5	605,3	602,7	714,4
Rumunjska	1.600,5	1.608,6	1.677,9	1.505,5	1.546,6	1.528,5	1.515,2	1.440,9	1.333,2	1.355,8	1.288,7	1.491,0
Slovačka	329,2	363,7	363,8	364,2	354,6	357,5	357,7	357,4	375,3	374,8	369,0	360,7
Slovenija	90,7	96,6	109,4	108,6	104,9	102,8	108,2	109,5	103,9	107,5	116,3	105,3
Španjolska	3.300,8	2.963,2	2.892,7	2.801,2	2.845,9	2.868,0	2.869,0	2.901,3	2.926,0	2.920,4	2.906,8	2.926,8
Švedska	420,0	419,2	429,3	417,8	413,8	424,3	414,5	412,1	409,0	413,8	420,1	417,6
Ujedinjeno Kraljevstvo	3.588,2	3.592,3	3.654,4	3.694,8	3.846,0	3.851,7	4.109,0	4.073,3	4.273,2	4.298,4	4.269,8	3.931,9
$\bar{x}$	1.109,9	1.099,5	1.102,4	1.091,3	1.091,9	1.082,2	1.091,3	1.086,7	1.089,9	1.084,5	1.078,9	

Izvor: izrada autorice prema podacima s Eurostata (2021_e).

Ako se promotre podaci prikazani u tablici 15., nužno je istaknuti da je samozaposlenost najveća u Italiji i to u prosjeku s 4 888 436 osoba godišnje od 2008. do 2018. godine. Taj podatak je interesantan, između ostalog, i zbog činjenice da je prosječna samozaposlenost na razini EU-28 u promatranom periodu prosječno 30 567 354 osoba godišnje.

6.2.2. Fleksibilnost radnopravnog statusa

Raspored radnog vremena i fleksibilnost radnopravnog statusa uvelike se razlikuju među zemljama i čini se da ovise o nekoliko pozadinskih značajki uključujući državu, spol, dob, razinu obrazovanja, profesionalni status, gospodarsku aktivnost i zanimanje. Štoviše, na to utječe i sastav kućanstva, veličina poduzeća u kojem su osobe zaposlene i učestalost rada od kuće. Europska komisija ističe kako je radno i socijalno pravo većine europskih država stvoreno

radi osiguranja zaštite radnika, kao subordiniranom subjektu radnopravnog odnosa, na pojedinim poslovima. Poboljšanjem radnih uvjeta i maksimalizacijom sigurnosti radnih mjesta u Europskoj uniji, stvara se poslovno okruženje koje je produktivnije, a zaposlenici efikasniji. No Kulušić (2009: 90) navodi kako je to još daleko od ostvarenja cilja pošto se norme radnog i socijalnog prava mogu pokazati nedostatnima da bi pomogle radnicima u određenim situacijama kao što je prijelaz iz jednog radnopravnog statusa u drugi, kako u slučaju neželjena prekida kontinuiranog radnog odnosa (primjerice, otkaz ili nezaposlenost) ili prekida prouzročenog slobodnom voljom radnika (primjerice, u slučaju dopusta za potrebe obrazovanja ili usavršavanja, prekida karijere ili rodiljnog dopusta). Prigode za ulazak, ostanak i napredak na tržištu rada značajno odstupaju ovisno o stupnju zakonske zaštite zaposlenja i zakonskog ugovornog okvira na nacionalnoj razini, što snažno utječe na fleksibilnost. Odstupanja se mogu primijetiti u konkretnom slučaju vezanom uz žensku radnu snagu koja je natprosječno neproporcionalno zastupljena u svim državama EU-a i koja se još uvijek suočava s preprekama u traženju pristupa ostvarenju određenih prava u punom opsegu, kao i prestacija na osnovi socijalne zaštite. Prema Svjetskoj banci, u 2008. godini postotak žena koje su bile dio tržišta rada u odnosu na ukupnu žensku populaciju iznad 15 godina iznosio je 48,9 %, dok je u 2018. godini taj postotak iznosio 50,7 % s tendencijom daljnjeg, ali neznatnog rasta (50,9 % u 2019. godini).

Fleksibilnost radnopravnog statusa, prema Goudswaardu & de Nantieulu (2000: 23), predstavlja oblik numeričke fleksibilnosti koja kombinira eksterne i kvantitativne varijable, a pojavljuje se u više oblika – od normiranja maksimalno dopuštenog broja konsekutivnih ugovora o radu na određeno vrijeme ili specijalnih normi za ugovore o radu za pripravnike kao ulazne točke za mlade radnike, odnosno u obliku ugovora o radu i obrazovanju do strukturnog korištenja radnika kroz zapošljavanje putem agencija za privremeno zapošljavanje i drugog.

Sve su to oblici ugovora koji omogućavaju zapošljavanje kada se poslodavci nalaze u neizvjesnosti vezanoj uz potražnju za radnom snagom.

6.2.2.1. Rad na određeno vrijeme

Anderson i Mailand (2005: 23) navode kako institut rada na određeno vrijeme predstavlja jedan od oblika fleksibilnog rada i to oblik vanjske, kvantitativne fleksibilnosti.

Zaposlenje na određeno vrijeme odnosi se na vrstu zaposlenja koja ima određeni datum početka i završetka, u kojem zaposlenik pristaje raditi do određenog datuma završetka ili po završetku projekta.

Prema Blanpainu (1995: 178), radnikom zaposlenim na određeno vrijeme smatra se onaj radnik koji je zaposlen na ograničeno razdoblje, na poslu za koji obje strane očekuju da će trajati samo kratko vrijeme.

Ugovori na određeno vrijeme mogu biti vrlo korisni u slučajevima kada tvrtka treba zamjenu za zaposlenika koji je na rodiljnom dopustu ili bolovanju ili zaposliti djelatnika za točno trajanje određenog projekta. U nekim zemljama, tvrtke koje zapošljavaju djelatnike na ugovor na određeno vrijeme imaju opciju za njihovo produženje, na primjer u slučaju da glavni projekt ostane nedovršen ili organizacija premjesti ugovornog zaposlenika na drugi projekt.

Međutim, ugovor na određeno vrijeme ne može se raskinuti prije naznačenog datuma isteka, što može tvrtku koštati više.

Zaposlenici na određeno vrijeme imaju ista prava i obveze iz radnog odnosa kao i zaposlenici na neodređeno vrijeme. No postoje slučajevi u kojima to nije u potpunosti tako. Europska unija putem Direktive (1999/70/EC) regulira ovo pitanje te nastoji spriječiti neopravdanu diskriminaciju i zlouporabu uzastopnih ugovora na određeno vrijeme između istog poslodavca i zaposlenika za isti posao.

6.2.2.2. Privremeno zapošljavanje

U smislu teorije fleksibilnosti tržišta rada, prema Kulušić (2009: 96), privremeno zapošljavanje putem agencija za zapošljavanje smatra se oblikom vanjske kvantitativne fleksibilnosti. Privremeno zapošljavanje radnika putem agencija za privremeno zapošljavanje smatra se fleksibilnim oblikom rada koji nudi rješenje u okvirima prilagođavanja trendovima potražnje na tržištima rada.

Blanpain (1995: 185) navodi kako se u europskom radnom pravu ugovor o radu za privremeno zapošljavanje definira kao onaj radni odnos koji obuhvaća svaki radni odnos između agencije za privremeno zapošljavanje koja ima položaj poslodavca u odnosu prema radniku, pri čemu potonji nema ugovor o radu s poduzećem korisnikom kod kojega *de facto* radi.

Taj trostrani odnos između poduzeća-korisnika, zaposlenika i agencije, obično nastaje ondje gdje je radnik zaposlen preko agencije za privremeno zapošljavanje i potom iznajmljen da bi obavio povjerene mu poslove poduzeću-korisniku u smislu uglavaka[36] ugovora trgovačkog prava sklopljenog između agencije i poduzeća-korisnika. (Commission of the European Communities, 2006: 12)

[36] uglavak = posebna odredba, klauzula; sastojak obveznih ugovora

U tablici 16. naveden je broj privremeno zaposlenih osoba na razini Europske unije u razdoblju od 2008. do 2018. godine prikazan u tisućama. Brojke se odnose na žensku i mušku populaciju od 20. do 64. godine svih razina obrazovanja.

Tablica 16. Privremeno zaposlene osobe na razini Europske unije u razdoblju od 2008. do 2018. godine

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	x̄
EU-28	23.196,9	21.965,2	22.375,5	22.756,7	22.205,3	22.090,2	22.923,6	23.659,2	24.174,2	24.722,3	24.715,8	23.162,3
Austrija	173,6	176,4	189,2	196,5	198,0	203,7	209,3	213,0	221,8	242,7	245,7	206,4
Belgija	289,7	281,5	287,0	312,8	290,7	291,1	311,4	326,0	334,5	383,1	393,1	318,3
Bugarska	137,5	124,8	114,0	101,8	110,8	139,9	131,9	112,3	103,4	115,1	106,9	118,0
Cipar	41,2	41,2	44,0	45,6	47,6	51,7	55,6	55,0	50,2	49,5	46,5	48,0
Češka	288,1	293,6	313,6	305,3	317,6	357,1	378,7	398,6	394,1	394,1	351,3	344,7
Danska	166,1	169,4	167,6	171,7	168,9	174,0	167,4	171,7	274,7	242,7	212,2	189,7
Estonija	13,2	11,7	17,5	22,6	17,0	17,7	15,6	17,3	18,0	15,4	16,6	16,6
Finska	288,5	272,2	291,2	295,8	293,1	286,6	283,5	279,3	290,5	299,6	312,7	290,3
Francuska	3.097,7	2.948,1	3.081,8	3.146,5	3.154,2	3.185,8	3.246,0	3.421,0	3.461,0	3.620,7	3.591,8	3.268,6
Grčka	336,5	352,2	348,1	300,2	235,5	220,8	258,9	275,4	266,1	278,1	283,0	286,8
Hrvatska	160,9	155,7	159,8	164,5	161,8	176,5	213,5	260,5	287,5	278,1	274,6	208,5
Irska	129,1	128,0	136,9	145,4	143,5	145,7	142,5	137,3	130,8	137,8	156,4	139,4
Italija	2.170,0	2.024,8	2.049,9	2.171,6	2.255,7	2.142,0	2.223,7	2.321,7	2.362,6	2.635,6	2.951,9	2.300,9
Latvija	27,9	32,3	50,6	48,9	35,0	31,5	24,3	26,9	26,8	21,5	20,0	31,4
Litva	27,9	25,0	25,5	28,9	27,6	28,4	29,9	23,0	20,7	18,0	16,0	24,6
Luksemburg	10,1	12,4	12,9	13,3	14,8	13,8	16,0	21,3	19,1	20,4	23,4	16,1
Mađarska	258,1	271,1	311,3	293,8	316,5	370,8	382,5	415,0	366,9	336,8	280,3	327,6
Malta	5,0	5,5	6,1	8,0	8,9	10,3	11,2	11,6	12,1	10,4	14,7	9,4
Nizozemska	993,9	998,4	990,0	995,3	1.057,6	1.099,3	1.135,1	1.064,5	1.099,8	1.173,7	1.160,0	1.069,8
Njemačka	3.975,2	3.962,1	3.980,1	4.111,2	3.935,1	3.844,4	3.798,1	3.856,1	3.977,2	3.937,2	3.876,5	3.932,1
Poljska	3.148,0	3.113,6	3.131,4	3.121,3	3.145,7	3.167,7	3.428,0	3.446,5	3.420,3	3.298,5	3.077,4	3.227,1
Portugal	831,0	784,4	823,5	784,9	702,3	712,8	743,3	781,9	808,6	828,1	850,9	786,5
Rumunjska	74,3	59,2	57,2	79,9	86,6	79,9	85,3	81,6	81,9	74,5	68,2	75,3
Slovačka	89,9	81,2	105,8	123,7	128,8	130,1	170,0	210,3	203,6	195,1	168,0	146,0

Slovenija	133,5	122,5	127,6	131,8	126,4	117,4	118,0	129,7	126,7	135,6	121,2	126,4
Španjolska	4.663,1	3.859,1	3.742,3	3.767,4	3.340,3	3.198,2	3.364,6	3.644,3	3.886,6	4.091,8	4.236,3	3.799,5
Švedska	534,4	495,8	536,9	576,6	562,0	583,9	611,1	613,9	609,6	614,9	609,4	577,1
Ujedinjeno Kraljevstvo	1.132,6	1.162,9	1.273,8	1.291,9	1.323,4	1.309,3	1.368,4	1.343,6	1.319,1	1.273,3	1.250,9	1.277,2
$\bar{x}$	828,5	784,5	799,1	812,8	793,1	788,9	818,7	845,0	863,4	882,9	882,7	

Izvor: izrada autorice prema podacima s Eurostata (2021_g).

Iz prikazanih podataka u tablici 16. može se primijetiti da je najveći broj privremeno zaposlenih osoba u Njemačkoj (u prosjeku 3 932 109 osoba godišnje od 2008. do 2018. godine) i Španjolskoj (u prosjeku 3 799 454 osoba u istom promatranom razdoblju).

S druge strane, najmanji broj osoba koje su privremeno zaposlene vidljiv je prema podacima iz tablice u Malti i to u prosjeku 9 436 osoba godišnje od 2008. do 2018. godine te u Luksemburgu, u prosjeku 16,1 tisuća ljudi godišnje u istom promatranom razdoblju. Jedna od pretpostavki zbog čega su te brojke niske je ta da je veći udio osoba koje su na tržištu rada u stalnom radnom odnosu u analiziranim državama.

Ako se uzme u obzir prosječna vrijednost privremeno zaposlenih osoba u razdoblju između 2008. do 2018. godine, primjetno je povećanje broja osoba s takvim ugovornim angažmanima nakon 2014. godine s rastućim trendom, što ukazuje na povećanje fleksibilnosti tržišta rada.

6.2.2.3. Neformalna zaposlenost

Neformalni rad ubraja se u sivu ekonomiju koja se definira kao obavljanje ekonomskih aktivnosti mimo zakonskih regulativa. Može se reći da se dio gospodarstva koji se naziva neformalnim sastoji od djelatnosti koje imaju tržišnu vrijednost, ali nisu formalno registrirane. Međunarodna organizacija rada procjenjuje da oko 2 milijarde radnika, odnosno preko 60 posto svjetske odrasle radne snage, radi u neformalnom sektoru – barem na pola radnog vremena.

Neformalna ekonomija je globalni fenomen, ali postoje velike varijacije unutar i među zemljama. Jednako tako, neformalnu ekonomiju je teško izmjeriti. To je iz razloga što se aktivnosti unutar nje ne mogu izravno promatrati, a većinom se ne žele uzeti u obzir sudionici neformalne ekonomije. Međutim, važno je pokušati izmjeriti veličinu neformalne ekonomije zbog njezine važnosti, ali i zbog toga što zapošljava neke od najranjivijih ljudi u svijetu.

Kulušić (2009: 96) navodi kako neformalna zaposlenost predstavlja oblik eksterne kvantitativne fleksibilnosti.

Mehanizmi primjene radnog prava morali bi biti dostatni da osiguraju dobro funkcioniranje i prilagodljiva tržišta rada, spriječe zlouporabu radnoga prava na nacionalnoj razini i očuvaju prava radnika na europskom tržištu rada koje je u nastajanju. U ovom kontekstu, neprijavljeni rad je osobito zabrinjavajuća i tajna pojava na današnjim tržištima rada, često povezan s prekograničnim kretanjem radne snage. Smatrajući neprijavljeni rad glavnim čimbenikom socijalnog *dampinga*, ističe se korelacija između neprijavljenog rada i odgovornosti, ne samo za eksploataciju radnika, nego i za narušavanje kompetitivnosti. (Commission of the European Communities, 2006: 14)

6.2.2.4. Prekidi karijera

Prekidi karijera, ponekad nazivani i prekidima zaposlenja, prema Kulušić (2009: 98), oblik su unutarnje kvalitativne fleksibilnosti, a u stvarnosti predstavljaju dulja razdoblja izbivanja – obično neplaćenog – od pet ili više godina. Radnici mogu koristiti prekide u karijeri kao priliku za rad na promjeni karijere bez pritiska da se nakon nekoliko mjeseci moraju vratiti na stari posao, kao što je to slučaj vezan uz *sabbaticals.*

Sabbaticals su poseban oblik prekida karijere. Unutar tvrtke može postojati »sabbatical politika«, prema kojoj zaposlenici mogu uzeti dogovorenu količinu slobodnog vremena. Dopušteno vrijeme ovisi o tvrtki i ne mora uvijek biti dostupno svim zaposlenicima, nego je to u nekim slučajevima povlastica za radnike na određenoj razini u organizaciji, kao što su viši menadžeri ili osoblje s punim radnim vremenom. Neke tvrtke koriste *sabbaticals* kako bi nagradile svoje radnike što može imati multiplikativan učinak za samu tvrtku u vidu dobrobiti i za poslodavce i za radnike. Radnici nakon korištenja spomenutog instituta budu odmorniji te umnogome produktivniji.

Carr i Li-Ping Tang (2005: 160) navode kako korištenje *sabbaticalsa* kao sredstva za poboljšanje motivacije i morala zaposlenika ubrzano raste jer tvrtke traže načine da zadrže svoje radnike-zvijezde i mehanizme kako se boriti s posljedicama izgaranja na poslu.

Dakako, postoje i negativne strane korištenja prekida karijere. One se ponajprije ogledaju u gubljenju statusa po povratku radnika te gubitka prihoda zato što poslodavac nije obvezatan isplatiti naknadu u bilo kojem obliku za vrijeme trajanja prekida karijere.

6.2.2.5. Fleksibilno umirovljenje

Na umirovljenje se tradicionalno gleda kao na trajni prestanak rada. Međutim, stavovi prema umirovljenju se mijenjaju i umirovljenje više ne mora biti situacija u kojoj ljudi u jednom danu prelaze s posla u mirovinu. Sa stajališta pojedinca, fleksibilno umirovljenje s glatkim prijelazom radnicima je sve privlačnije.

Fleksibilno umirovljenje, kako navodi Blanpain (1995: 231), jedan je od oblika fleksibilnosti tržišta rada koji je u europsko socijalno pravo uveden preporukom Vijeća kojom se poziva države članice da obznane mogućnost fleksibilnog umirovljenja kao jednog od sredstava socijalne politike, odnosno mogućnost da zaposleni sami odaberu kada žele ići u mirovinu.

Biti fleksibilno umirovljen znači da je radnik u mogućnosti prilagoditi svoj radni vijek prema vlastitim željama i okolnostima.

Van Vuuren (2013: 573) navodi kako se takva prilagodba može dogoditi na intenzivnoj margini (radni sati) ili na ekstenzivnoj margini ((ne) povlačenju s tržišta rada). Niske mirovinske naknade mogu se nadoknaditi višom dobi za umirovljenje. Općenito, povrat na imovinu te demografski i zdravstveni rizici mogu se zaštititi ponudom radne snage pojedinca.

Kulušić (2009: 100) ističe kako preporuka sugerira i utvrđivanje posebnih pripremnih programa za umirovljenje s kojima se započinje godinu dana prije nastupa umirovljenja, uz sudjelovanje socijalnih partnera – predstavnika poslodavaca i radnika te drugih zainteresiranih tijela.

Učur (2000: 137) navodi kako se u okvirima reformi mirovinskih sustava poduzimanih u europskim državama pojavljuje više oblika fleksibilnog umirovljenja kao što su: veća fleksibilnost za godine umirovljenja i promicanje postupnog umirovljenja, poticanje produljenja razdoblja plaćanja doprinosa i slobode kombinacija mirovine s dohotkom od rada.

Djelomično ili postupno umirovljenje omogućuje starijim zaposlenicima da postupno smanje radno opterećenje prije odlaska u mirovinu umjesto da njihov radni vijek odjednom bude potpuno prekinut. Time im se pruža prilika da se prilagode novim obrascima rada i umirovljenja.

6.2.3. Fleksibilnost radnog vremena

Oblik fleksibilnosti poznat kao vremenska fleksibilnost, prema Goudswaardu i de Nantieulu (2000: 28), kombinira kako interne, tako i kvantitativne varijable fleksibilnosti. „Fleksibilnost radnog vremena, s obzirom na učestalost primjene toga modela, može se okarakterizirati kao najkorišteniji oblik fleksibilnosti. Istraživanja Europske zaklade za unaprjeđenje uvjeta života

i rada[37] pokazala su da u svim sektorima industrije, kao i u svim uslugama, poduzeća koriste različite oblike fleksibilnog radnog vremena, bilo da je riječ o smjenskom radu, radu s nepunim radnim vremenom, noćnom radu ili radu tijekom vikenda, prekovremenom radu, sabijenom radnom tjednu, promjenjivom radnom vremenu i drugim oblicima te pravima radnika po toj osnovi, uključujući pravo na stanku, dnevni i tjedni odmor te godišnji odmor." (Kulušić: 2009: 60)

6.2.3.1. Rad s nepunim radnim vremenom

Rad s nepunim radnim vremenom je fleksibilan radni aranžman koji podrazumijeva rad koji je u konačnici vremenski uvijek manji od punog radnog vremena. Zaposlenici se obično smatraju zaposlenima s nepunim radnim vremenom ako rade manje od 30 sati tjedno, što nerijetko znači da rade manje dana u radnom tjednu. U literaturi se može pronaći i podatak da se rad s nepunim radnim vremenom smatra svaki koji iznosi manje od 35 sati tjedno do marginalnih 15 sati tjedno. Zaposlenici s nepunim radnim vremenom ostvaruju ista prava na zaposlenje kao i radnici s punim radnim vremenom.

Zaposlenici na nepuno radno vrijeme obično uključuju studente, mame i tate, umirovljenike, ljude koji žele pokrenuti vlastiti posao i trebaju više vremena i druge radnike koji ne žele ili ne trebaju puno radno vrijeme. Neki radnici također mogu imati dva ili čak više poslova s nepunim radnim vremenom, umjesto jednog radnog mjesta na puno radno vrijeme u jednoj organizaciji. Razlog što neki ljudi radije rade na nepuno radno vrijeme može biti to što takav oblik rada uključuje više vremena za roditeljske obveze. Jednako tako, osobe koje rade na nepuno radno vrijeme mogu se dodatno posvetiti radu na vlastitim poslovnim pothvatima ili to vrijeme iskoristiti kako bi završili školovanje. Manje rada također može pomoći u smanjenju stresa i ponuditi bolju ravnotežu između posla i života.

Wojčák i Baráth (2017a: 74) navode kako se posao s nepunim radnim vremenom definira i kao rad s manjim rasponom sati rada u unaprijed definiranom okruženju, za razliku od rada s punim radnim vremenom. Isti se pokazao kao jedan od najčešćih fleksibilnih oblika radnog aranžmana. Fernández-Kranz, Paul i Rodríguez-Planas (2015: 512) ističu kako je, za razliku od privremenog zapošljavanja koje je ravnomjerno raspoređeno po spolovima, rad na nepuno radno vrijeme uglavnom oblik zaposlenja u kojem je većinski udio žena, koji se kreće u rasponu od 65 % u Grčkoj do 90 % u Nizozemskoj.

[37] engl. *European Foundation for the Improvement of Living and Working Conditions*

U kontekstu radnoga prava Europske unije, prema Kulušić (2009: 64), rad s nepunim radnim vremenom uređen je poglavito Direktivom o radu s nepunim radnim vremenom. Rad s nepunim radnim vremenom, prema odredbi čl. 3. Direktive 97/81/EC, definira se kao rad radnika koji ima normalan, redoviti broj sati, izračunatih na tjednoj bazi ili prosječni kroz razdoblje za koje je radnik zaposlen do godine dana, manje od normalnog redovitog broja radnih sati usporedivog radnika s punim radnim vremenom.

U tablici 17. prikazana je zaposlenost s nepunim radnim vremenom kao postotak od ukupne zaposlenosti na razini Europske unije u razdoblju od 2008. do 2018. godine. Podaci se odnose na populaciju starosti od 20. do 64. godine.

Tablica 17. Zaposlenost s nepunim radnim vremenom kao postotak od ukupne zaposlenosti na razini Europske unije u razdoblju od 2008. do 2018. godine

(podaci prikazani u %)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	x̄
EU-28	**16,8**	**17,3**	**17,9**	**18,2**	**18,6**	**19,0**	**19,0**	**19,0**	**18,9**	**18,7**	**18,5**	**18,4**
Austrija	23,2	24,4	24,9	25,0	25,7	26,5	27,4	27,7	28,2	28,2	27,6	26,3
Belgija	22,2	23,0	23,4	24,4	24,5	24,1	23,5	24,1	24,4	24,2	24,0	23,8
Bugarska	2,0	2,1	2,2	2,1	2,2	2,5	2,4	2,2	1,9	2,1	1,8	2,1
Cipar	6,5	7,3	8,1	8,7	9,4	11,7	13,3	12,9	13,3	12,1	10,6	10,4
Češka	4,2	4,7	5,1	4,6	4,9	5,7	5,4	5,2	5,6	6,0	6,2	5,2
Danska	19,5	21,1	21,2	20,7	20,5	20,7	20,6	20,4	21,6	21,3	20,7	20,8
Estonija	6,2	9,2	9,6	9,1	9,0	8,7	8,2	9,2	9,5	9,2	10,5	8,9
Finska	11,2	11,9	12,5	12,7	12,7	12,5	12,7	12,7	13,5	13,5	13,6	12,7
Francuska	16,7	17,1	17,5	17,5	17,6	18,0	18,5	18,3	18,2	18,1	17,8	17,8
Grčka	5,3	5,7	6,1	6,6	7,6	8,3	9,2	9,3	9,7	9,6	9,0	7,9
Hrvatska	6,4	6,4	7,0	7,0	5,6	5,4	5,2	5,9	5,6	4,8	4,9	5,8
Irska	16,9	19,8	21,0	22,1	22,4	22,5	21,7	20,9	20,3	18,6	18,1	20,4
Italija	14,0	14,0	14,7	15,2	16,7	17,6	18,0	18,2	18,5	18,5	18,3	16,7
Latvija	5,6	7,9	9,2	8,7	8,8	7,4	6,7	7,1	8,3	7,5	7,1	7,7
Litva	6,4	7,8	7,7	8,3	8,8	8,2	8,5	7,6	7,1	7,4	6,9	7,7
Luksemburg	18,0	17,5	17,4	17,9	18,3	18,5	18,3	17,9	18,9	19,4	17,5	18,1
Mađarska	4,3	5,2	5,5	6,4	6,7	6,4	6,0	5,7	4,8	4,3	4,2	5,4

Malta	10,4	10,2	10,7	11,5	12,2	13,1	14,5	13,5	13,1	12,8	12,3	12,2
Nizozemska	43,0	43,9	45,1	45,4	46,1	46,9	46,6	46,9	46,6	46,6	46,8	45,8
Njemačka	25,2	25,5	25,7	25,9	25,9	26,7	26,6	26,8	26,8	26,9	26,8	26,3
Poljska	7,4	7,3	7,3	7,0	6,9	6,9	6,8	6,6	6,2	6,3	6,2	6,8
Portugal	8,7	8,4	8,4	10,1	11,0	10,8	9,9	9,6	9,2	8,6	7,8	9,3
Rumunjska	8,2	8,2	9,6	9,1	9,0	8,8	8,5	8,4	7,2	6,5	6,3	8,2
Slovačka	2,5	3,4	3,7	3,9	3,9	4,5	5,0	5,7	5,7	5,7	4,8	4,4
Slovenija	7,2	8,6	9,2	8,6	8,5	8,5	9,2	9,3	8,9	9,6	9,1	8,8
Španjolska	11,3	12,1	12,7	13,2	14,2	15,5	15,6	15,5	14,9	14,6	14,2	14,0
Švedska	24,3	24,6	24,5	23,9	23,8	23,4	23,3	23,0	22,6	21,9	21,2	23,3
Ujedinjeno Kraljevstvo	22,5	23,3	24,1	24,1	24,5	24,2	24,0	23,8	23,8	23,6	23,3	23,7
$\bar{x}$	12,8	13,6	14,1	14,3	14,6	14,8	14,8	14,8	14,8	14,6	14,2	

Izvor: izrada autorice prema podacima s Eurostata (2021_d).

Ako se promotre postoci prikazani u tablici 17., interesantan je podatak da je zaposlenost s nepunim radnim vremenom u Nizozemskoj u prosjeku 45,8 % od ukupne zaposlenosti u promatranih jedanaest godina. U Austriji i Njemačkoj je zaposlenost s nepunim radnim vremenom također visoka te u prosjeku iznosi 26,3 % od ukupne zaposlenosti u promatranih jedanaest godina, dok, s druge strane, Slovačka ima najniži postotak zaposlenosti s nepunim radnim vremenom koji je bio najniži u 2008. godini, a iznosio je 2,5 % od ukupne zaposlenosti te je u zadnjoj promatranoj 2018. godini viši za 1,9 postotna boda.

Ako se analiziraju podaci u tablici vezani uz prosječne vrijednosti zaposlenih s nepunim radnim vremenom po godinama, primjetan je porast njihovog udjela izražen u postotku u ukupno zaposlenima sve do 2014. godine, nakon čega stagnira do 2016. godine. U 2016. godini vidljiv je postepeni pad zaposlenih s nepunim radnim vremenom, što se može obrazložiti činjenicom da na tržištu rada nakon 2016. dolazi do disperzije fleksibilnih oblika ugovora o radu te pojave novih fleksibilnih oblik rada i zanimanja, kao što je primjerice *freelancer*.

6.2.3.2. Prekovremeni rad

Prekovremeni rad podrazumijeva rad koji uključuje sve dodatne sate koji uobičajeno nisu predviđeni u okviru radnog vremena - tjedno ograničenje iznosi 40 sati.

Prekovremeni sati su u određenoj mjeri regulirani direktivama o radnom vremenu ili zakonima, koji se razlikuju od zemlje do zemlje, ali općenito imaju za cilj zaštitu zaposlenika od

zlostavljanja. Temeljno pravno vrelo u Europskoj zajednici za institut prekovremenog rada, kojim se uspostavljaju ograničenja i pravila za primjenu toga instituta, prema Kulušić (2009: 69), jest Direktiva o određenim aspektima organizacije radnog vremena. U državama EU-a, uređeni sustav prekovremenoga rada imanentniji je radnicima plaćenim po satu nego radnicima na plaću.

Prekovremeni rad može se pokazati korisnim za poslodavce i zaposlenike. Upravljanje prekovremenim radom na fluktuirajućim tržištima također može biti važan izvor konkurentske prednosti ako se radi strateški i imajući na umu produktivnost.

Kao nedostaci prekovremenog rada ističu se niža produktivnost, zakonodavni izazovi te mogući zdravstveni problemi zaposlenika. „Rad zaposlenika u produženom radnom vremenu, za koji su posebno, dodatno plaćeni, ali tijekom kojeg zbog umora ispoljavaju značajno manji radni učinak, dovodi do toga da takav rad nije za vlasnika ili menadžment koristan niti isplativ. U konačnici, vlasnik ili menadžment ljudskih potencijala prisiljen je ukinuti prekovremeni rad i zaposliti nove radnike.“ (Požega, 2012: 262-263)

6.2.3.3. Rad nedjeljom

Rad nedjeljom je svaki rad u kojem relevantna smjena počinje nedjeljom i gdje se veći dio te smjene obavlja tijekom nedjelje.

Slijedeći klasifikaciju fleksibilnosti, prema Kulušić (2009: 72), institut rada nedjeljom svrstava se među oblike unutarnje, kvantitativne fleksibilnosti, poput prekovremenog rada i varijabilnog dnevnog i tjednog radnog vremena. Tijekom posljednjih desetljeća, broj zaposlenika koji rade fleksibilno kao što je, primjerice, večernji rad i rad subotom i nedjeljom, znatno se povećao, navode Wirtz, Nachreiner i Rolfes (2011: 361). Iako je rad subotom prilično čest, česte su i rasprave o produženju postojećih dozvola za rad nedjeljom u Europskoj uniji.

Međutim, rad vikendom može smanjiti i vrijeme oporavka i količinu društveno vrijednih sati. Kivimäki i suautori (2006: 402) navode kako nedovoljan oporavak vikendom može povećati rizik od kardiovaskularne smrti, a druga oštećenja zdravlja mogu također biti potaknuta nedostatkom dovoljnog oporavka.

U tablici 18. prikazane su zaposlene osobe koje rade nedjeljom kao postotak od ukupne zaposlenosti na razini Europske unije u razdoblju od 2008. do 2018. godine. Podaci se odnose na žensku i mušku populaciju od 20. do 64. godine.

Tablica 18. Zaposlene osobe koje rade nedjeljom kao postotak od ukupne zaposlenosti na razini Europske unije u razdoblju od 2008. do 2018. godine

(podaci prikazani u %)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	x̄
EU-28	**13,4**	**12,9**	**13,4**	**13,5**	**14,4**	**14,3**	**14,4**	**14,4**	**14,4**	**14,1**	**13,8**	**13,9**
Austrija	16,7	16,7	16,4	16,3	16,0	15,7	15,9	15,4	15,7	15,4	15,1	15,9
Belgija	10,4	10,3	10,3	11,1	11,2	11,9	12,2	12,1	12,1	12,4	11,9	11,4
Bugarska	11,3	9,7	8,6	8,1	8,9	9,2	8,9	9,0	7,7	8,5	7,7	8,9
Cipar	6,9	7,4	9,2	10,4	11,7	13,5	15,5	15,9	15,3	14,9	14,5	12,3
Češka	14,6	13,0	13,8	14,7	13,8	12,7	12,2	12,8	12,1	11,8	11,3	13,0
Danska	15,2	14,7	15,1	16,3	15,8	17,3	16,4	15,5	15,4	13,7	13,1	15,3
Estonija	10,7	12,3	14,1	13,8	14,7	14,5	15,6	14,2	16,5	16,2	15,8	14,4
Finska	15,9	15,6	15,8	15,8	16,4	17,2	17,3	17,2	17,9	17,0	17,0	16,6
Francuska	13,7	13,9	14,6	14,6	14,9	14,4	14,1	14,4	14,6	14,5	14,6	14,4
Grčka	11,0	13,7	15,3	15,6	15,9	16,8	17,6	18,5	18,9	17,4	16,7	16,1
Hrvatska	10,0	9,5	9,9	10,4	9,0	7,8	7,4	8,5	7,6	6,1	6,4	8,4
Irska	13,5	14,4	16,4	16,4	18,8	19,4	19,6	19,2	18,8	19,2	20,4	17,8
Italija	13,2	12,5	12,8	12,6	13,5	13,6	14,0	14,4	14,7	15,2	15,3	13,8
Latvija	12,4	13,8	13,7	14,7	13,5	12,8	12,3	13,8	14,2	11,6	10,9	13,1
Litva	11,3	12,5	12,4	12,7	13,2	14,0	14,9	11,7	12,6	11,2	9,6	12,4
Luksemburg	12,1	9,4	8,9	9,1	7,9	8,5	9,9	10,2	10,1	8,9	10,6	9,6
Mađarska	6,7	7,2	8,1	8,6	8,4	7,9	7,0	6,0	6,2	6,3	6,1	7,1
Malta	15,0	14,5	15,7	15,3	16,0	16,2	15,6	14,4	13,9	14,5	14,9	15,1
Nizozemska	17,6	18,6	17,6	17,8	18,1	19,1	19,1	19,0	19,7	20,3	19,8	18,8
Njemačka	14,1	13,1	14,0	14,5	14,3	14,1	14,2	14,3	14,3	13,2	13,0	13,9
Poljska	9,2	8,7	8,2	7,8	8,4	8,2	7,6	7,1	6,8	6,5	5,7	7,7
Portugal	12,4	11,7	11,4	4,0	4,2	4,8	4,7	4,2	4,6	4,7	4,8	6,5
Rumunjska	16,9	17,4	17,5	17,2	17,3	16,4	15,9	14,0	13,4	13,4	13,2	15,7
Slovačka	19,9	18,6	18,4	19,6	19,2	19,3	19,3	19,7	18,7	17,2	16,2	18,7
Slovenija	14,1	14,2	15,0	14,0	13,6	13,6	14,4	14,2	13,1	13,1	12,4	13,8
Španjolska	13,8	14,7	15,5	16,0	16,5	16,0	17,3	17,9	17,5	17,2	17,8	16,4
Švedska	11,9	12,2	12,5	12,6	12,7	13,3	13,2	13,2	12,9	12,3	12,0	12,6
Ujedinjeno Kraljevstvo	-	10,5	11,4	12,2	18,1	18,1	18,5	17,9	18,1	17,9	17,3	14,5

$\bar{x}$	13,0	12,9	13,3	13,3	13,6	13,8	14,0	13,7	13,7	13,2	13,0

Izvor: izrada autorice prema podacima s Eurostata (2021_a).

Prema postocima na razini EU-28, prikazanima u tablici 18., prosječno 13,9 % osoba koje su zaposlene rade nedjeljom. Zanimljivo je istaknuti da je najveći postotak osoba koje su zaposlene i rade nedjeljom u Nizozemskoj u prosjeku 18,8 % od ukupne zaposlenosti u promatranih jedanaest godina te u Slovačkoj u prosjeku 18,7 % od ukupne zaposlenosti u promatranom razdoblju.

Ako se uzme u obzir prosječna vrijednost zaposlenih osoba koje rade nedjeljom u razdoblju između 2008. do 2018. godine, primjetan je raspon njihova udjela u ukupnoj zaposlenosti s konstantnim oscilacijama u okviru 1,1 postotnog boda, točnije od 12,9 % do 14 % u 2014. godini, što je za 0,1 postotna boda više nego prosječna vrijednost na razini EU-28.

6.2.3.4. Dijeljenje radnog mjesta

Dijeljenje radnog mjesta fleksibilni je oblik rada u kojem se posao s punim radnim vremenom dijeli između dviju osoba, od kojih je svaka odgovorna za uspjeh cjelokupnog posla. Podjela posla osigurava angažiranom osoblju dijeljenje odgovornosti jednog radnog mjesta s punim radnim vremenom, obično s razmjernom plaćom i plaćenim slobodnim vremenom. Kreativni i inovativni rasporedi mogu se osmisliti kako bi zadovoljili potrebe onih koji dijele posao i odjela. Aranžmani podjele poslova mogu biti 50/50, 60/40 ili bilo koja slična kombinacija. Rasporedi se također mogu preklapati prema potrebi ili želji. Djelatnici će raditi zajedno dio tjedna ili mjesec dana i više, s tim da nije nužno da, po završetku posla, moraju ponovno raditi zajedno. Oni djelatnici koji dijele posao moraju odrediti hoće li svaki od njih biti odgovoran za položaj u različito vrijeme ili će svaki biti odgovoran za različite zadatke.

Za poslodavce je ključna prednost to što uvijek imaju radnika na radnom mjestu te mogu ponuditi fleksibilnost posla potrebnu za zadržavanje dobrih radnika. Za zaposlenike veća fleksibilnost može dovesti do bolje ravnoteže između posla i života i većeg zadovoljstva poslom.

Crampton i suautori (2003: 21) navode kako su u ovom slučaju plaća i beneficije radnika s punim radnim vremenom podijeljeni između dvaju djelitelja posla, za razliku od radnika s nepunim radnim vremenom koji obično ne uživaju takve beneficije, kao što su godišnji odmor, podjela dobiti itd. Koristi od dijeljenja radnog mjesta ogledaju se i u boljem odlučivanju i

kvaliteti obavljenog posla. Jednako tako, ako više od jednog pojedinca sudjeluje u radnim zadacima, vjerojatnije je da će se pogreške i problemi prije identificirati.

Bušelić (2017: 124-125) navodi kako su u praksi poznata dva načina dijeljenja posla: „model blizanaca“ i „model otoka“. Rad naziva „model blizanaca“ zahtijeva da zaposlenici dijele posao, što znači da zajednički rade na istom projektu (svaki od njih pola radnog vremena). Dijeljenje posla se najčešće nudi starijim zaposlenicima, što može pomoći da svojom stručnošću i iskustvom podučavaju i daju institucionalno znanje svojim manje iskusnim kolegama. Nasuprot tome, u „modelu otoka“ zaposlenici rade neovisno jedan o drugome na različitim vrstama posla. Autorica naglašava kako ovi nezavisni stručnjaci koji imaju komplementarne vještine mogu za poslodavca biti najbolje rješenje. Pojedini poslodavci zapošljavaju radnike sa skraćenim radnim vremenom kako bi uštedjeli. S druge strane, zapošljavanje sa skraćenim radnim vremenom omogućava poslodavcu prepoznati kvalitetu i sposobnost zaposlenika prije nego što ga zaposli na puno radno vrijeme.

6.2.3.5. Skraćeni (sažeti) radni tjedan

„Skraćeni (sažeti) radni tjedan još je jedan u nizu mogućnosti koje poduzeća pružaju svojim zaposlenicima u svrhu povećanja motivacije.“ (Požega, 2012: 164)

Kraći radni tjedan obično znači da su zaposlenici u uredu četiri dana tjedno, umjesto uobičajenih pet. Mnoge tvrtke imaju četverodnevne tjedne u kojima zaposlenici rade dulje od 10 sati te time još uvijek dobivaju punih 40 sati tjedno. Ali istinski skraćeni radni tjedan skraćuje radno vrijeme, često na 32 sata tjedno za zaposlene s punim radnim vremenom. Time zaposlenici i dalje dobivaju punu plaću, ali ulažu manje sati da bi istu zaradili.

Za radnike, skraćeni radni tjedan pruža veću ravnotežu između posla i privatnog života - zaposlenici time imaju dodatni dan koji mogu provesti sa svojim obiteljima. Poboljšana ravnoteža između posla i privatnog života i više slobodnog vremena čine zaposlenike sretnijima, što može poboljšati zadovoljstvo poslom i lojalnost zaposlenika te njihovu produktivnost. Skraćeni radni tjedan financijska je prednost za zaposlenike jer jedan dan manje putovanja znači uštedu na benzinu i smanjenje troškova za održavanja vozila.

Iz perspektive tvrtke, skraćeni radni tjedan smanjuje troškove tvrtke jer se zatvaranjem ureda jedan dodatni dan smanjuju operativni troškovi kao što su potrošnja struje i vode. Jednako tako, smanjuje se korištenje uredske opreme. Skraćeni radni tjedan može privući više kandidata, što odjelu za ljudske potencijale daje više mogućnosti kod zapošljavanja.

Povrh svega navedenog, skraćeni radni tjedan pogoduje okolišu. Jedan dan manje rada u uredu i dolaska zaposlenika na posao smanjuje emisije ugljika.

6.2.3.6. Smjenski rad

Međunarodna organizacija rada definira smjenski rad kao način organizacije radnog vremena u kojem se radnici izmjenjuju na radnom mjestu tako da ustanova može raditi duže od radnog vremena pojedinih radnika u različitim dnevnim i noćnim satima.

Smjenski rad, prema Parent-Thirion i suautorima (2007: 22), predstavlja jedan od oblika unutarnje, kvantitativne fleksibilnosti koji se često uvodi u organizacijama s proizvodnim procesima koji, zbog tehničkih ili ekonomskih razloga, moraju raditi dulje razdoblje ili čak neprestano. Smjenski je rad također uobičajen tamo gdje se usluge pružaju dugotrajno ili neprestano. Isti može smanjiti jedinične troškove, osigurati fleksibilnost i može osigurati višu zaradu radnicima, ali može također poremetiti društveni i obiteljski život radnika te dovesti do poremećaja spavanja.

Pojam smjenskog rada odnosi se na svaki radni raspored koji je izvan radnog vremena od 7 do 18 sati. Rad u smjenama može uključivati večernje, noćne i ranojutarnje smjene, kao i fiksni ili rotirajući raspored. Mnoga smjenska radna mjesta slijede fiksni raspored s istim vremenom početka i završetka za svaku smjenu, kao i istim radnim danima tijekom tjedna. Rotirajući raspored, s druge strane, može uključivati različita vremena smjena i/ili različite radne dane koji se razlikuju od tjedna do tjedna. Rotirajuće smjene mogu biti teže od fiksnih smjena jer zahtijevaju od radnika da prilagođavaju svoj raspored svaki tjedan ili svaki mjesec.

Svaka država članica Europske unije obvezna je donijeti svoje nacionalne zakone i definirati specifičnosti, koristeći Europsku direktivu o radnom vremenu (EWTD) kao opću smjernicu.

Glavna svrha Europske direktive o radnom vremenu je zaštita zdravlja i sigurnosti zaposlenika. Previše radnih sati i nedovoljno vremena za odmor dokazano dovode do sagorijevanja, depresije, bolesti i toksičnog stresa. Direktiva na taj način štiti i poslodavce, budući da bi dugoročni cilj svakog poslodavca trebao biti zdravi, odmorni i posljedično produktivni zaposlenici.

6.2.3.7. Godišnje radno vrijeme

Godišnje radno vrijeme sastoji se od raspodjele ukupnog broja radnih sati osoblja tijekom cijele godine, poštujući neke granice i pravila utvrđena zakonom i kolektivnim ugovorom.

Prema OECD-u (2022), prosječni godišnji radni sati definiraju se kao ukupan broj stvarno odrađenih sati godišnje podijeljen s prosječnim brojem zaposlenih godišnje. Stvarno odrađeni sati uključuju redovno radno vrijeme radnika s punim i nepunim radnim vremenom, plaćene i neplaćene prekovremene sate, sate odrađene na dodatnim poslovima, a isključuje neradno vrijeme zbog: državnih praznika, godišnjih plaćenih odmora, bolesti, ozljeda i privremenih nesposobnosti, rodiljnih dopusta, roditeljskih dopusta, školovanja ili osposobljavanja, zastoja u radu iz tehničkih ili ekonomskih razloga, štrajka ili radnih sporova, lošeg vremena i drugih razloga.

Corominas, Lusa i Pastor (2005: 10) navode kako godišnje radno vrijeme pruža veliku fleksibilnost proizvodnom sustavu pa je poduzeću omogućeno učinkovitije planiranje radnog vremena osoblja. Sustav godišnjeg radnog vremena, prema Kulušić (2009: 81), obično se smatra prihvatljivim zbog nekog od sljedećih razloga: kao pomoć smanjenju broja radnih sati, radi ukidanja, smanjenja ili nadzora prekovremenog rada, usklađenja sa sezonskim varijacijama ili drugim vrhuncima i padovima potražnje, radi maksimiziranja produktivnosti i učinkovitosti te uvođenja tehnoloških promjena, kao i harmoniziranja uvjeta zapošljavanja i rada.

6.2.4. Fleksibilnost organizacije rada

Promjene u organizaciji rada, prema Lowtheru (2003: 462), potrebne su zbog tehnoloških promjena, potražnje visokokvalitetnih proizvoda i usluga, sve veće globalne konkurencije i obrazovanije radne snage.

Parent-Thirion i suautori (2007: 52) ističu kako ovaj oblik fleksibilnosti, koji se u teoriji klasificira kao „funkcionalna fleksibilnost“, kombinira interne i kvalitativne varijable fleksibilnosti i određuje se kao *differentia specifica* novih oblika organizacije rada u odnosu na tradicionalne.

Kulušić (2009: 83) navodi kako je fleksibilnost organizacije rada često korišten oblik fleksibilnosti, osobito u vidu rotiranja radnih mjesta, kombinacije radnih zadaća, timskog rada, podugovaranja, fleksibilnih radnih mjesta, geografske mobilnosti, polivalentnih radnih vještina, dijeljenja radnih mjesta i drugih, manje zastupljenih oblika.

6.2.4.1. Fleksibilna mjesta rada

Za razliku od tradicionalnih ureda s fiksnim i dodijeljenim radnim mjestima, radnici s fleksibilnim mjestom rada mogu odabrati mjesto rada i područje u kojem će smjestiti svoj ured

na način koji najbolje odgovara vrsti posla kojeg u tom trenutku treba obaviti. Šribar (2005: 58) navodi kako, zahvaljujući izuzetnom napretku tehnologija prijenosa podataka u raznim oblicima uz umrežavanje korisnika podataka, fleksibilna mjesta rada pružaju nove mogućnosti rada u prostoru koji nije prostor poslodavca, odnosno prostor korisnika rada druge osobe, otvarajući ove mogućnosti podjednako radnicima koji rade za poznatog poslodavca kao i, tzv. slobodnjacima – *freelancerima* koji rade za nepoznatog korisnika kojemu se putem interneta nude usluge ili materijalni uradci.

Baitenizov i suautori (2019) navode kako *freelancer* može poslovati kao samozaposlena registrirana osoba ili raditi u »sivoj zoni ekonomije«. Prema Floridi (2002), *freelanceri* su predstavnici kreativne klase samozaposlenih neovisnih stručnjaka s općenito visokim intelektualnim potencijalom i aktivnim korištenjem suvremenih informacijskih, komunikacijskih i drugih tehnologija.

Među najčešćim oblicima fleksibilnosti mjesta rada, prema Kulušić (2009: 84), su izmještanje radnika,[38] rad na izdvojenome mjestu, odnosno kod kuće, tzv. *teleworking*, a radnici koji su zaposleni na takav način su „*teleworkers*, *homeworkers* i *outworkers*."

6.2.4.2. Rad na izdvojenome mjestu rada

Rad na izdvojenome mjestu rada je vrsta posla i/ili pružanja usluga koji se obavljaju na daljinu i *online* korištenjem računalne i telematske tehnologije.

Kriza uzrokovana pandemijom stvorila je iznenadnu potrebu da tvrtke i njihovi zaposlenici počnu ili povećaju rad na daljinu. Olakšavanjem rada na izdvojenom mjestu rada, informacijske i komunikacijske tehnologije bile su ključne u omogućavanju opstanka gospodarskih aktivnosti i omogućavanju značajnom dijelu pojedinaca da nastave zarađivati.

Tavares i suautori (2020: 334) pojašnjavaju kako je adaptacija na rad na daljinu u vrijeme pandemije bila laka ili vrlo laka te da se prilagodba na takav rad dogodila vrlo brzo. Glavne poteškoće s kojima su se pojedinci susreli bili su nedostatak profesionalne interakcije/komunikacije sa suradnicima, nedostatak resursa povezanih s infrastrukturom, poput interneta ili pisača te usklađivanje rada na daljinu s obiteljskim životom/kućanskim poslovima/posvećenošću djeci i upravljanje vremenom/rasporedom.

[38] engl. „*posting of workers*"

Prema Učuru (2005: 5), *teleworking* uključuje i radnike koji rade kod kuće, ali i radnike koji rad obavljaju na prostoru poslodavca no izvan njegova sjedišta, odnosno mobilne radnike, kao što su predstavnici prodaje i menadžeri koji provode određeni broj dana izvan ureda.

Bušelić (2017: 123) navodi kako rad od kuće predstavlja daljinski rad s fleksibilnim satima rada. U tim uvjetima poslodavci od radnika očekuju jednak angažman kao što je to u uredskom okruženju, očuvanje povjerljivih informacija, primjereni prostor kućnog ureda, vlasništvo nad opremom i praćenje rokova realizacije posla.

Rad od kuće zahtijeva od radnika ponekad i izravno prisustvo u kompaniji kao i pravo poslodavca da vrati zaposlenika raditi u kompaniju. Kako se sve više u društvu naglašava potreba usklađivanja radnog i privatnog života zbog toga sve više kompanija primjenjuje fleksibilne politike koje omogućavaju rad od kuće.

Sve je veći broj radnika na daljinu, što nije rezultat isključivo potrebe poslodavaca da se prilagode tržišnim zahtjevima, već se to događa zbog veće dostupnosti ICT proizvoda i brže internetske veze. (Wojčák i Baráth, 2017_b: 66)

6.2.4.3. Izmještanje radnika (posting of workers)

Izmještanje radnika je proces u kojem poslodavac šalje zaposlenika na privremeno obavljanje usluge u drugu državu članicu EU-a u kontekstu ugovora o uslugama, izmještanja unutar grupe ili zapošljavanja putem privremenih agencija.

Peraro (2017: 114) ističe kako je fenomen izmještanja radnika sve veći u zemljama članicama Europske unije i doprinosi razvoju unutarnjeg tržišta.

Maslauskaite (2014: 4) navodi kako je izmještanje radnika zapravo rezultat jedne od triju sloboda jedinstvenog tržišta, odnosno slobodnog prekograničnog pružanja usluga.

Prema European Commission (2022), izmješteni radnici u državi članici domaćinu ostaju samo privremeno i ne integriraju se na tržište rada odredišne članice.

U europskom radnom pravu, institut izmještanja radnika uređuje Direktiva 2018/957/EU nastala na temelju izmjene Direktive 96/71/EZ o upućivanju radnika u okviru pružanja usluga. Direktiva o izmještanju radnika propisuje obvezu država članica kojom one trebaju međusobno surađivati i javnosti omogućiti pristup informacijama o nacionalnim uvjetima zapošljavanja.

6.3. Fleksigurnost kao ravnoteža fleksibilnosti i sigurnosti na tržištu rada EU-a

Sigurnost, kao protuteža fleksibilnosti, znači više od sigurnosti zadržavanja posla - ona se odnosi na opremanje radnika vještinama koje će im omogućiti napredovanje tijekom radnoga vijeka te im pomoći u pronalaženju novoga zaposlenja. Sigurnost znači i niz prava, osobito primitaka primjerene visine za vrijeme razdoblja nezaposlenosti koji olakšavaju prijelaze te prilika za obrazovanje i usavršavanje za sve radnike, posebno za niskokvalificirane i starije. I radnici i poduzeća mogu imati koristi i od fleksibilnosti i od sigurnosti na tržištu rada, a takva se strategija koja objedinjuje oba pristupa naziva se fleksigurnost. (Commission of the European Communities, 2007: 5)

Pojam fleksigurnosti (engl. *flexicurity*) označava, između ostalog, integriranu strategiju za istovremeno povećanje fleksibilnosti i sigurnosti na tržištu rada. Pokušava pomiriti potrebu poslodavaca za fleksibilnom radnom snagom s potrebom radnika za sigurnošću.

Potočnjak (2012: 115) navodi kako fleksigurnost podrazumijeva:

- umjerenu zakonsku zaštitu zaposlenja
- visoku stopu učešća u cjeloživotnom učenju
- visoku potrošnju na mjere politike tržišta rada (aktivne i pasivne)
- izdašne primitke za slučaj nezaposlenosti uz ravnotežu prava i obveza
- široki obuhvat sustava socijalne sigurnosti
- visoke stope organiziranosti radnika u sindikate.

Tijekom proteklog desetljeća, a posebno od 2007. godine, Europska komisija sve je više primjenjivala koncept fleksigurnosti pri oblikovanju svojih propisa u okviru politika tržišta rada te je poticala države članice EU-a u razvijanju politika tržišta rada koje su u skladu s njezinom agendom fleksigurnosti. (Heyes, 2015: 643-644)

„Svaka država članica EU-a danas primjenjuje vlastiti set instituta i politika što rezultira određenim „stanjem fleksigurnosti“. Jednoznačna strategija ili smjer fleksigurnosti za sve zemlje ne postoji. Putokaz mogu biti smjernice (načela) fleksigurnosti koje je predložila Europska komisija.“ (Laleta i Bodiroga-Vukobrat, 2016: 40)

„Na temelju europske strategije Europa 2020. svaka zemlja članica mora ugraditi u svoje nacionalne strategije zapošljavanja glavne komponente fleksigurnosti i to:

- fleksibilne ugovorne i poslovne aranžmane
- cjelovite strategije cjeloživotnog učenja
- učinkovite aktivne politike zapošljavanja
- moderne sustave socijalne sigurnosti.“ (Bušelić, 2017: 139)

Kroz koncept fleksigurnosti zemlje bi osigurale veću konkurentnost gospodarstvima, čime bi posljedično rastao bruto domaći proizvod te bi se potaknulo zapošljavanje i sigurnost istog.
„Ključno obilježje fleksigurnosti jest razlikovanje između sigurnosti radnog mjesta i sigurnosti zaposlenja. Sigurnost radnog mjesta može se definirati kao ostajanje na istom radnom mjestu kod istog poslodavca u relativno dugom razdoblju (cjeloživotno zaposlenje). Takav pojam zamijenjen je pojmom sigurnosti zaposlenja koji znači sposobnost ostajanja u sigurnom zaposlenju tijekom cijele karijere neke osobe, ali ne nužno na istom radnom mjestu kod istog poslodavca. Moderno je tržište rada dinamično i „prijelazno“, obilježeno promjenama, pa tako i češćim promjenama radnog mjesta i poslodavca, kao i razdobljima kombinacije samozaposlenosti i ovisnog rada neke osobe.“ (Schmid, 2010: 101 navedeno u Laleta i Bodiroga-Vukobrat, 2016: 41)
Interes za fleksigurnost u početku je bio potaknut iskustvima Danske i Nizozemske tijekom 1990-ih. Nakon što su prethodno doživjele dugotrajno visoku nezaposlenost, čini se da su obje zemlje nakon toga uživale neke od najnižih stopa nezaposlenosti u Europi, zadržavajući relativno izdašne naknade za nezaposlenost. Navodni uzrok bio je pojačani naglasak na aktivnim mjerama na tržištu rada, u kombinaciji s umjerenom količinom zaštite zaposlenja. (Hastings & Heyes, 2016: 2-3)
Kod fleksigurnosti poseban interes je udovoljiti „zlatnom trokutu“ danskog tržišta rada, koji je kompromis između fleksibilnosti i sigurnosti, navodi Bušelić (2017: 140). Sukladno navedenom, jednu stranu trokuta karakterizira fleksibilnost zapošljavanja, druga strana predstavlja sigurnost nezaposlenih u vidu materijalnih naknada, dok treću stranu čine mjere aktivne politike zapošljavanja (poglavito edukacija nezaposlenih) na koje Danska troši 1,5 % svog BDP-a.

Slika 6. prikazuje »zlatni trokut« danskog tržišta rada. U modelu su prikazana tri stupa koje čini, kao što je prethodno navedeno, fleksibilno tržište rada, dobro koncipiran sustav socijalne sigurnosti te aktivna politika tržišta rada.

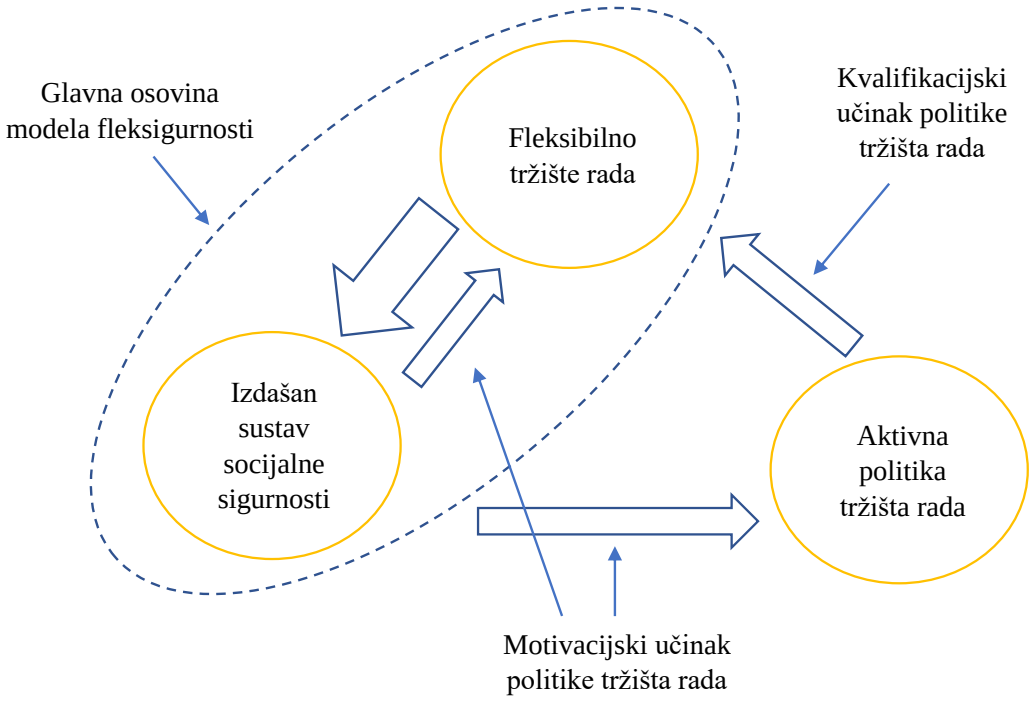

Slika 6. „Zlatni trokut" danskog tržišta rada
Izvor: izrada autorice prema Bredgaard, Flemming, & Madsen (2005: 6)

Slika 6. zorno prikazuje međuovisnost fleksibilnosti tržišta rada, uređenosti sustava socijalne sigurnosti te djelovanja aktivne politike tržišta rada. Na slici su istaknute silnice koje utječu te time pospješuju međudjelovanje navedenih faktora - aktivne politike tržišta rada imaju kvalifikacijski učinak na fleksibilnost tržišta rada omogućavajući sudionicima lakši i brži pristup tržištu rada te visokokvalitetno sudjelovanje na istom, dok dobro uređen sustav socijalne sigurnosti nudi motivacijski učinak te omogućava kako numeričku, tako i funkcionalnu fleksibilnost na tržištu rada.

Naknada za nezaposlenost, kao socijalna naknada u danskom modelu u slučajevima najnižih plaća, može iznositi 90 % prethodne plaće, navodi Bušelić (2017:140). U istom modelu naknada kao postotak prethodne plaće snižava se ovisno i o visini plaće. To je ujedno najveći postotak naknade prethodne plaće u Europi.

Strukturni aspekti danskog tržišta rada općenito su ispravni i pouzdani. To se odražava u rastućem strukturnom zapošljavanju i niskoj strukturnoj nezaposlenosti. Nezaposlenost i dugotrajna nezaposlenost na niskoj su razini u povijesnom kontekstu. Istodobno je fleksibilnost na danskom tržištu rada visoka, što se odražava u relativno visokom obrtaju radnih mjesta (*job*

turnover)[39] i relativno brzom pronalaženju novih radnih mjesta za osobe koje su nezaposlene. (Denmark's National Reform Programme, 2019: 22)

Prema Bredgaardu, Flemmingu i Madsenu (2005: 9), dansko tržište rada ima supstancijalnu mobilnost na strani poslodavaca, a ovaj visoki stupanj mobilnosti radnih mjesta predstavlja strukturalnu karakteristiku jer je razina mobilnosti konstantna, ali uz određene ciklične varijacije, što konkretno znači da, u prosjeku, između 25 i 30 posto radne snage Danske svake godine mijenja poslodavca. Pokazalo se da se na taj način poboljšava konkurentnost i pospješuje razvoj kompetencija koje su podloga za napredovanje u karijeri.

Bušelić (2017:141) naglašava kako je Danska uvela model s reformskim mjerama koje su rezultirale jačanjem poticaja za rad te povećanjem zapošljivosti. Prethodno navedene mjere su se odnosile na prihvaćanje ponude za posao izvan svoje profesije nakon 3 mjeseca od početka statusa nezaposlenosti, obveze aktiviranja nezaposlenih nakon 6 mjeseci nezaposlenosti, što uključuje i osobe mlađe od 25 godina te korištenje aktivnih programa prekvalificiranja koje je u Danskoj usklađeno s tržišnim potrebama. Primanje socijalne pomoći moguće je jedino u slučaju u kojem nezaposlena osoba nije uspjela u roku od četiri godine pronaći posao.

Rodgers (2007: 7) navodi kako, uz danski, postoje različiti načini kombiniranja fleksibilnosti i sigurnosti, a švedski i finski pristup daju još jedan, drugačiji primjer, koji obuhvaća visoku javnu potrošnju na socijalne usluge, fleksibilnost za poduzeća, sigurnost tržišta rada za radnike te jednak okvir vrijednosti u kojima svi akteri imaju i prava i svoje odgovornosti.

Bušelić (2017:142) također ističe da je u Danskoj (kao i u drugim nordijskim zemljama te u Nizozemskoj) aktivno traženje posla stvar časti za nezaposlene jer se naknada za nezaposlenost shvaća kao tranzicijsko rješenje do ionako lakog pronalaska novog posla u uvjetima slobodnog tržišta rada. Međutim, to nije slučaj u većini drugih Europskih zemalja, kao što je primjerice Hrvatska u kojoj su socijalne naknade relativno visoke bez nužnog uvjeta za aktivacijom na tržištu rada što je za nezaposlene osobe olakotno i destimulirajuće, a posljedično otegotno za samu situaciju na tržištu rada.

Prijedlog za unaprjeđenje i ostvarenje koncepta fleksigurnosti bi svakako trebao ići u smjeru većeg implementiranja aktivnih mjera politike tržišta rada koje bi smanjile razdoblja nezaposlenosti i pomogle nezaposlenim osobama upravljati brzim promjenama na tržištu rada, a sve to popraćeno involviranjem različitih programa cjeloživotnog obrazovanja koji osiguravaju kontinuiranu prilagodljivost radnika, što je neminovno u današnjem dinamičnom okruženju.

[39] Pozitivan obrtaj poslova znači da se više novih poslova stvori nego što se starih ugasi

7. ANALIZA UTJECAJA FLEKSIBILNOSTI RADNE SNAGE NA GOSPODARSKI RAZVOJ ZEMALJA EU-a

U ovom poglavlju doktorske disertacije definirat će se varijable korištene u radu i metodologija njihova izračuna, analizirat će se uzorak istraživanja nakon čega će se statistički obraditi i analizirati podaci prikupljeni za potrebe istraživanja.

7.1. Definiranje varijabli korištenih u radu i metodologija njihova izračuna

Kako bi se ispitale hipoteze koje su postavljene u radu, u analizu su inkorporirane sljedeće varijable: *profesionalni status*, *puno i nepuno radno vrijeme*, *stalnost posla*, *dob*, *radni status*, *trajanje nezaposlenosti*, *traženje zaposlenja*, *razina obrazovanja*, *rad u smjenama*, *večernji rad*, *noćni rad*, *rad subotom*, *rad nedjeljom* i *rad od kuće*.

U skladu s dosadašnjim teorijskim znanjem i empirijskim istraživanjima, hipoteze koje će istraživanjem biti prihvaćene ili odbačene su:

H1.

Fleksibilnost tržišta radne snage pozitivno je korelirana sa stupnjem razvijenosti zemlje.

H1.1.

Povećanje udjela privremenog zapošljavanja i zapošljavanja na nepuno radno vrijeme ima pozitivan utjecaj na stopu zaposlenosti.

H1.2.

S porastom udjela rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće, smanjuje se stopa nezaposlenosti.

H2.

Proporcija zaposlenosti na određeno radno vrijeme i proporcija zaposlenosti na nepuno radno vrijeme razlikuje se kod osoba različitih razina obrazovanja.

H3.

Vremensko razdoblje trajanja nezaposlenosti u izravnoj je korelaciji s dobnom strukturom radnika i njihovom motivacijom za traženjem novog posla.

U tablici 19. prikazane su varijable, njihova detaljna kodifikacija i opisi varijabli.

Tablica 19. Popis varijabli – detaljna kodifikacija

Naziv varijable	**Kod**	**Opis varijable**
STAPRO		**Profesionalni status**
	0	Samozaposleni sa zaposlenicima ili bez njih
	3	Zaposlenik
	4	Obiteljski radnik
	9	Nije primjenjivo (nije radio jer je otpušten / bio obveznik na obveznom vojnom ili društvenom radu / Ostali (15 godina ili više) koji niti su radili niti su imali posao ili posao tijekom referentnog tjedna / dijete mlađe od 15 godina)
	prazno	Nema odgovora
FTPT		**Puno radno vrijeme / nepuno radno vrijeme**
	1	Puno radno vrijeme
	2	Nepuno radno vrijeme
	9	Nije primjenjivo (nije radio jer je otpušten / bio obveznik na obveznom vojnom ili društvenom radu / Ostali (15 godina ili više) koji niti su radili niti su imali posao ili posao tijekom referentnog tjedna / dijete mlađe od 15 godina)
	prazno	Nema odgovora
TEMP		**Stalnost posla**
	1	Osoba ima stalni posao ili ugovor o radu na neograničeno vrijeme
	2	Osoba ima privremeni posao / ugovor o radu na određeno vrijeme
	9	Nije primjenjivo (STAPRO≠3; nije zaposlen)
	prazno	Nema odgovora
AGE		**Dob intervjuirane osobe**
	0-120	Brojkom navedena dob
ILOSTAT		**Radni status**
	1	Zaposlen
	2	Nezaposlen
	3	Neaktivan
	4	Obavezno služenje vojnog roka
	9	Osobe mlađe od 15 godina
DURUNE		**Trajanje nezaposlenosti**
	0	Trenutno nema aktivnosti traženja posla (posao je već pronađen)
	1	Manje od 1. mjeseca
	2	1-2 mjeseca
	3	3-5 mjeseci
	4	6-11 mjeseci
	5	12-17 mjeseci
	6	18-23 mjeseca
	7	24-47 mjeseca
	8	4 godine ili duže
	9	Nije primjenjivo (ILOSTAT≠2; nije nezaposlen)
	prazno	Nema odgovora
SEEKWORK		**Traženje zaposlenja**
	1	Osoba je već našla posao koji će započeti u roku od najviše 3 mjeseca
	2	Osoba je već našla posao koji će započeti za više od 3 mjeseca
	3	Osoba ne traži zaposlenje i nije pronašla bilo koji posao koji će započeti kasnije
	4	Osoba traži posao
	9	Nije primjenjivo ((WSTATOR = 1,2 ili 9; Radio je bilo koji posao za plaću tijekom referentnog tjedna - jedan sat ili više / Nije radio, ali je imao posao ili posao na kojem je izbivao tijekom referentnog tjedna (uključujući obiteljske radnike, ali isključujući regrute na obveznu vojnu ili zajedničku

		službu) ili djeca mlađa od 15 godina i SIGNISAL ≠ 3; Odsutni dulje od 3 mjeseca i primaju plaću, plaću ili socijalni dodatak koji odgovaraju manje od polovice plaće) ili dob jednaka ili veća od 75)
HATLEV1D		**Razina obrazovanja**
	L	Niska (4 razreda osnovne škole / osnovna škola / strukovno osposobljavanje / jednogodišnje i dvogodišnje srednjoškolsko strukovno obrazovanje)
	M	Srednja (trogodišnje strukovno obrazovanje / gimnazijsko, četverogodišnje i petogodišnje strukovno obrazovanje)
	H	Visoka (strukovni studiji, strukovno specijalističko usavršavanje i osposobljavanje, programi za majstore / sveučilišni ili stručni preddiplomski studij / sveučilišni diplomski studij, specijalistički diplomski stručni studij / poslijediplomski znanstveni magistarski studij / poslijediplomski sveučilišni doktorski studij)
	9	Nije primjenjivo (dijete mlađe od 15 godina)
	prazno	Nema odgovora
SHIFTWK		**Rad u smjenama**
	1	Osoba radi u smjenama
	2	Osoba ponekad radi u smjenama
	3	Osoba nikada ne radi u smjenama
	9	Nije primjenjivo (STAPRO≠3; nije zaposlen)
	prazno	Nema odgovora
EVENWK		**Večernji rad** (16:00 h - ponoć)
	1	Osoba obično radi navečer
	2	Osoba ponekad radi navečer
	3	Osoba nikada ne radi navečer
	9	Nije primjenjivo (nije radio jer je otpušten / bio obveznik na obveznom vojnom ili društvenom radu / Ostali (15 godina ili više) koji niti su radili niti su imali posao ili posao tijekom referentnog tjedna / dijete mlađe od 15 godina)
	prazno	Nema odgovora
NIGHTWK		**Noćni rad**
	1	Osoba obično radi noću
	2	Osoba ponekad radi noću
	3	Osoba nikada ne radi noću
	9	Nije primjenjivo (nije radio jer je otpušten / bio obveznik na obveznom vojnom ili društvenom radu / Ostali (15 godina ili više) koji niti su radili niti su imali posao ili posao tijekom referentnog tjedna / dijete mlađe od 15 godina)
	prazno	Nema odgovora
SATWK		**Rad subotom**
	1	Osoba obično radi subotom
	2	Osoba ponekad radi subotom
	3	Osoba nikada ne radi subotom
	9	Nije primjenjivo (nije radio jer je otpušten / bio obveznik na obveznom vojnom ili društvenom radu / Ostali (15 godina ili više) koji niti su radili niti su imali posao ili posao tijekom referentnog tjedna / dijete mlađe od 15 godina)
	prazno	Nema odgovora
SUNWK		**Rad nedjeljom**
	1	Osoba obično radi nedjeljom
	2	Osoba ponekad radi nedjeljom
	3	Osoba nikada ne radi nedjeljom
	9	Nije primjenjivo (nije radio jer je otpušten / bio obveznik na obveznom vojnom ili društvenom radu / Ostali (15 godina ili više) koji niti su radili niti su imali posao ili posao tijekom referentnog tjedna / dijete mlađe od 15 godina)
	prazno	Nema odgovora
HOMEWK		**Rad kod kuće**
	1	Osoba obično radi kod kuće

	2	Osoba ponekad radi kod kuće
	3	Osoba nikada ne radi kod kuće
	9	Nije primjenjivo (nije radio jer je otpušten / bio obveznik na obveznom vojnom ili društvenom radu / Ostali (15 godina ili više) koji niti su radili niti su imali posao ili posao tijekom referentnog tjedna / dijete mlađe od 15 godina)
	prazno	Nema odgovora

Izvor: izrada autorice prema EU Labour Force Survey (2020).

U okviru hipoteze H1. definirana je fleksibilnost tržišta radne snage formulom kako slijedi:

$$\boldsymbol{FLEX = \frac{SENSSH}{ILOSTAT1}}$$

Izvor: izrada autorice prema Galik, A. i suautorima (2022:538)

U formuli izraz FLEX označava fleksibilnost tržišta radne snage. Izraz SENSSH predstavlja ukupan broj osoba koje rade u nekom od sljedećih fleksibilnih oblika rada: u smjenama / večernji rad /noćni rad / rad subotom / rad nedjeljom / rad od kuće. Izraz ILOSTAT1 označava ukupan broj zaposlenih osoba. Formula je izvedena te prilagođena varijablama u disertaciji na temelju istraživanja Galik, A. i suautora u kojem navode kako su sljedeće četiri varijable smatrane stimulansima za povećanje fleksibilnosti tržišta rada: stopa zaposlenosti radnika na određeno vrijeme, udio radnika s nepunim radnim vremenom, stopa zaposlenosti mlađih radnika u dobi od 15 do 24 godine i stopa zaposlenosti starijih radnika u dobi od 55 do 64 godine. Kao zaključak navode kako je povećanje vrijednosti ovih varijabli dovelo do povećanja fleksibilnosti tržišta rada. Sličan odabir varijabli korišten je i u sljedećim istraživačkim studijama - Ertman (2011: 43 -64) te Jadamus-Hacura, M., Melich-Iwanek, K. (2015: 36–57).

Stupanj razvijenosti zemlje za pojedinu državu u analizi promatran je u okviru varijable BDP po stanovniku (GDP p. c.) u razdoblju od 2008. do 2018. godine, što je prikazano u tablici 20.

Tablica 20. BDP po stanovniku prikazan prema državama i godinama

(podaci prikazani u € po stanovniku)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.
Austrija	36,280	34,830	35,390	36,300	36,390	36,180	36,130	36,140	36,430	37,090	37,810
Belgija	33,640	32,700	33,330	33,460	33,490	33,490	33,870	34,360	34,690	35,210	35,580

Bugarska	5,140	4,990	5,050	5,300	5,350	5,400	5,530	5,790	6,050	6,310	6,550
Cipar	24,680	23,550	23,400	22,900	21,780	20,400	20,240	21,040	22,360	23,120	23,770
Češka	15,500	14,690	15,020	15,310	15,170	15,160	15,480	16,290	16,670	17,490	17,980
Danska	45,700	43,220	43,840	44,240	44,170	44,410	44,890	45,630	46,720	47,360	48,260
Estonija	12,640	10,830	11,150	12,010	12,430	12,640	13,060	13,330	13,650	14,440	15,090
Finska	37,330	34,150	35,080	35,810	35,140	34,660	34,390	34,460	35,320	36,390	36,880
Francuska	31,310	30,250	30,690	31,210	31,160	31,170	31,320	31,540	31,770	32,380	32,860
Grčka	22,560	21,530	20,320	18,500	17,240	16,800	17,040	17,080	17,110	17,410	17,780
Hrvatska	11,470	10,630	10,500	10,500	10,300	10,280	10,310	10,630	11,100	11,560	11,990
Irska	38,600	36,300	36,770	36,840	36,740	37,010	39,920	49,510	49,930	53,890	57,780
Italija	28,230	26,590	26,930	27,020	26,090	25,480	25,420	25,640	26,020	26,490	26,740
Latvija	9,990	8,710	8,500	9,200	9,700	10,030	10,310	10,740	11,030	11,560	12,140
Litva	10,110	8,710	9,030b	9,790	10,300	10,780	11,250	11,590	12,040	12,720	13,310
Luksemburg	81,880	76,900	79,160	79,310	77,240	78,030	79,490	81,300	82,880	82,550	83,470
Mađarska	10,500	9,810	9,900	10,110	10,010	10,230	10,690	11,130	11,410	11,930	12,560
Malta	15,960	15,450	15,920	16,080	16,380	16,930	18,080	19,590	20,260	20,990	21,750
Nizozemska	39,810	38,160	38,470	38,880	38,340	38,180	38,580	39,170	39,810	40,730	41,450
Njemačka	32,320	30,580	31,940	33,200	33,280	33,330	33,920	34,130	34,610	35,380	35,720
Poljska	8,910	9,070	9,390	9,860	10,020	10,170	10,510	10,920	11,260	11,820	12,460
Portugal	17,260	16,710	16,990	16,720	16,110	16,050	16,260	16,620	17,010	17,650	18,150
Rumunjska	6,730	6,410	6,190	6,350	6,510	6,760	7,020	7,320	7,720	8,320	8,740
Slovačka	12,600	11,890	12,540	12,980	13,200	13,270	13,620	14,270	14,550	14,970	15,540
Slovenija	19,190	17,570	17,750	17,870	17,360	17,160	17,620	17,990	18,540	19,430	20,170
Španjolska	24,200	23,100	23,040	22,770	22,080	21,840	22,210	23,080	23,760	24,410	24,880
Švedska	40,100	38,030	39,950	40,920	40,380	40,510	41,180	42,580	42,920	43,430	43,760
Ujedinjeno Kraljevstvo	30,940	29,420	29,750	29,960	30,200	30,660	31,220	31,700	32,050	32,460	32,700

Izvor: izrada autorice prema podacima s Eurostata (2020_g).

Za potrebe analize u hipotezi H1.1. primijenjene su varijable TEMP2* i ILOSTAT1 za izračunavanje udjela privremeno zaposlenih osoba te varijable FTPT2** i ILOSTAT1 za izračunavanje udjela zaposlenih na nepuno radno vrijeme.

TEMP2* = Ukupan broj osoba koje imaju privremeni posao / ugovor o radu na određeno vrijeme

FTPT2** = Ukupan broj osoba zaposlenih na nepuno radno vrijeme

Varijabla *stopa zaposlenosti* (SZ) u hipotezi H1.1. također je promatrana u periodu od 2008. do 2018. godine za sve države Europske unije. Podaci o stopi zaposlenosti preuzeti s Eurostata prikazani su u tablici 21, a odnose se na populaciju od 15 do 64 godine.

Tablica 21. Stopa zaposlenosti u EU-u od 2008. do 2018. godine

(podaci prikazani u %)

Godina / Država	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.
Austrija	70,8	70,3	70,8	71,1	71,4	71,4	71,1	71,1	71,5	72,2	73
Belgija	62,4	61,6	62	61,9	61,8	61,8	61,9	61,8	62,3	63,1	64,5
Bugarska	64	62,6	59,8	58,4	58,8	59,5	61	62,9	63,4	66,9	67,7
Cipar	70,9	69	68,9	67,6	64,6	61,7	62,1	62,7	63,7	65,6	68,6
Češka	66,6	65,4	65	65,7	66,5	67,7	69	70,2	72	73,6	74,8
Danska	76,3	73,5	71,8	71,6	71	70,7	71,1	72	72,7	73,2	74,1
Estonija	70,1	63,8	61,2	65,3	67,1	68,5	69,6	71,9	72,1	74,1	74,8
Finska	71,1	68,7	68,1	69	69,4	68,9	68,7	68,5	69,1	70	72,1
Francuska	64,4	63,5	63,5	63,4	63,5	63,5	63,7	63,8	64,2	64,7	65,3
Grčka	61,4	60,8	59,1	55,1	50,8	48,8	49,4	50,8	52	53,5	54,9
Hrvatska	60	59,4	57,4	55,2	53,5	52,5	54,6	56	56,9	58,9	60,6
Irska	69,7	63,6	61	60	59,9	61,7	63,1	64,8	66,4	67,7	68,6
Italija	58,6	57,4	56,8	56,8	56,6	55,5	55,7	56,3	57,2	58	58,5
Latvija	68,2	60,3	58,5	60,8	63	65	66,3	68,1	68,7	70,1	71,8
Litva	64,4	59,9	57,6	60,2	62	63,7	65,7	67,2	69,4	70,4	72,4
Luksemburg	63,4	65,2	65,2	64,6	65,8	65,7	66,6	66,1	65,6	66,3	67,1
Mađarska	56,4	55	54,9	55,4	56,7	58,1	61,8	63,9	66,5	68,2	69,2
Malta	55,5	55,3	56,2	57,9	59,9	62,2	63,9	65,1	67,2	69,2	71,9
Nizozemska	74,9	74,6	73,9	74,2	74,4	73,6	73,1	74,1	74,8	75,8	77,2
Njemačka	70,1	70,3	71,3	72,7	73	73,5	73,8	74	74,7	75,2	75,9
Poljska	59,2	59,3	58,9	59,3	59,7	60	61,7	62,9	64,5	66,1	67,4
Portugal	68	66,1	65,3	63,8	61,4	60,6	62,6	63,9	65,2	67,8	69,7
Rumunjska	59	58,6	60,2	59,3	60,2	60,1	61	61,4	61,6	63,9	64,8
Slovačka	62,3	60,2	58,8	59,3	59,7	59,9	61	62,7	64,9	66,2	67,6
Slovenija	68,6	67,5	66,2	64,4	64,1	63,3	63,9	65,2	65,8	69,3	71,1
Španjolska	64,5	60	58,8	58	55,8	54,8	56	57,8	59,5	61,1	62,4
Švedska	74,3	72,2	72,1	73,6	73,8	74,4	74,9	75,5	76,2	76,9	77,4
Ujedinjeno Kraljevstvo	71,5	69,9	69,4	69,3	69,9	70,5	71,9	72,7	73,5	74,1	74,7

Izvor: izrada autorice prema podacima s Eurostata (2020_c).

U hipotezi H1.2. korištena je varijabla *SENSSH* te varijabla *stopa nezaposlenosti*. Podaci za varijablu *stopa nezaposlenosti* preuzeti su iz baze podataka Eurostata za period od 2008. do 2018. godine za sve države Europske unije te su prikazani u tablici 22. Podaci se odnose na populaciju od 15 do 74 godine[40].

Tablica 22. Stopa nezaposlenosti u zemljama EU-a od 2008. do 2018. godine

(podaci prikazani u %)

Godina / Država	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
Austrija	4,1	5,3	4,8	4,6	4,9	5,4	5,6	5,7	6	5,5	4,9
Belgija	7	7,9	8,3	7,2	7,6	8,4	8,5	8,5	7,8	7,1	6
Bugarska	5,6	6,8	10,3	11,3	12,3	13	11,4	9,2	7,6	6,2	5,2
Cipar	3,7	5,4	6,3	7,9	11,9	15,9	16,1	15	13	11,1	8,4
Češka	4,4	6,7	7,3	6,7	7	7	6,1	5,1	4	2,9	2,2
Danska	3,7	6,4	7,7	7,8	7,8	7,4	6,9	6,3	6	5,8	5,1
Estonija	5,5	13,5	16,7	12,3	10	8,6	7,4	6,2	6,8	5,8	5,4
Finska	6,4	8,2	8,4	7,8	7,7	8,2	8,7	9,4	8,8	8,6	7,4
Francuska	7,1	8,7	8,9	8,8	9,4	9,9	10,3	10,4	10	9,4	9
Grčka	7,8	9,6	12,7	17,9	24,5	27,5	26,5	24,9	23,6	21,5	19,3
Hrvatska	8,6	9,2	11,7	13,7	16	17,3	17,3	16,2	13,1	11,2	8,5
Irska	6,8	12,6	14,6	15,4	15,5	13,8	11,9	10	8,4	6,7	5,8
Italija	6,7	7,8	8,4	8,4	10,7	12,2	12,7	11,9	11,7	11,2	10,6
Latvija	7,7	17,5	19,5	16,2	15	11,9	10,8	9,9	9,6	8,7	7,4
Litva	5,8	13,8	17,8	15,4	13,4	11,8	10,7	9,1	7,9	7,1	6,2
Luksemburg	5,1	5,1	4,4	4,9	5,1	5,9	5,9	6,7	6,3	5,5	5,6
Mađarska	7,8	10	11,2	11	11	10,2	7,7	6,8	5,1	4,2	3,7
Malta	6	6,9	6,9	6,4	6,2	6,1	5,7	5,4	4,7	4	3,7
Nizozemska	3,7	4,4	5	5	5,8	7,3	7,4	6,9	6	4,9	3,8
Njemačka	7,5	7,8	7	5,8	5,4	5,2	5	4,6	4,1	3,8	3,4
Poljska	7,1	8,2	9,7	9,7	10,1	10,3	9	7,5	6,2	4,9	3,9
Portugal	7,7	9,6	11	12,9	15,8	16,4	14,1	12,6	11,2	9	7,1
Rumunjska	5,8	6,9	7	7,2	6,8	7,1	6,8	6,8	5,9	4,9	4,2
Slovačka	9,5	12	14,4	13,6	14	14,2	13,2	11,5	9,7	8,1	6,5
Slovenija	4,4	5,9	7,3	8,2	8,9	10,1	9,7	9	8	6,6	5,1
Španjolska	11,3	17,9	19,9	21,4	24,8	26,1	24,5	22,1	19,6	17,2	15,3

[40] Nezaposlenu osobu Eurostat, prema smjernicama Međunarodne organizacije rada, definira kao osobu u dobi od 15 do 74 godine (u Italiji, Španjolskoj, Ujedinjenom Kraljevstvu, Islandu, Norveškoj: 16 do 74 godine) (Eurostat, Unemployment, 2010)

Švedska	6,2	8,4	8,6	7,8	8	8,1	8	7,4	7	6,7	6,4
Ujedinjeno Kraljevstvo	5,6	7,6	7,8	8,1	7,9	7,5	6,1	5,3	4,8	4,3	4

Izvor: izrada autorice prema podacima s Eurostata (2020_h).

U hipotezi H1. koristila se korelacijska analiza te je izračunat koeficijent korelacije, koeficijent determinacije, pravac regresije te je pridružena statistička značajnost. Također, koristila se regresijska analiza – model višestruke regresije i to: višestruka linearna regresija te višestruka nelinearna regresija pri čemu se odredila značajnost modela, koeficijent determinacije i pripadajući ponderi prediktorskih varijabli.

U okviru hipoteze H2. izračunate su sljedeće proporcije: T2HL/T2HLMH, T2HM/T2HLMH, T2HH/T2HLMH, F2HL/F2HLMH, F2HM/F2HLMH i F2HH/F2HLMH prikazane u statističkom dijelu analize u poglavlju 7.3. na sljedeći način: P^1_1, P^1_2, P^1_3, P^2_1, P^2_2 i P^2_3.
U tablici 23. prikazane su varijable korištene u hipotezi H2. te deskripcija istih.

Tablica 23. Opis varijabli analiziranih u hipotezi H2.

Varijabla	**Opis varijable**
T2	Ukupan broj osoba koje imaju privremeni posao / ugovor o radu na određeno vrijeme
F2	Ukupan broj osoba zaposlenih na nepuno radno vrijeme
HL	Ukupan broj niskoobrazovanih osoba
HM	Ukupan broj srednjeobrazovanih osoba
HH	Ukupan broj visokoobrazovanih osoba
T2HL	Ukupan broj privremeno zaposlenih osoba koje su niskoobrazovane
T2HM	Ukupan broj privremeno zaposlenih osoba koje su srednjeobrazovane
T2HH	Ukupan broj privremeno zaposlenih osoba koje su visokoobrazovane
F2HL	Ukupan broj osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane
F2HM	Ukupan broj osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane
F2HH	Ukupan broj osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane
T2HL/T2HLMH	Udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
T2HM/T2HLMH	Udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
T2HH/T2HLMH	Udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja

F2HL/F2HLMH	Udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
F2HM/F2HLMH	Udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
F2HH/F2HLMH	Udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja

Izvor: izrada autorice

U hipotezi H2. korišten je test značajnosti razlike između proporcija.

U hipotezi H3. primijenjena je varijabla DURUNE (kodovi 1-3 u tablici 18.). Kodovi 4-8 nisu dio analize jer je u upitniku evidentirano da u uzorku nema ispitanika čije je trajanje nezaposlenosti duže od 6 mjeseci. Ovaj podatak se detektira kao jedno od ograničenja u analizi. Nadalje, što se dobne strukture radnika tiče, ispitanici su rangirani prema klasifikaciji OECD-a u pripadajuće starosne grupe, odnosno razrede i to kako slijedi:

1) 15 – 24 godine (oni koji ulaze na tržište rada nakon edukacije)
2) 25 – 54 godine (oni koji su u radnom vijeku u najboljim godinama)
3) 55 – 64 godine (oni koji prolaze vrhunac svoje karijere i približavaju se mirovini). (OECD, 2020_a)

Dobna struktura radnika iliti prethodno definirane starosne grupe prikazane su u hipotezi $H3_1$ u rezultatima analize na sljedeći način: DS_R 1, DS_R 2 i DS_R 3.

U tablici 24. prikazana je kodifikacija i opis varijabli korištenih u analizi prvog dijela hipoteze H3.

Tablica 24. Opis varijabli analiziranih u hipotezi $H3_1$

Varijabla	**Opis varijable**
D1 A 15-24	Ukupan broj osoba od 15-24 godine nezaposlenih u trajanju do 1. mjeseca
D2 A 15-24	Ukupan broj osoba od 15-24 godine nezaposlenih u trajanju od 1. do 2. mjeseca
D3 A 15-24	Ukupan broj osoba od 15-24 godine nezaposlenih u trajanju od 3 do 5 mjeseci
D1 A 25-54	Ukupan broj osoba od 25-54 godine nezaposlenih u trajanju do 1. mjeseca
D2 A 25-54	Ukupan broj osoba od 25-54 godine nezaposlenih u trajanju od 1. do 2. mjeseca
D3 A 25-54	Ukupan broj osoba od 25-54 godine nezaposlenih u trajanju od 3 do 5 mjeseci
D1 A 55-64	Ukupan broj osoba od 55-64 godine nezaposlenih u trajanju do 1. mjeseca
D2 A 55-64	Ukupan broj osoba od 55-64 godine nezaposlenih u trajanju od 1. do 2. mjeseca

D3 A 55-64	Ukupan broj osoba od 55-64 godine nezaposlenih u trajanju od 3 do 5 mjeseci
D123A15-64	Ukupan broj osoba od 15-64 godine koji su nezaposleni do 5 mjeseci

Izvor: izrada autorice

U drugom dijelu hipoteze H3. definirana je motivacija za traženjem novog zaposlenja i to formulom kako slijedi;

$$\boldsymbol{M_{TNP}} = \frac{\sum_{i=0}^{n} \boldsymbol{M_n}}{\boldsymbol{V_{TN}}}$$

Izvor: izrada autorice prema van den Hee, S. M., van Hooft, E. A. J., van Vianen, A. E. M. (2020)

U formuli izraz M_{TNP} označava motivaciju za traženjem novog zaposlenja. Izraz $\sum_{i=0}^{n} M_n$ predstavlja ukupan broj metoda korištenih za pronalaženje posla. Izraz V_{TN} označava vremensko trajanje nezaposlenosti. Formula je izvedena te prilagođena varijablama u disertaciji na temelju istraživanja o motivaciji i traženju novog zaposlenja. Jedno od istraživanja proveli su van den Hee, S. M., van Hooft, E. A. J., van Vianen, A. E. M. (2020) koji navode kako je smanjen broj intervjua (kao jedne od metoda traženja novog zaposlenja) negativno povezan sa satusom ponovnog zaposlenja. Njihovi rezultati upućuju na važnost vremenske perspektive traženja posla te zaključuju kako je odgađanje traženja posla također negativno povezano sa statusom ponovnog zaposlenja.

U tablici 25. prikazana je kodifikacija i opis varijabli korištenih u analizi u drugom dijelu hipoteze H3.

Tablica 25. Opis varijabli analiziranih u hipotezi $H3_2$

Varijabla	**Opis varijable**
M_{TNP} 1	osoba je kontaktirala Javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla

M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2 mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci

Izvor: izrada autorice

U hipotezi H3. bit će određene kontingencijske tablice te će se primijeniti χ^2-test za ispitivanje povezanosti dviju nominalnih varijabli.

7.2. Analiza uzorka istraživanja

Istraživanje u ovoj disertaciji temeljit će se na službenim podacima o istraživanju radne snage Europske unije (EU LFS) koje obuhvaća približno 50 milijuna ispitanika u razdoblju od 1983. godine do 2018. godine koji su dobiveni na temelju odobrenog projekta RPP 35/2020-LFS.
U tablici 26. je prikazan ukupan broj ispitanika u uzorku prema razredima, odnosno starosnim grupama i državama EU-a u razdoblju od 2008. do 2018. godine – ukupno 1 978 417 ispitanika.

Tablica 26. Ukupan broj ispitanika u uzorku prema razredima, odnosno starosnim grupama i državama EU

Razredi / Država	15 – 24 godine	25 – 54 godine	55 – 64 godine
Austrija	10.895	26.555	3.528
Belgija	7.833	24.970	3.065
Bugarska	1.871	9.232	2.766
Cipar	4.424	15.184	2.953
Češka	5.829	19.966	4.375
Danska	16.865	21.228	6.012
Estonija	2.675	7.246	1.614
Finska	7.437	9.653	2.799
Francuska	54106	150.527	23.863
Grčka	31.277	163.993	20.381
Hrvatska	5.698	14.397	2.355
Irska	25.860	74.436	10.574
Italija	53.311	181.234	19.977
Latvija	3.990	14.867	3.182
Litva	5.235	24.855	5.700
Luksemburg	1.127	3.471	369

Mađarska	20.800	72.087	10.712
Malta	2.103	3.368	622
Nizozemska	7.666	13.725	6.293
Njemačka	13.376	53.763	15.997
Poljska	31.083	83.105	13.681
Portugal	19.146	63.495	13.708
Rumunjska	17.989	46.173	5.076
Slovačka	11.053	39.446	7.135
Slovenija	4.484	18.690	2.308
Španjolska	19.226	75.019	12.290
Švedska	41.382	64.832	26.021
Ujedinjeno Kraljevstvo	9.874	15.868	3.061

Izvor: izrada autorice na temelju podataka iz projekta RPP 35/2020-LFS

EU-LFS službeni skup podataka iz projekta RPP 35/2020-LFS sadrži podatke za sve države članice EU-a. Podaci pokrivaju sve industrije i profesije. U disertaciji će se analizirati podaci zaposlenih i nezaposlenih osoba starijih od 15 godina i mlađih od 64 godine koji žive u kućanstvima. Osobe koje obavljaju obvezni vojni rok ili rad u javnom interesu nisu uključene u ciljanu skupinu istraživanja.

Treba napomenuti kako je EU-LFS glavni izvor podataka za domenu 'zaposlenost i nezaposlenost' te sadržaj istog uključuje podatke o stanovništvu, zaposlenosti, radnom vremenu, trajnosti posla, profesionalnom statusu. Podaci se obično raščlanjuju prema dobi, spolu, stupnju obrazovanja, ekonomskoj aktivnosti i zanimanju, gdje je to primjenjivo.

7.3. Statistička obrada i analiza podataka istraživanja

U ovom poglavlju su statistički obrađeni, tabelarno prikazani te analizirani podaci po hipotezama za svaku državu EU-a.

7.3.1. Utjecaj fleksibilnosti tržišta radne snage na stupanj razvijenosti zemalja

U statističkoj obradi hipoteze H1. za svaku zemlju EU-a generiran je statistički značajan model:

a) linearne povezanosti kriterijske varijable *fleksibilnost tržišta radne snage* s prediktorskom varijablom *bruto domaći proizvod po stanovniku*

b) nelinearne povezanosti kriterijske varijable *fleksibilnost tržišta radne snage* s prediktorskom varijablom *bruto domaći proizvod po stanovniku*

Za potrebe analize podataka u hipotezi H1. uključena je vremenska komponenta te je varijabla *bruto domaći proizvod po stanovniku* u okviru iste hipoteze upotrijebljen kao iznos za svaku, u analizu uključenu, godinu, za sve države individualno. Jednako tako, u svaki model za svaku državu uvrštena je stohastička varijabla greške (rezidualnog odstupanja) označena slovom e.

Hipoteza H1. će biti prihvaćena u slučaju ako je ista potvrđena za sve države ili njih 27 od 28. U slučaju da je hipoteza H1. potvrđena ili parcijalno potvrđena za 15 do 26 zemalja, ista će biti parcijalno potvrđena. Hipoteza H1. će biti odbačena ako je potvrđena za 14 ili manje zemalja.

U tablici 27. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Austriju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 27. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Austriju

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,92; R^2 = 0,84; t = -6,97; p < 0,01			
	b_0	b_1	
GDP p. c.	0,85	-0,002502	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. c.^{2} + e			
R = 0,92; R^2 = 0,84; F = 21,80; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,004707	-0,000034	0,81

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Potrebno je istaknuti da je koeficijent determinacije u linearnom modelu statistički značajan i iznosi 0,84, što ukazuje na to da je 84 % varijabiliteta kriterija određeno s korištenim prediktorom. U nelinearnom modelu koeficijent determinacije je također statistički značajan i, jednako kao i u linearnom modelu, iznosi 0,84, što ukazuje na to da je 84 % varijabiliteta kriterija određeno korištenim prediktorom.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Austriju potvrđena.

U tablici 28. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* sa varijablom *fleksibilnost tržišta radne snage* za Belgiju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 28. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Belgiju

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,95; R^2 = 0,90; t = 9,00; p < 0,01			
	b_0	b_1	
GDP p. c.	-0,01	0,004556	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,95; R^2 = 0,91; F = 38,59; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,037588	-0,000142	0,49

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Nužno je naglasiti da je koeficijent determinacije u linearnom modelu statistički značajan i iznosi 0,90, što ukazuje na to da je 90 % varijabiliteta kriterija određeno korištenim prediktorom. U nelinearnom modelu koeficijent determinacije je također statistički značajan i iznosi 0,91, što ukazuje na to da je 91 % varijabiliteta kriterija određeno korištenim prediktorom.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Belgiju potvrđena.

U tablici 29. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Bugarsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 29. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Bugarsku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,78; R^2 = 0,60; t = -3,68; p < 0,01			
	b_0	b_1	
GDP p. c.	1,59	-0,008865	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,91; R^2 = 0,82; F = 18,64; p < 0,01			
	b_1	b_2	p
GDP p. c.	-0,499672	0,001932	0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Potrebno je istaknuti da je u nelinearnom modelu koeficijent determinacije statistički značajan i iznosi 0,82, što ukazuje na to da je 82 % varijabiliteta kriterija određeno korištenim prediktorom.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Bugarsku potvrđena.

U tablici 30. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* sa varijablom *fleksibilnost tržišta radne snage* za Cipar. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 30. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Cipar

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,75; R^2 = 0,57; t = 3,43; p < 0,01			
	b_0	b_1	
GDP p. c.	0,11	0,002594	
Nelinearni model FLEX = b_1 • GDP p. c. + b_2 • GDP p. $c.^2$ + e			
R = 0,92; R^2 = 0,85; F = 22,46; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,197571	-0,000654	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Potrebno je naglasiti da je u nelinearnom modelu koeficijent determinacije statistički značajan i iznosi 0,85, što ukazuje na to da je 85 % varijabiliteta kriterija određeno korištenim prediktorom.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Cipar potvrđena.

U tablici 31. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* sa varijablom *fleksibilnost tržišta radne snage* za Češku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 31. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Češku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,63; R^2 = 0,39; t = -2,42; p = 0,04			
	b_0	b_1	
GDP p. c.	0,81	-0,001892	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,63; R^2 = 0,40; F = 2,67; p = 0,13			
	b_1	b_2	p
GDP p. c.	0,025449	-0,000085	0,78

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Češku parcijalno potvrđena.

U tablici 32. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* sa varijablom *fleksibilnost tržišta radne snage* za Dansku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 32. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Dansku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,28; R^2 = 0,08; t = 0,87; p = 0,41			
	b_0	b_1	
GDP p. c.	0,36	0,001632	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,88; R^2 = 0,77; F = 13,78; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,635078	-0,001750	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Dansku parcijalno potvrđena.

U tablici 33. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Estoniju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 33. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Estoniju

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,60; R^2 = 0,36; t = 2,23; p = 0,05			
	b_0	b_1	
GDP p. c.	-0,25	0,003990	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,66; R^2 = 0,43; F = 3,08; p = 0,10			
	b_1	b_2	p
GDP p. c.	-0,281650	0,000747	0,32

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model na granici statističke značajnosti. Nadalje, u linearnom modelu varijabli GDP p. c. statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage* je na granici.

Iz tablice je također vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Estoniju odbačena.

U tablici 34. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Finsku. U tablici su

navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 34. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Finsku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,43; R^2 = 0,18; t = -1,41; p = 0,19			
	b_0	b_1	
GDP p. c.	0,62	-0,000276	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,93; R^2 = 0,87; F = 26,14; p < 0,01			
	b_1	b_2	p
GDP p. c.	-0,018374	0,000057	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. Nužno je istaknuti da je u nelinearnom modelu koeficijent determinacije statistički značajan i iznosi 0,87, što ukazuje na to da je 87 % varijabiliteta kriterija određeno korištenim prediktorom. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Finsku parcijalno potvrđena.

U tablici 35. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* sa varijablom *fleksibilnost tržišta radne snage* za Francusku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 35. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Francusku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,86; R^2 = 0,75; t = -5,17; p < 0,01			
	b_0	b_1	
GDP p. c.	12,51	-0,054221	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,87; R^2 = 0,76; F = 12,52; p < 0,01			
	b_1	b_2	p
GDP p. c.	-1,057893	0,002250	0,58

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je također vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Francusku potvrđena.

U tablici 36. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* sa varijablom *fleksibilnost tržišta radne snage* za Grčku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 36. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Grčku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e
R = 0,16; R^2 = 0,02; t = 0,48; p = 0,64

	b_0	b_1	
GDP p. c.	0,64	0,000393	
Nelinearni model FLEX = b_1 • GDP p. c. + b_2 • GDP p. c.^{2} + e			
R = 0,69; R^2 = 0,48; F = 3,71; p = 0,07			
	b_1	b_2	p
GDP p. c.	-0,280552	0,000600	0,03

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da je nelinearni model na granici statističke značajnosti. U nelinearnom modelu varijabli GDP p. c. statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage* je na granici.

Time je hipoteza H 1. za Grčku odbačena.

U tablici 37. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Hrvatsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 37. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Hrvatsku

Linearni model FLEX = b_0 + b_1• GDP p. c. + e			
R = -0,75; R^2 = 0,57; t = -3,44; p < 0,01			
	b_0	b_1	
GDP p. c.	1,68	-0,003790	
Nelinearni model FLEX = b_1 • GDP p. c. + b_2 • GDP p. c.^{2} + e			
R = 0,84; R^2 = 0,70; F = 9,33; p < 0,01			
	b_1	b_2	p

GDP p. c.	0,414644	-0,000858	0,10
Oznaka	Opis oznake		
R	koeficijent korelacije		
R^2	koeficijent determinacije		
T	vrijednost testne statistike za koeficijent		
F	vrijednost testne statistike za model		
P	nivo statističke značajnosti		
FLEX	fleksibilnost tržišta radne snage		
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku		

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je također vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Hrvatsku potvrđena.

U tablici 38. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Irsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 38. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Irsku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,06; R^2 = 0,004; t = -0,20; p = 0,85			
	b_0	b_1	
GDP p. c.	0,60	-0,000021	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,26; R^2 = 0,07; F = 0,29; p = 0,75			
	b_1	b_2	p
GDP p. c.	0,003092	-0,000008	0,48
Oznaka	Opis oznake		
R	koeficijent korelacije		
R^2	koeficijent determinacije		
T	vrijednost testne statistike za koeficijent		
F	vrijednost testne statistike za model		

P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Irsku odbačena.

U tablici 39. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Italiju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 39. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Italiju

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,43; R^2 = 0,19; t = -1,43; p = 0,19			
	b_0	b_1	
GDP p. c.	1,02	-0,001763	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,88; R^2 = 0,78; F = 13,87; p < 0,01			
	b_1	b_2	p
GDP p. c.	-0,644953	0,001128	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. Važno je naglasiti da je u nelinearnom modelu koeficijent determinacije statistički značajan i iznosi 0,78, što ukazuje na to da je 78 % varijabiliteta kriterija određeno korištenim prediktorom. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Italiju parcijalno potvrđena.

U tablici 40. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Latviju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 40. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Latviju

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,61; R^2 = 0,37; t = 2,30; p = 0,05			
	b_0	b_1	
GDP p. c.	-0,03	0,001566	
Nelinearni model FLEX = b_1 • GDP p. c. + b_2 • GDP p. $c.^2$ + e			
R = 0,69; R^2 = 0,47; F = 3,55; p = 0,08			
	b_1	b_2	p
GDP p. c.	0,037886	-0,000065	0,25

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model na granici statističke značajnosti. Nadalje, u linearnom modelu varijabli GDP p. c. statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage* je na granici.

Iz tablice je vidljivo da je nelinearni model također na granici statističke značajnosti. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Latviju parcijalno potvrđena.

U tablici 41. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Litvu. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 41. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Litvu

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,53; R^2 = 0,28; t = -1,89; p = 0,09			
	b_0	b_1	
GDP p. c.	0,84	-0,001337	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,89; R^2 = 0,79; F = 15,27; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,129320	-0,000241	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model na granici statističke značajnosti. Nadalje, u linearnom modelu varijabli GDP p. c. statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage* je na granici.

Iz tablice je vidljivo da je nelinearni model statistički značajan. Nužno je istaknuti da je u nelinearnom modelu koeficijent determinacije statistički značajan i iznosi 0,79, što ukazuje na to da je 79 % varijabiliteta kriterija određeno korištenim prediktorom. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1. za Litvu potvrđena.

U tablici 42. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Luksemburg. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 42. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Luksemburg

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,65; R^2 = 0,42; t = 2,55; p = 0,03			
	b_0	b_1	
GDP p. c.	-3,51	0,013284	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,66; R^2 = 0,44; F = 3,09; p = 0,10			
	b_1	b_2	p
GDP p. c.	0,583530	-0,000935	0,64

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.
Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Luksemburg parcijalno potvrđena.

U tablici 43. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Mađarsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 43. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Mađarsku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,33; R^2 = 0,11; t = 1,05; p = 0,32			
	b_0	b_1	
GDP p. c.	-0,03	-0,002067	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,85; R^2 = 0,72; F = 10,32; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,443505	-0,000882	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Mađarsku parcijalno potvrđena.

U tablici 44. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Maltu. U tablici su

navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 44. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Maltu

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,54; R^2 = 0,30; t = -1,83; p = 0,10			
	b_0	b_1	
GDP p. c.	1,69	-0,003453	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,58; R^2 = 0,34; F = 1,76; p = 0,24			
	b_1	b_2	p
GDP p. c.	-0,329909	0,000503	0,54

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Maltu odbačena.

U tablici 45. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Nizozemsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 45. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Nizozemsku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,62; R^2 = 0,38; t = 2,36; p = 0,04			
	b_0	b_1	
GDP p. c.	-2,96	0,010906	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,73; R^2 = 0,54; F = 4,68; p = 0,04			
	b_1	b_2	p
GDP p. c.	-1,849895	0,002783	0,14

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da je nelinearni model također statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Nizozemsku potvrđena.

U tablici 46. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Njemačku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 46. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Njemačku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e
R = -0,23; R^2 = 0,05; t = -0,71; p = 0,49

	b_0	b_1	
GDP p. c.	0,68	-0,000541	
Nelinearni model FLEX = b_1 • GDP p. c. + b_2 • GDP p. c.^{2} + e			
R = 0,90; R^2 = 0,82; F = 17,76; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,062905	-0,000222	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. Važno je istaknuti da je u nelinearnom modelu koeficijent determinacije statistički značajan i iznosi 0,82, što ukazuje na to da je 82 % varijabiliteta kriterija određeno korištenim prediktorom. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Njemačku parcijalno potvrđena.

U tablici 47. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Poljsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 47. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Poljsku

Linearni model FLEX = b_0 + b_1• GDP p. c. + e			
R = -0,93; R^2 = 0,87; t = -7,82; p < 0,01			
	b_0	b_1	
GDP p. c.	3,22	-0,001767	
Nelinearni model FLEX = b_1 • GDP p. c. + b_2 • GDP p. c.^{2} + e			

R = 0,93; R^2 = 0,87; F = 27,23; p < 0,01			
	b_1	b_2	p
GDP p. c.	-0,043227	0,000051	0,89

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Interesantno je istaknuti da je koeficijent determinacije u linearnom modelu statistički značajan i iznosi 0,87, što ukazuje na to da je 87 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent determinacije je statistički značajan i također iznosi 0,87, što ukazuje na to da je 87 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model također statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Poljsku potvrđena.

U tablici 48. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Portugal. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 48. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Portugal

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,05; R^2 = 0,002; t = -0,14; p = 0,89			
	b_0	b_1	
GDP p. c.	0,62	-0,000183	

Nelinearni model FLEX = b_1 • GDP p. c. + b_2 • GDP p. c.^{2} + e			
R = 0,20; R^2 = 0,04; F = 0,18; p = 0,84			
	b_1	b_2	p
GDP p. c.	-0,212184	0,000289	0,58
Oznaka	Opis oznake		
R	koeficijent korelacije		
R^2	koeficijent determinacije		
T	vrijednost testne statistike za koeficijent		
F	vrijednost testne statistike za model		
P	nivo statističke značajnosti		
FLEX	fleksibilnost tržišta radne snage		
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku		

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Portugal odbačena.

U tablici 49. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Rumunjsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 49. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Rumunjsku

Linearni model FLEX = b_0 + b_1• GDP p. c. + e			
R = -0,92; R^2 = 0,84; t = -6,87; p < 0,01			
	b_0	b_1	
GDP p. c.	3,25	-0,007026	
Nelinearni model FLEX = b_1 • GDP p. c. + b_2 • GDP p. c.^{2} + e			
R = 0,93; R^2 = 0,86; F = 24,41; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,281585	-0,000382	0,33
Oznaka	Opis oznake		
R	koeficijent korelacije		

R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Nužno je istaknuti da je koeficijent determinacije u linearnom modelu statistički značajan i iznosi 0,84, što ukazuje na to da je 84 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent determinacije je statistički značajan i iznosi 0,86, što ukazuje na to da je 86 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model također statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Rumunjsku potvrđena.

U tablici 50. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Slovačku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 50. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Slovačku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,21; R^2 = 0,05; t = -0,65; p = 0,53			
	b_0	b_1	
GDP p. c.	1,05	-0,001098	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,73; R^2 = 0,54; F = 4,64; p = 0,05			
	b_1	b_2	p
GDP p. c.	1,063040	-0,001295	0,02
Oznaka	Opis oznake		
R	koeficijent korelacije		

R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da je nelinearni model na granici statističke značajnosti. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za Slovačku odbačena.

U tablici 51. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Sloveniju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 51. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Sloveniju

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,40; R^2 = 0,16; t = 1,29; p = 0,23			
	b_0	b_1	
GDP p. c.	0,35	0,000910	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,60; R^2 = 0,36; F = 2,26; p = 0,17			
	b_1	b_2	p
GDP p. c.	0,299232	-0,000373	0,15

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.
Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1. za Sloveniju odbačena.

U tablici 52. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Španjolsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 52. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Španjolsku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,73; R^2 = 0,53; t = 3,16; p = 0,01			
	b_0	b_1	
GDP p. c.	-0,14	0,003206	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,92; R^2 = 0,85; F = 23,26; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,368920	-0,000905	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je također vidljivo da je nelinearni model statistički značajan. Važno je naglasiti da je u nelinearnom modelu koeficijent determinacije statistički značajan i iznosi 0,85, što ukazuje na to da je 85 % varijabiliteta kriterija određeno korištenim prediktorom. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1. za Španjolsku potvrđena.

U tablici 53. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Švedsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 53. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Švedsku

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = 0,91; R^2 = 0,82; t = 6,40; p < 0,01			
	b_0	b_1	
GDP p. c.	-3,10	0,009403	
Nelinearni model FLEX = b_1 • GDP p. c. + b_2 • GDP p. $c.^2$ + e			
R = 1,00; R^2 = 0,99; F = 568,40; p < 0,01			
	b_1	b_2	p
GDP p. c.	1,212281	-0,001546	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.
Interesantno je istaknuti da je koeficijent determinacije u linearnom modelu statistički značajan i iznosi 0,82, što ukazuje na to da je 82 % varijabiliteta kriterija određeno korištenim

prediktorima. U nelinearnom modelu koeficijent determinacije je statistički značajan i iznosi 0,99, što ukazuje na to da je 99 % varijabiliteta kriterija određeno korištenim prediktorima.
Iz tablice je vidljivo da je nelinearni model također statistički značajan. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1. za Švedsku potvrđena.

U tablici 54. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za Ujedinjeno Kraljevstvo. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 54. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Ujedinjeno Kraljevstvo

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c. + e			
R = -0,03; R^2 = 0,0009; t = -0,09; p = 0,93			
	b_0	b_1	
GDP p. c.	0,62	-0,000041	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$ + e			
R = 0,44; R^2 = 0,19; F = 0,96; p = 0,42			
	b_1	b_2	p
GDP p. c.	-0,033551	0,000063	0,20

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
T	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
P	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.
Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla GDP p. c. nema statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1. za Ujedinjeno Kraljevstvo odbačena.

Tablica 55. prikazuje ukupne rezultate istraživanja i analize podataka za hipotezu H1. po državama.

Tablica 55. Ukupni rezultati empirijskog istraživanja po državama i hipotezi H1.

Država	Hipoteza H1.	Država	Hipoteza H1.	Država	Hipoteza H1.
Austrija	Potvrđena	**Hrvatska**	Potvrđena	**Njemačka**	Parcijalno potvrđena
Belgija	Potvrđena	**Irska**	Odbačena	**Poljska**	Potvrđena
Bugarska	Potvrđena	**Italija**	Parcijalno potvrđena	**Portugal**	Odbačena
Cipar	Potvrđena	**Latvija**	Parcijalno potvrđena	**Rumunjska**	Potvrđena
Češka	Parcijalno potvrđena	**Litva**	Potvrđena	**Slovačka**	Odbačena
Danska	Parcijalno potvrđena	**Luksemburg**	Parcijalno potvrđena	**Slovenija**	Odbačena
Estonija	Odbačena	**Mađarska**	Parcijalno potvrđena	**Španjolska**	Potvrđena
Finska	Parcijalno potvrđena	**Malta**	Odbačena	**Švedska**	Potvrđena
Francuska	Potvrđena	**Nizozemska**	Potvrđena	**Ujedinjeno Kraljevstvo**	Odbačena
Grčka	Odbačena				

Izvor: izrada autorice

Tablica 55. prikazuje ukupne rezultate empirijskog istraživanja po državama i hipotezi H1. koja je istraživanjem i analizom potvrđena, parcijalno potvrđena ili odbačena. Rezultati pokazuju da je hipoteza potvrđena za 12 država i to za: Austriju, Belgiju, Bugarsku, Cipar, Francusku, Hrvatsku, Litvu, Nizozemsku, Poljsku, Rumunjsku, Španjolsku i Švedsku. Hipoteza H1. je parcijalno potvrđena za sljedeće države: Češku, Dansku, Finsku, Italiju, Latviju, Luksemburg, Mađarsku i Njemačku. Za države: Estoniju, Grčku, Irsku, Maltu, Portugal, Slovačku, Sloveniju i Ujedinjeno Kraljevstvo hipoteza H1. je odbačena.

7.3.2. Zapošljavanje na nepuno radno vrijeme i privremeno zapošljavanje u korelaciji sa stopom zaposlenosti

U statističkoj obradi hipoteze H1.1, za svaku zemlju EU-a generiran je statistički značajan model:

a) linearne povezanosti kriterijske varijable *stopa zaposlenosti* s prediktorskim varijablama: *privremeno zapošljavanje* i *zapošljavanje na nepuno radno vrijeme*
b) nelinearne povezanosti kriterijske varijable *stopa zaposlenosti* s prediktorskim varijablama: *privremeno zapošljavanje* i *zapošljavanje na nepuno radno vrijeme*

Varijabla *stopa zaposlenosti* u okviru hipoteze H1.1. upotrijebljena je za analizu kao decimalan broj transformiran iz iznosa stope zaposlenosti po godinama za sve države individualno. Jednako tako, u svaki model za svaku državu uvrštena je stohastička varijabla greške (rezidualnog odstupanja) označena slovom e.

Hipoteza H1.1. će biti prihvaćena u slučaju ako je ista potvrđena za sve države ili njih 27 od 28. U slučaju da je hipoteza H1.1. potvrđena ili parcijalno potvrđena za 15 do 26 zemalja, ista će biti parcijalno potvrđena. Hipoteza H1.1. će biti odbačena ako je potvrđena za 14 ili manje zemalja.

U tablici 56. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Austriju. U tablici su k tomu navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 56. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Austriju

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}71$; $R^2 = 0{,}50$; $F = 4{,}05$; $p = 0{,}06$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			55,14	10,23	< 0,01
PZ	0,24	0,29	80,23	98,37	0,44
NRV	0,81	0,29	36,08	13,13	0,03

Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}92$; $R^2 = 0{,}84$; $F = 7{,}84$; $p = 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	26,44	11,49	8866,55	3854,80	0,06
PZ^2	-25,43	11,40	-52591,29	23568,15	0,07
NRV	-34,14	10,62	-1528,45	475,39	0,02
NRV^2	35,46	10,75	2963,65	898,45	0,02

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model na granici statističke značajnosti. Nadalje, u linearnom modelu varijabla PZ nema statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV ima statistički značajan utjecaj na kriterijsku varijablu.

Iz tablice je vidljivo da je nelinearni model statistički značajan. Potrebno je naglasiti da je koeficijent višestruke determinacije u nelinearnom modelu statistički značajan i iznosi 0,84, što ukazuje na to da je 84 % varijabiliteta kriterija određeno korištenim prediktorima.

U nelineranom modelu varijablama PZ i PZ^2 statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti* je na granici, dok varijable NRV i NRV^2 imaju statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.1. za Austriju potvrđena.

U tablici 57. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Belgiju. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 57. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Belgiju

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}43$; $R^2 = 0{,}19$; $F = 0{,}91$; $p = 0{,}44$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			52,12	8,03	< 0,01
PZ	0,28	0,36	62,92	80,54	0,46
NRV	0,22	0,36	21,66	34,55	0,55
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}72$; $R^2 = 0{,}51$; $F = 1{,}59$; $p = 0{,}29$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	15,53	16,04	3490,84	3604,63	0,37
PZ^2	-15,54	16,11	-23238,56	24090,32	0,37
NRV	-29,68	16,17	-2861,72	1558,78	0,12
NRV^2	30,14	16,24	5861,21	3157,46	0,11

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Belgiju odbačena.

U tablici 58. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Bugarsku. U tablici su navedeni i koeficijent višestruke korelacije (R),

koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 58. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Bugarsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}14$; $R^2 = 0{,}02$; $F = 0{,}08$; $p = 0{,}93$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			64,68	11,70	< 0,01
PZ	0,19	0,55	110,45	321,67	0,74
NRV	-0,21	0,55	-273,62	713,24	0,71
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}67$; $R^2 = 0{,}45$; $F = 1{,}25$; $p = 0{,}38$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-11,07	13,05	-6448,70	7606,69	0,43
PZ^2	11,16	13,51	73722,04	89271,36	0,44
NRV	-5,26	8,72	-6792,77	11266,07	0,57
NRV^2	5,08	9,17	126677,91	228768,30	0,60

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Bugarsku odbačena.

U tablici 59. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Cipar. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 59. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Cipar

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}89$; $R^2 = 0{,}79$; $F = 14{,}92$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			79,35	7,45	< 0,01
PZ	0,17	0,80	34,15	156,33	0,83
NRV	-1,06	0,80	-152,57	115,36	0,22
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}89$; $R^2 = 0{,}79$; $F = 5{,}79$; $p = 0{,}03$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	4,88	11,73	952,78	2292,08	0,69
PZ^2	-5,10	12,66	-3872,45	9614,36	0,70
NRV	-3,52	6,62	-507,30	954,26	0,61
NRV^2	2,84	7,69	1784,09	4824,72	0,72

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Interesantno je istaknuti da je koeficijent višestruke determinacije i u linearnom i u nelinearnom modelu statistički značajan i iznosi 0,79, što ukazuje na to da je 79 % varijabiliteta kriterija određeno korištenim prediktorima u obama modelima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Cipar potvrđena.

U tablici 60. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Češku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 60. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Češku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}91$; $R^2 = 0{,}82$; $F = 18{,}72$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			45,42	8,35	< 0,01
PZ	0,04	0,18	26,12	125,48	0,84
NRV	0,89	0,18	320,54	64,59	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}96$; $R^2 = 0{,}91$; $F = 15{,}69$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-5,39	7,89	-3787,53	5540,81	0,52
PZ^2	5,60	7,74	24693,02	34136,17	0,50
NRV	-2,62	3,75	-949,12	1356,16	0,51
NRV^2	3,43	3,64	9048,90	9601,40	0,38

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti

PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ nema statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV ima statistički značajan utjecaj na kriterijsku varijablu.

Nužno je istaknuti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,82, što ukazuje na to da je 82 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,91, što ukazuje na to da je 91 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Češku potvrđena.

U tablici 61. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Dansku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 61. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Dansku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}92$; $R^2 = 0{,}84$; $F = 21{,}40$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			98,94	4,36	< 0,01
PZ	0,12	0,14	18,84	22,80	0,43
NRV	-0,93	0,14	-96,62	14,81	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}93$; $R^2 = 0{,}86$; $F = 9{,}17$; $p = 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-1,12	3,52	-177,90	560,99	0,76
PZ^2	1,28	3,49	1129,27	3065,97	0,73
NRV	-4,56	5,05	-471,46	521,93	0,40

NRV^2	3,67	5,02	678,40	928,52	0,49

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ nema statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV ima statistički značajan utjecaj na kriterijsku varijablu.

Nužno je istaknuti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,84, što ukazuje na to da je 84 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,86, što ukazuje na to da je 86 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Dansku potvrđena.

U tablici 62. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Estoniju. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 62. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Estoniju

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$

R = 0,37; R^2 = 0,14; F = 0,64; p = 0,55					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			71,13	13,12	< 0,01
PZ	-0,38	0,35	-343,80	312,94	0,30
NRV	0,23	0,35	81,77	125,75	0,53
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
R = 0,65; R^2 = 0,42; F = 1,11; p = 0,43					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	5,84	4,01	5222,01	3590,54	0,20
PZ^2	-6,01	3,93	-87194,38	57068,22	0,18
NRV	-4,13	3,78	-1482,74	1357,18	0,32
NRV^2	4,08	3,69	7368,03	6662,67	0,31

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model statistički nije značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Iz tablice je vidljivo da nelinearni model statistički nije značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Estoniju odbačena.

U tablici 63. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Finsku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 63. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Finsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}62$; $R^2 = 0{,}39$; $F = 2{,}53$; $p = 0{,}14$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			49,92	8,73	< 0,01
PZ	1,47	0,71	293,50	141,47	0,07
NRV	-1,11	0,71	-123,63	78,73	0,15
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}88$; $R^2 = 0{,}78$; $F = 5{,}34$; $p = 0{,}04$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-1,95	13,52	-388,94	2703,57	0,89
PZ^2	2,87	13,29	2295,10	10626,69	0,84
NRV	-15,14	8,90	-1684,69	990,30	0,14
NRV^2	14,56	8,73	6000,69	3597,58	0,15

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabli PZ statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti* je na granici, a varijabla NRV nema statistički značajan utjecaj na kriterijsku varijablu.

Iz tablice je vidljivo da je nelinearni model statistički značajan. Potrebno je naglasiti da je koeficijent višestruke determinacije u nelinearnom modelu statistički značajan i iznosi 0,78, što ukazuje na to da je 78 % varijabiliteta kriterija određeno korištenim prediktorima.

U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Finsku parcijalno potvrđena.

U tablici 64. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Francusku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 64. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Francusku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}88$; $R^2 = 0{,}78$; $F = 13{,}79$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			55,21	2,69	< 0,01
PZ	1,12	0,22	118,44	23,17	< 0,01
NRV	-0,52	0,22	-40,11	16,89	0,04
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}89$; $R^2 = 0{,}79$; $F = 5{,}71$; $p = 0{,}03$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	2,65	12,07	280,31	1274,95	0,83
PZ^2	-1,44	11,99	-550,32	4570,33	0,91
NRV	7,36	11,96	566,78	920,93	0,56
NRV^2	-7,94	12,06	-1634,91	2482,30	0,53

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV imaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Potrebno je istaknuti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,78, što ukazuje na to da je 78 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički

značajan i iznosi 0,79, što ukazuje na to da je 79 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Francusku potvrđena.

U tablici 65. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Grčku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 65. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Grčku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}95$; $R^2 = 0{,}91$; $F = 38{,}57$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			51,59	8,57	< 0,01
PZ	0,41	0,11	376,57	101,40	0,01
NRV	-0,80	0,11	-303,31	41,93	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}96$; $R^2 = 0{,}92$; $F = 16{,}84$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	3,15	4,70	2907,62	4337,81	0,53
PZ^2	-2,77	4,67	-18334,60	30909,56	0,57
NRV	-1,89	2,85	-722,39	1088,21	0,53
NRV^2	1,08	2,86	2621,49	6947,58	0,72

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV imaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Važno je naglasiti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,91, što ukazuje na to da je 91 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,92, što ukazuje na to da je 92 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Grčku potvrđena.

U tablici 66. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Hrvatsku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 66. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Hrvatsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}19$; $R^2 = 0{,}03$; $F = 0{,}14$; $p = 0{,}87$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			54,09	16,60	0,01
PZ	0,22	0,64	15,82	46,65	0,74
NRV	0,04	0,64	7,75	131,26	0,95
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}68$; $R^2 = 0{,}47$; $F = 1{,}31$; $p = 0{,}37$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-9,89	5,50	-721,92	401,46	0,12
PZ^2	9,54	5,23	2533,12	1388,86	0,12
NRV	-4,98	4,49	-1023,53	922,06	0,31
NRV^2	4,36	4,41	5255,22	5309,93	0,36

Oznaka	Opis oznake
R	koeficijent višestruke korelacije

R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Iz tablice je vidljivo da nelinearni model statistički nije značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Hrvatsku odbačena.

U tablici 67. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Irsku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 67. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Irsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}87$; $R^2 = 0{,}75$; $F = 12{,}32$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			110,19	9,51	< 0,01
PZ	-0,10	0,21	-53,21	115,63	0,66
NRV	-0,81	0,21	-183,51	46,90	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}87$; $R^2 = 0{,}76$; $F = 4{,}64$; $p = 0{,}05$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-1,13	8,76	-631,04	4870,64	0,90
PZ^2	1,03	8,74	3816,05	32222,81	0,91

NRV	-0,69	7,04	-156,10	1587,93	0,92
NRV^2	-0,11	7,03	-55,85	3533,54	0,99

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ nema statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV ima statistički značajan utjecaj na kriterijsku varijablu.

Potrebno je istaknuti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,75, što ukazuje na to da je 75 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,76, što ukazuje na to da je 76 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model na granici statističke značajnosti. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Irsku potvrđena.

U tablici 68. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Italiju. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 68. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Italiju

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}87$; $R^2 = 0{,}75$; $F = 12{,}09$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			52,78	2,07	< 0,01
PZ	1,05	0,22	113,62	23,93	< 0,01
NRV	-0,86	0,22	-44,51	11,48	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}98$; $R^2 = 0{,}95$; $F = 30{,}51$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	6,23	2,32	676,02	251,67	0,04
PZ^2	-5,24	2,28	-2544,38	1110,05	0,06
NRV	-15,50	3,08	-806,18	160,38	< 0,01
NRV^2	14,58	3,09	2253,37	477,98	< 0,01

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV imaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Nužno je naglasiti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,75, što ukazuje na to da je 75 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,95, što ukazuje na to da je 95 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, NRV i NRV^2 imaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Varijabla PZ^2 nema statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.1. za Italiju potvrđena.

U tablici 69. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa*

zaposlenosti za Latviju. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 69. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Latviju

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}87$; $R^2 = 0{,}76$; $F = 12{,}67$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			81,50	7,72	< 0,01
PZ	-0,72	0,25	-216,56	74,94	0,02
NRV	-0,20	0,25	-87,81	109,69	0,45
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}92$; $R^2 = 0{,}84$; $F = 7{,}82$; $p = 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-2,89	1,43	-871,89	430,76	0,09
PZ^2	2,24	1,39	7257,72	4490,76	0,16
NRV	2,21	3,37	974,74	1489,35	0,54
NRV^2	-2,41	3,48	-6174,85	8915,97	0,51

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ ima statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV nema statistički značajan utjecaj na kriterijsku varijablu.

Interesantno je istaknuti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,76, što ukazuje na to da je 76 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također

statistički značajan i iznosi 0,84, što ukazuje na to da je 84 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Latviju potvrđena.

U tablici 70. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Litvu. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 70. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Litvu

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0,77$; $R^2 = 0,59$; $F = 5,68$; $p = 0,03$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			69,83	13,44	< 0,01
PZ	-0,83	0,25	-1033,77	307,99	0,01
NRV	0,25	0,25	165,49	161,06	0,33
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0,87$; $R^2 = 0,75$; $F = 4,59$; $p = 0,05$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-3,89	2,28	-4856,66	2853,69	0,14
PZ^2	2,92	2,33	97961,11	78304,99	0,26
NRV	-6,89	5,17	-4498,77	3377,29	0,23
NRV^2	7,13	5,24	26545,30	19500,73	0,22

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ ima statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV nema statistički značajan utjecaj na kriterijsku varijablu.
Iz tablice je vidljivo da je nelinearni model na granici statističke značajnosti. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.
Time je hipoteza H 1.1. za Litvu potvrđena.

U tablici 71. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Luksemburg. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 71. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Luksemburg

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}79$; $R^2 = 0{,}62$; $F = 6{,}64$; $p = 0{,}02$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			56,07	4,53	< 0,01
PZ	0,75	0,22	83,54	24,45	0,01
NRV	0,19	0,22	18,51	21,26	0,41
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}94$; $R^2 = 0{,}88$; $F = 11{,}09$; $p = 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	9,50	3,12	1064,83	349,40	0,02
PZ^2	-8,64	3,11	-6926,74	2492,21	0,03
NRV	-15,76	7,39	-1535,86	719,87	0,08
NRV^2	15,68	7,39	3653,61	1721,29	0,08

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane

St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ ima statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV nema statistički značajan utjecaj na kriterijsku varijablu.

Iz tablice je vidljivo da je nelinearni model statistički značajan. Potrebno je naglasiti da je koeficijent višestruke determinacije u nelinearnom modelu statistički značajan i iznosi 0,88, što ukazuje na to da je 88 % varijabiliteta kriterija određeno korištenim prediktorima.

U nelinearnom modelu varijable PZ i PZ^2 imaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Varijable NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.1. za Luksemburg potvrđena.

U tablici 72. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Mađarsku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 72. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Mađarsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}82$; $R^2 = 0{,}68$; $F = 8{,}46$; $p = 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			67,97	9,35	< 0,01
PZ	0,64	0,21	224,77	75,44	0,02
NRV	-0,80	0,21	-514,45	138,64	0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}92$; $R^2 = 0{,}84$; $F = 8{,}14$; $p = 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	1,98	2,57	697,99	904,32	0,47
PZ^2	-1,20	2,57	-2000,10	4280,72	0,66
NRV	-8,78	3,53	-5681,06	2286,36	0,05

NRV^2	7,93	3,52	42277,12	18761,94	0,07

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV imaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Iz tablice je vidljivo da je nelinearni model statistički značajan. Potrebno je naglasiti da je koeficijent višestruke determinacije u nelinearnom modelu statistički značajan i iznosi 0,84, što ukazuje na to da je 84 % varijabiliteta kriterija određeno korištenim prediktorima.
U nelinearnom modelu varijable PZ i PZ^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Varijabla NRV ima statistički značajan utjecaj na kriterijsku varijablu, dok je varijabli NRV^2 statistički značajan utjecaj na kriterijsku varijablu na granici. Time je hipoteza H 1.1. za Mađarsku potvrđena.

U tablici 73. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Maltu. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 73. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Maltu

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0,87$; $R^2 = 0,76$; $F = 11,03$; $p = 0,01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			16,72	10,21	0,15
PZ	-0,73	0,33	-474,87	217,39	0,07

NRV	1,38	0,33	491,21	118,94	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0,90$; $R^2 = 0,81$; $F = 5,40$; $p = 0,05$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-0,50	6,64	-323,58	4332,67	0,94
PZ^2	-0,30	6,42	-1754,13	37877,29	0,96
NRV	5,55	8,24	1980,54	2942,93	0,53
NRV^2	-4,13	8,03	-5074,30	9873,35	0,63

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ nema statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV ima statistički značajan utjecaj na kriterijsku varijablu.

Potrebno je naglasiti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,76, što ukazuje na to da je 76 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,81, što ukazuje na to da je 81 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model na granici statističke značajnosti. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Maltu potvrđena.

U tablici 74. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Nizozemsku. U tablici su navedeni i koeficijent višestruke korelacije (R),

koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 74. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Nizozemsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}38$; $R^2 = 0{,}14$; $F = 0{,}66$; $p = 0{,}55$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			79,04	12,75	< 0,01
PZ	0,72	0,67	62,97	59,06	0,32
NRV	-0,49	0,67	-28,58	39,23	0,49
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}55$; $R^2 = 0{,}30$; $F = 0{,}64$; $p = 0{,}65$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-3,23	11,37	-283,46	997,79	0,79
PZ^2	3,63	11,12	980,27	2999,69	0,75
NRV	-20,42	27,33	-1189,63	1592,40	0,48
NRV^2	20,24	27,30	1158,74	1562,67	0,49

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Nizozemsku odbačena.

U tablici 75. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Njemačku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 75. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Njemačku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}94$; $R^2 = 0{,}88$; $F = 29{,}31$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			51,35	38,86	0,22
PZ	-0,40	0,38	-123,51	119,43	0,33
NRV	0,55	0,38	132,16	92,01	0,19
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}94$; $R^2 = 0{,}88$; $F = 11{,}43$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-5,40	11,85	-1675,41	3679,62	0,66
PZ^2	4,88	11,62	6416,23	15284,74	0,69
NRV	8,51	18,34	2035,23	4386,79	0,66
NRV^2	-8,07	18,58	-3524,06	8113,59	0,68

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Zanimljivo je istaknuti da je koeficijent višestruke determinacije i u linearnom i u nelinearnom modelu statistički značajan i iznosi 0,88, što ukazuje na to da je 88 % varijabiliteta kriterija određeno korištenim prediktorima u obama modelima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Njemačku potvrđena.

U tablici 76. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Poljsku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 76. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Poljsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}89$; $R^2 = 0{,}78$; $F = 14{,}59$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			138,12	19,78	< 0,01
PZ	-0,36	0,17	-185,95	84,84	0,06
NRV	-0,86	0,17	-454,69	87,82	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}95$; $R^2 = 0{,}90$; $F = 13{,}87$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-7,34	6,73	-3765,17	3452,82	0,32
PZ^2	7,11	6,73	8927,37	8454,37	0,33
NRV	-14,40	5,81	-7646,86	3085,56	0,05
NRV^2	13,63	5,81	42412,81	18084,52	0,06

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti

PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabli PZ statistički značajan utjecaj na kriterijsku varijablu je na granici, a varijabla NRV ima statistički značajan utjecaj na kriterijsku varijablu.

Važno je istaknuti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,78, što ukazuje na to da je 78 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,90, što ukazuje na to da je 90 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ i PZ^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Varijablama NRV i NRV^2 statistički značajan utjecaj na kriterijsku varijablu je na granici.

Time je hipoteza H 1.1. za Poljsku potvrđena.

U tablici 77. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Portugal. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 77. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Portugal

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}90$; $R^2 = 0{,}81$; $F = 17{,}21$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			89,24	19,68	< 0,01
PZ	-0,03	0,24	-13,33	90,80	0,89
NRV	-0,93	0,24	-159,96	40,92	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}97$; $R^2 = 0{,}93$; $F = 20{,}94$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	15,35	9,88	5878,65	3782,18	0,17
PZ^2	-15,04	9,73	-17530,60	11334,29	0,17
NRV	-13,07	4,17	-2255,27	719,69	0,02

NRV^2	12,50	4,33	7479,70	2589,52	0,03

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ nema statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV ima statistički značajan utjecaj na kriterijsku varijablu.

Potrebno je naglasiti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,81, što ukazuje na to da je 81 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,93, što ukazuje na to da je 93 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ i PZ^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, dok varijable NRV i NRV^2 imaju statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.1. za Portugal potvrđena.

U tablici 78. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Rumunjsku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 78. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Rumunjsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$

R = 0,89; R^2 = 0,80; F = 15,80; p < 0,01					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			73,88	3,87	< 0,01
PZ	0,10	0,17	153,47	244,67	0,55
NRV	-0,86	0,17	-134,89	25,91	< 0,01
Nelinearni model SZ = b_1 • PZ + b_2 • PZ^2 + b_3 • NRV + b_4 • NRV^2 + e					
R = 0,96; R^2 = 0,92; F = 16,98; p < 0,01					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	0,28	1,98	409,35	2935,60	0,89
PZ^2	0,06	2,00	5448,95	185388,92	0,98
NRV	-10,23	3,40	-1605,11	533,19	0,02
NRV^2	9,44	3,40	7400,56	2669,27	0,03

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ nema statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV ima statistički značajan utjecaj na kriterijsku varijablu.

Nužno je istaknuti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,80, što ukazuje na to da je 80 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,92, što ukazuje na to da je 92 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ i PZ^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, dok varijable NRV i NRV^2 imaju statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.1. za Rumunjsku potvrđena.

U tablici 79. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba*, *udio zaposlenih osoba na nepuno radno vrijeme* te *stopa*

zaposlenosti za Slovačku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 79. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Slovačku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}65$; $R^2 = 0{,}43$; $F = 2{,}97$; $p = 0{,}11$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			54,07	3,55	< 0,01
PZ	0,06	0,88	10,26	146,25	0,95
NRV	0,59	0,88	146,17	216,15	0,52
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}87$; $R^2 = 0{,}76$; $F = 4{,}87$; $p = 0{,}04$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	2,07	2,42	344,00	403,00	0,43
PZ^2	-2,82	2,47	-3661,60	3202,53	0,30
NRV	-5,50	2,33	-1354,52	572,83	0,06
NRV^2	6,90	2,50	17153,95	6215,30	0,03

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ i PZ^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Varijabli NRV statistički značajan utjecaj na kriterijsku varijablu je na granici, a varijabla NRV^2 ima statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Slovačku parcijalno potvrđena.

U tablici 80. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Sloveniju. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 80. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Sloveniju

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}24$; $R^2 = 0{,}06$; $F = 0{,}25$; $p = 0{,}79$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			50,14	26,01	0,09
PZ	0,25	0,35	95,14	136,11	0,50
NRV	0,07	0,35	23,62	124,98	0,85
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}29$; $R^2 = 0{,}08$; $F = 0{,}13$; $p = 0{,}96$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-7,18	18,69	-2784,88	7246,90	0,71
PZ^2	7,42	18,66	10093,21	25393,28	0,70
NRV	-2,18	14,28	-777,51	5083,86	0,88
NRV^2	2,21	14,24	3587,98	23108,92	0,88

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Sloveniju odbačena.

U tablici 81. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Španjolsku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 81. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Španjolsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}97$; $R^2 = 0{,}94$; $F = 67{,}68$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			35,68	4,98	< 0,01
PZ	0,82	0,09	170,85	17,88	< 0,01
NRV	-0,35	0,09	-74,31	18,49	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0{,}98$; $R^2 = 0{,}95$; $F = 31{,}39$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-0,30	2,95	-62,66	610,90	0,92
PZ^2	1,17	2,97	598,98	1525,65	0,71
NRV	2,93	2,84	627,16	609,51	0,34
NRV^2	-3,26	2,83	-2462,37	2136,52	0,29

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV imaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Važno je naglasiti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,94, što ukazuje na to da je 94 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 0,95, što ukazuje na to da je 95 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.
Time je hipoteza H 1.1. za Španjolsku potvrđena.

U tablici 82. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba*, *udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Švedsku. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 82. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Švedsku

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0{,}99$; $R^2 = 0{,}98$; $F = 206{,}31$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			108,63	2,28	< 0,01
PZ	0,47	0,05	86,31	9,34	< 0,01
NRV	-1,03	0,05	-174,81	8,71	< 0,01
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 1{,}00$; $R^2 = 1{,}00$; $F = 311{,}57$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	3,01	1,05	546,93	191,62	0,03
PZ^2	-2,53	1,06	-1645,74	687,93	0,05
NRV	6,32	1,76	1071,41	297,66	0,01
NRV^2	-7,31	1,75	-2363,21	565,15	0,01

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije

F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV imaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Interesantno je istaknuti da je koeficijent višestruke determinacije u linearnom modelu statistički značajan i iznosi 0,98, što ukazuje na to da je 98 % varijabiliteta kriterija određeno korištenim prediktorima. U nelinearnom modelu koeficijent višestruke determinacije je također statistički značajan i iznosi 1,00, što ukazuje na to da je 100 % varijabiliteta kriterija određeno korištenim prediktorima.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, NRV i NRV^2 imaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*. Varijabli PZ^2 statistički značajan utjecaj na kriterijsku varijablu je na granici.

Time je hipoteza H 1.1. za Švedsku potvrđena.

U tablici 83. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za Ujedinjeno Kraljevstvo. U tablici su navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Tablica 83. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Ujedinjeno Kraljevstvo

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV + e$					
$R = 0,47$; $R^2 = 0,22$; $F = 1,11$; $p = 0,38$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			53,95	30,31	0,11
PZ	-0,61	0,41	-496,44	334,12	0,18
NRV	0,43	0,41	144,71	138,09	0,33

Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2 + e$					
$R = 0,53$; $R^2 = 0,28$; $F = 0,57$; $p = 0,69$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-6,52	22,50	-5345,86	18444,01	0,78
PZ^2	6,23	23,10	58069,57	215221,73	0,80
NRV	29,12	47,60	9865,02	16124,17	0,56
NRV^2	-28,96	48,19	-18105,23	30125,24	0,57

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijable PZ i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijable PZ, PZ^2, NRV i NRV^2 nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*.

Time je hipoteza H 1.1. za Ujedinjeno Kraljevstvo odbačena.

Tablica 84. prikazuje ukupne rezultate istraživanja i analize podataka za hipotezu H1. po državama.

Tablica 84. Ukupni rezultati empirijskog istraživanja po državama i hipotezi H1.1.

Država	Hipoteza H1.1.	Država	Hipoteza H1.1.	Država	Hipoteza H1.1.
Austrija	Potvrđena	**Hrvatska**	Odbačena	**Njemačka**	Potvrđena
Belgija	Odbačena	**Irska**	Potvrđena	**Poljska**	Potvrđena
Bugarska	Odbačena	**Italija**	Potvrđena	**Portugal**	Potvrđena
Cipar	Potvrđena	**Latvija**	Potvrđena	**Rumunjska**	Potvrđena
Češka	Potvrđena	**Litva**	Potvrđena	**Slovačka**	Parcijalno potvrđena

Danska	Potvrđena	**Luksemburg**	Potvrđena	**Slovenija**	Odbačena
Estonija	Odbačena	**Mađarska**	Potvrđena	**Španjolska**	Potvrđena
Finska	Parcijalno potvrđena	**Malta**	Potvrđena	**Švedska**	Potvrđena
Francuska	Potvrđena	**Nizozemska**	Odbačena	**Ujedinjeno Kraljevstvo**	Odbačena
Grčka	Potvrđena				

Izvor: izrada autorice

Tablica 84. prikazuje ukupne rezultate empirijskog istraživanja po državama i hipotezi H1.1. koja je istraživanjem i analizom potvrđena, parcijalno potvrđena ili odbačena. Rezultati pokazuju da je hipoteza potvrđena za 19 država i to za: Austriju, Cipar, Češku, Dansku, Francusku, Grčku, Irsku, Italiju, Latviju, Litvu, Luksemburg, Mađarsku, Maltu, Njemačku, Poljsku, Portugal, Rumunjsku, Španjolsku i Švedsku. Hipoteza H1. je parcijalno potvrđena za sljedeće države: Finsku i Slovačku. Za države: Belgiju, Bugarsku, Estoniju, Hrvatsku, Nizozemsku, Sloveniju i Ujedinjeno Kraljevstvo hipoteza H1. je odbačena.

7.3.3. Učinak povećanja rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće na smanjenje stope nezaposlenosti

U statističkoj obradi hipoteze H1.2 za svaku zemlju EU-a generiran je statistički značajan model:

a) linearne povezanosti kriterijske varijable *stopa nezaposlenosti* s prediktorskom varijablom *SENSSH*
b) nelinearne povezanosti kriterijske varijable *stopa nezaposlenosti* s prediktorskom varijablom *SENSSH*

Varijabla *stopa nezaposlenosti* u okviru hipoteze H1.2. upotrijebljena je za analizu kao decimalan broj transformiran iz iznosa stope nezaposlenosti po godinama za sve države individualno. Jednako tako, u svaki model za svaku državu uvrštena je stohastička varijabla greške (rezidualnog odstupanja) označena slovom e.

Hipoteza H1.2. će biti prihvaćena u slučaju ako je ista potvrđena za sve države ili njih 27 od 28. U slučaju da je hipoteza H1.2. potvrđena ili parcijalno potvrđena za 15 do 26 zemalja, ista će biti parcijalno potvrđena. Hipoteza H1.2. će biti odbačena ako je potvrđena za 14 ili manje zemalja.

U tablici 85. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Austriju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 85. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Austriju

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,70; R^2 = 0,48; t = -2,90; p = 0,02			
	b_0	b_1	
SENSSH	15,90	-0,000206	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,70; R^2 = 0,49; F = 4,38; p = 0,05			
	b_1	b_2	p
SENSSH	0,000000	0,000394	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da je nelinearni model na granici statističke značajnosti. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1.2. za Austriju potvrđena.

U tablici 86. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba*

koje imaju fleksibilni oblik radnog odnosa s varijablom *stopa nezaposlenosti* za Belgiju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 86. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Belgiju

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,70; R^2 = 0,48; t = 2,91; p = 0,02			
	b_0	b_1	
SENSSH	5,37	0,000116	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ SENSSH^2 + e			
R = 0,73; R^2 = 0,53; F = 5,13; p = 0,03			
	b_1	b_2	p
SENSSH	0,000000	0,000873	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1.2. za Belgiju potvrđena.

U tablici 87. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Bugarsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 87. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Bugarsku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,63; R^2 = 0,40; t = -2,45; p = 0,04			
	b_0	b_1	
SENSSH	20,86	-0,001920	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,57; R^2 = 0,33; F = 2,19; p = 0,17			
	b_1	b_2	p
SENSSH	0,000000	0,004424	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Bugarsku parcijalno potvrđena.

U tablici 88. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Cipar. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 88. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Cipar

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,64; R^2 = 0,41; t = -2,49; p = 0,03			
	b_0	b_1	
SENSSH	57,09	-0,005070	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,61; R^2 = 0,38; F = 2,73; p = 0,12			
	b_1	b_2	p
SENSSH	-0,000001	0,007024	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije

R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1.2. za Cipar parcijalno potvrđena.

U tablici 89. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Češku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 89. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Češku

Linearni model $SNZ = b_0 + b_1 \bullet SENSSH + e$			
$R = 0{,}24$; $R^2 = 0{,}06$; $t = 0{,}75$; $p = 0{,}47$			
	b_0	b_1	
SENSSH	4,95	0,000021	
Nelinearni model $SNZ = b_1 \bullet SENSSH + b_2 \bullet SENSSH^2 + e$			
$R = 0{,}54$; $R^2 = 0{,}30$; $F = 1{,}90$; $p = 0{,}20$			
	b_1	b_2	p
SENSSH	0,000000	0,000638	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Češku odbačena.

U tablici 90. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Dansku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 90. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Dansku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,73; R^2 = 0,54; t = 3,25; p = 0,01			
	b_0	b_1	
SENSSH	-2,74	0,000224	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,74; R^2 = 0,54; F = 5,29; p = 0,03			
	b_1	b_2	p
SENSSH	0,000000	0,000086	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Dansku potvrđena.

U tablici 91. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Estoniju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 91. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Estoniju

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,74; R^2 = 0,55; t = -3,35; p = 0,01			
	b_0	b_1	
SENSSH	23,50	-0,002487	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,55; R^2 = 0,30; F = 1,96; p = 0,20			
	b_1	b_2	p
SENSSH	-0,000001	0,004856	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Estoniju parcijalno potvrđena.

U tablici 92. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Finsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 92. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Finsku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,64; R^2 = 0,40; t = -2,47; p = 0,04			
	b_0	b_1	
SENSSH	16,76	-0,000612	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,67; R^2 = 0,45; F = 3,75; p = 0,06			
	b_1	b_2	p
SENSSH	0,000000	0,001709	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da je nelinearni model na granici statističke značajnosti. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1.2. za Finsku potvrđena.

U tablici 93. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Francusku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 93. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Francusku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,51; R^2 = 0,26; t = -1,77; p = 0,11			
	b_0	b_1	
SENSSH	10,23	-0,000013	

Oznaka	Opis oznake
R	koeficijent korelacije

R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Zbog nedostatka podataka nelinearni model nije mogao biti generiran.

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Time je hipoteza H 1.2. za Francusku odbačena.

U tablici 94. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Grčku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 94. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Grčku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,96; R^2 = 0,93; t = -11,0; p < 0,01			
	b_0	b_1	
SENSSH	52,06	-0,000498	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,95; R^2 = 0,90; F = 41,74; p < 0,01			
	b_1	b_2	p
SENSSH	0,000000	0,001043	< 0,01
Oznaka	Opis oznake		
R	koeficijent korelacije		
R^2	koeficijent determinacije		
t	vrijednost testne statistike za koeficijent		
F	vrijednost testne statistike za model		
p	nivo statističke značajnosti		
SNZ	stopa nezaposlenosti		
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa		

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. Potrebno je naglasiti da je koeficijent determinacije u nelinearnom modelu statistički značajan i iznosi 0,90, što ukazuje na to da je 90 % varijabiliteta kriterija određeno korištenim prediktorom.

U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Grčku potvrđena.

U tablici 95. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Hrvatsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 95. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Hrvatsku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,49; R^2 = 0,24; t = -1,67; p = 0,13			
	b_0	b_1	
SENSSH	25,00	-0,001180	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,56; R^2 = 0,32; F = 2,08; p = 0,18			
	b_1	b_2	p
SENSSH	0,000000	0,003669	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Hrvatsku odbačena.

U tablici 96. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Irsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 96. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Irsku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,26; R^2 = 0,07; t = 0,81; p = 0,44			
	b_0	b_1	
SENSSH	6,90	0,000080	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,51; R^2 = 0,26; F = 1,61; p = 0,25			
	b_1	b_2	p
SENSSH	0,000000	0,000393	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Irsku odbačena.

U tablici 97. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Italiju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 97. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Italiju

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,95; R^2 = 0,90; t = -8,77; p < 0,01			
	b_0	b_1	
SENSSH	31,05	-0,000188	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,91; R^2 = 0,83; F = 21,81; p < 0,01			
	b_1	b_2	p
SENSSH	0,000000	0,000344	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Interesantno je istaknuti da je koeficijent determinacije u linearnom modelu statistički značajan i iznosi 0,90, što ukazuje na to da je 90 % varijabiliteta kriterija određeno korištenim prediktorom. U nelinearnom modelu koeficijent determinacije je također statistički značajan i iznosi 0,83, što ukazuje na to da je 83 % varijabiliteta kriterija određeno korištenim prediktorom.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Italiju potvrđena.

U tablici 98. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Latviju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 98. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Latviju

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,31; R^2 = 0,09; t = 0,96; p = 0,36			
	b_0	b_1	
SENSSH	8,29	0,000598	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,55; R^2 = 0,30; F = 1,95; p = 0,20			
	b_1	b_2	p
SENSSH	0,000000	0,004951	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Latviju odbačena.

U tablici 99. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Litvu. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 99. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Litvu

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,19; R^2 = 0,04; t = 0,59; p = 0,57			
	b_0	b_1	
SENSSH	1,88	0,000695	

Nelinearni model SNZ = b_1 • SENSSH + b_2 • SENSSH^2 + e			
R = 0,20; R^2 = 0,04; F = 0,20; p = 0,83			
	b_1	b_2	p
SENSSH	0,000000	0,001145	< 0,01
Oznaka	Opis oznake		
R	koeficijent korelacije		
R^2	koeficijent determinacije		
t	vrijednost testne statistike za koeficijent		
F	vrijednost testne statistike za model		
p	nivo statističke značajnosti		
SNZ	stopa nezaposlenosti		
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa		

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Litvu odbačena.

U tablici 100. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Luksemburg. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 100. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Luksemburg

Linearni model SNZ = b_0 + b_1• SENSSH + e			
R = 0,43; R^2 = 0,18; t = 1,42; p = 0,19			
	b_0	b_1	
SENSSH	4,77	0,000134	
Oznaka	Opis oznake		
R	koeficijent korelacije		
R^2	koeficijent determinacije		
t	vrijednost testne statistike za koeficijent		
F	vrijednost testne statistike za model		
p	nivo statističke značajnosti		
SNZ	stopa nezaposlenosti		
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa		

Izvor: izrada autorice

Zbog nedostatka podataka, nelinearni model nije mogao biti generiran.

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Time je hipoteza H 1.2. za Luksemburg odbačena.

U tablici 101. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Mađarsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 101. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Mađarsku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,83; R^2 = 0,69; t = 4,44; p < 0,01			
	b_0	b_1	
SENSSH	-31,24	0,000827	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,82; R^2 = 0,68; F = 9,59; p < 0,01			
	b_1	b_2	p
SENSSH	0,000000	-0,000508	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Mađarsku potvrđena.

U tablici 102. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Maltu. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 102. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Maltu

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,13; R^2 = 0,02; t = -0,39; p = 0,70			
	b_0	b_1	
SENSSH	6,05	-0,000080	

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Zbog nedostatka podataka nelinearni model nije mogao biti generiran.

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Time je hipoteza H 1.2. za Maltu odbačena.

U tablici 103. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Nizozemsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 103. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Nizozemsku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e

R = -0,77; R^2 = 0,59; t = -3,59; p = 0,01			
	b_0	b_1	
SENSSH	18,63	-0,000404	
Nelinearni model SNZ = b_1 • SENSSH + b_2 • $SENSSH^2$ + e			
R = 0,75; R^2 = 0,57; F = 5,90; p = 0,02			
	b_1	b_2	p
SENSSH	0,000000	0,000704	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Nizozemsku potvrđena.

U tablici 104. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Njemačku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 104. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Njemačku

Linearni model SNZ = b_0 + b_1• SENSSH + e			
R = -0,86; R^2 = 0,75; t = -5,01; p < 0,01			
	b_0	b_1	
SENSSH	7,30	-0,000020	

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Zbog nedostatka podataka nelinearni model nije mogao biti generiran.
Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Time je hipoteza H 1.2. za Njemačku potvrđena.

U tablici 105. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Poljsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 105. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Poljsku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,69; R^2 = 0,47; t = 2,85; p = 0,02			
	b_0	b_1	
SENSSH	1,27	0,000076	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,68; R^2 = 0,46; F = 3,83; p = 0,06			
	b_1	b_2	p
SENSSH	0,000000	0,000096	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da je nelinearni model na granici statističke značajnosti. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1.2. za Poljsku potvrđena.

U tablici 106. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Portugal. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 106. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Portugal

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = -0,62; R^2 = 0,39; t = -2,39; p = 0,04			
	b_0	b_1	
SENSSH	43,03	-0,000819	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,60; R^2 = 0,36; F = 2,59; p = 0,13			
	b_1	b_2	p
SENSSH	0,000000	0,001353	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Portugal parcijalno potvrđena.

U tablici 107. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Rumunjsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 107. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Rumunjsku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,29; R^2 = 0,08; t = 0,89; p = 0,40			
	b_0	b_1	
SENSSH	0,34	0,000101	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,29; R^2 = 0,08; F = 0,40; p = 0,68			
	b_1	b_2	p
SENSSH	0,000000	0,000114	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Rumunjsku odbačena.

U tablici 108. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Slovačku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 108. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Slovačku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,44; R^2 = 0,20; t = 1,49; p = 0,17			
	b_0	b_1	
SENSSH	-5,07	0,000684	

Nelinearni model SNZ = b_1 • SENSSH + b_2 • SENSSH^2 + e			
R = 0,43; R^2 = 0,18; F = 1,00; p = 0,40			
	b_1	b_2	p
SENSSH	0,000000	0,000390	< 0,01
Oznaka	Opis oznake		
R	koeficijent korelacije		
R^2	koeficijent determinacije		
t	vrijednost testne statistike za koeficijent		
F	vrijednost testne statistike za model		
p	nivo statističke značajnosti		
SNZ	stopa nezaposlenosti		
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa		

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Slovačku odbačena.

U tablici 109. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Sloveniju. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 109. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Sloveniju

Linearni model SNZ = b_0 + b_1• SENSSH + e			
R = -0,84; R^2 = 0,71; t = -4,65; p < 0,01			
	b_0	b_1	
SENSSH	30,96	-0,001144	
Nelinearni model SNZ = b_1 • SENSSH + b_2 • SENSSH^2 + e			
R = 0,85; R^2 = 0,72; F = 11,62; p < 0,01			
	b_1	b_2	p
SENSSH	0,000000	0,001879	< 0,01
Oznaka	Opis oznake		
R	koeficijent korelacije		
R^2	koeficijent determinacije		
t	vrijednost testne statistike za koeficijent		
F	vrijednost testne statistike za model		
p	nivo statističke značajnosti		

SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*. Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1.2. za Sloveniju potvrđena.

U tablici 110. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Španjolsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 110. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Španjolsku

Linearni model $SNZ = b_0 + b_1 \bullet SENSSH + e$			
$R = -0{,}45$; $R^2 = 0{,}20$; $t = -1{,}52$; $p = 0{,}16$			
	b_0	b_1	
SENSSH	82,16	-0,003002	
Nelinearni model $SNZ = b_1 \bullet SENSSH + b_2 \bullet SENSSH^2 + e$			
$R = 0{,}46$; $R^2 = 0{,}22$; $F = 1{,}24$; $p = 0{,}34$			
	b_1	b_2	p
SENSSH	0,000000	0,004967	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1.2. za Španjolsku odbačena.

U tablici 111. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za Švedsku. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 111. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Švedsku

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,50; R^2 = 0,25; t = 1,74; p = 0,12			
	b_0	b_1	
SENSSH	3,53	0,000045	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,46; R^2 = 0,21; F = 1,21; p = 0,34			
	b_1	b_2	p
SENSSH	0,000000	0,000123	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da linearni model nije statistički značajan. Nadalje, u linearnom modelu varijabla *SENSSH* nema statistički značajan utjecaj na kriterijsku varijablu *stopa nezaposlenosti*.
Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.
Time je hipoteza H 1.2. za Švedsku odbačena.

U tablici 112. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba*

koje imaju fleksibilni oblik radnog odnosa s varijablom *stopa nezaposlenosti* za Ujedinjeno Kraljevstvo. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Tablica 112. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Ujedinjeno Kraljevstvo

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH + e			
R = 0,58; R^2 = 0,32; t = 2,06; p = 0,07			
	b_0	b_1	
SENSSH	-3,65	0,000405	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$ + e			
R = 0,58; R^2 = 0,33; F = 2,24; p = 0,16			
	b_1	b_2	p
SENSSH	0,000000	0,000087	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model na granici statističke značajnosti. Nadalje, u linearnom modelu varijabli *SENSSH* statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti* je na granici.

Iz tablice je vidljivo da nelinearni model nije statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za Ujedinjeno Kraljevstvo odbačena.

Tablica 113. prikazuje ukupne rezultate istraživanja i analize podataka za hipotezu H1.2. po državama.

Tablica 113. Ukupni rezultati empirijskog istraživanja po državama i hipotezi H1.2.

Država	Hipoteza H1.2.	Država	Hipoteza H1.2.	Država	Hipoteza H1.2.
Austrija	Potvrđena	**Hrvatska**	Odbačena	**Njemačka**	Potvrđena
Belgija	Potvrđena	**Irska**	Odbačena	**Poljska**	Potvrđena
Bugarska	Parcijalno potvrđena	**Italija**	Potvrđena	**Portugal**	Parcijalno potvrđena

Cipar	Parcijalno potvrđena	**Latvija**	Odbačena	**Rumunjska**	Odbačena
Češka	Odbačena	**Litva**	Odbačena	**Slovačka**	Odbačena
Danska	Potvrđena	**Luksemburg**	Odbačena	**Slovenija**	Potvrđena
Estonija	Parcijalno potvrđena	**Mađarska**	Potvrđena	**Španjolska**	Odbačena
Finska	Potvrđena	**Malta**	Odbačena	**Švedska**	Odbačena
Francuska	Odbačena	**Nizozemska**	Potvrđena	**Ujedinjeno Kraljevstvo**	Odbačena
Grčka	Potvrđena				

Izvor: izrada autorice

Tablica 113. prikazuje ukupne rezultate empirijskog istraživanja po državama i hipotezi H1.2. koja je istraživanjem i analizom potvrđena, parcijalno potvrđena ili odbačena. Rezultati pokazuju da je hipoteza potvrđena za 11 država i to za: Austriju, Belgiju, Dansku, Finsku, Grčku, Italiju, Mađarsku, Nizozemsku, Njemačku, Poljsku i Sloveniju. Hipoteza H1.2. je parcijalno potvrđena za sljedeće države: Bugarsku, Cipar, Estoniju i Portugal. Za države: Češku, Francusku, Hrvatsku, Latviju, Litvu, Luksemburg, Maltu, Rumunjsku, Slovačku, Španjolsku, Švedsku i Ujedinjeno Kraljevstvo hipoteza H1.2. je odbačena.

7.3.4. Značaj razine obrazovanja u okviru zaposlenosti na određeno radno vrijeme i zaposlenosti na nepuno radno vrijeme

U statističkoj obradi hipoteze H2. za svaku zemlju EU-a identificirano je postojanje statistički značajne razlike između proporcije visokoobrazovanih osoba zaposlenih na ugovor o radu na određeno vrijeme te proporcija srednjeobrazovanih i niskoobrazovanih osoba zaposlenih na ugovor o radu na određeno vrijeme. Također, identificirano je postojanje statistički značajne razlike između proporcije visokoobrazovanih osoba zaposlenih na nepuno radno vrijeme te proporcija srednjeobrazovanih i niskoobrazovanih osoba zaposlenih na nepuno radno vrijeme.

Hipoteza H2. će biti prihvaćena u slučaju da je ista potvrđena za sve države ili njih 27 od 28. U slučaju da je hipoteza H2. potvrđena ili parcijalno potvrđena za 15 do 26 zemalja, ista će biti parcijalno potvrđena. Hipoteza H2. će biti odbačena ako je potvrđena za 14 ili manje zemalja.

U tablici 114. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Austriju. U tablici 114. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Austriju.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 114. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Austriju

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,52	0,35	0,12	1809,27	< 0,01	0,21	0,65	0,14	10246,94	< 0,01
2009	0,51	0,35	0,14	1452,26	< 0,01	0,21	0,64	0,15	9965,72	< 0,01
2010	0,50	0,36	0,14	1377,44	< 0,01	0,20	0,65	0,15	10640,07	< 0,01
2011	0,50	0,36	0,14	1417,25	< 0,01	0,19	0,66	0,15	10744,76	< 0,01
2012	0,47	0,37	0,16	1083,92	< 0,01	0,18	0,66	0,16	11130,31	< 0,01
2013	0,45	0,37	0,17	896.48	< 0,01	0,18	0,65	0,17	10705,76	< 0,01
2014	0,43	0,33	0,24	350,27	< 0,01	0,17	0,56	0,28	5890,76	< 0,01
2015	0,41	0,34	0,25	235,90	< 0,01	0,16	0,55	0,29	5722,28	< 0,01
2016	0,39	0,33	0,28	127,02	< 0,01	0,16	0,54	0,30	5799,36	< 0,01
2017	0,36	0,34	0,30	47,94	< 0,01	0,15	0,54	0,31	6126,64	< 0,01
2018	0,36	0,34	0,30	27,92	< 0,01	0,14	0,55	0,31	6577,84	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Austriju potvrđena.

U tablici 115. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Belgiju. U tablici 115. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Belgiju.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 115. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Belgiju

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,29	0,36	0,34	25.79	< 0,01	0,27	0,41	0,31	339,00	< 0,01
2009	0,28	0,36	0,36	45.88	< 0,01	0,26	0,41	0,34	352,10	< 0,01
2010	0,29	0,34	0,37	36,76	< 0,01	0,26	0,40	0,34	311,36	< 0,01
2011	0,28	0,37	0,35	42,20	< 0,01	0,25	0,41	0,34	371,31	< 0,01
2012	0,26	0,36	0,37	61,15	< 0,01	0,24	0,40	0,36	435,55	< 0,01
2013	0,27	0,37	0,36	58,28	< 0,01	0,24	0,41	0,35	490,57	< 0,01
2014	0,25	0,36	0,40	116,53	< 0,01	0,23	0,40	0,37	498,96	< 0,01
2015	0,22	0,39	0,39	170,02	< 0,01	0,22	0,41	0,37	570,49	< 0,01
2016	0,23	0,39	0,37	151,26	< 0,01	0,21	0,40	0,38	679,68	< 0,01
2017	0,25	0,37	0,38	48,66	< 0,01	0,21	0,39	0,40	350,45	< 0,01
2018	0,22	0,39	0,39	75,63	< 0,01	0,19	0,43	0,38	467,88	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Belgiju potvrđena.

U tablici 116. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Bugarsku. U tablici 116. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Bugarsku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 116. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Bugarsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,41	0,49	0,11	131,63	< 0,01	0,42	0,45	0,13	73,58	< 0,01
2009	0,48	0,43	0,09	171,60	< 0,01	0,35	0,49	0,16	59,63	< 0,01
2010	0,43	0,48	0,09	139,56	< 0,01	0,33	0,51	0,17	57,42	< 0,01
2011	0,41	0,49	0,10	121,09	< 0,01	0,32	0,50	0,18	46,89	< 0,01
2012	0,40	0,50	0,10	114,50	< 0,01	0,30	0,54	0,16	68,45	< 0,01
2013	0,43	0,49	0,08	179,41	< 0,01	0,34	0,47	0,19	43,32	< 0,01
2014	0,44	0,45	0,11	142,07	< 0,01	0,35	0,48	0,17	48,57	< 0,01
2015	0,46	0,42	0,11	103,16	< 0,01	0,36	0,49	0,15	53,22	< 0,01
2016	0,49	0,42	0,08	152,91	< 0,01	0,34	0,47	0,19	43,49	< 0,01
2017	0,51	0,41	0,08	210,74	< 0,01	0,42	0,47	0,11	90,64	< 0,01
2018	0,48	0,40	0,12	115,93	< 0,01	0,37	0,47	0,16	45,57	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Bugarsku potvrđena.

U tablici 117. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Cipar. U tablici 117. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Cipar.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 117. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Cipar

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,30	0,36	0,34	8,57	0,01	0,39	0,35	0,26	40,72	< 0,01
2009	0,36	0,33	0,32	5,62	0,06	0,38	0,35	0,28	29,32	< 0,01
2010	0,38	0,32	0,29	29,71	< 0,01	0,37	0,35	0,27	37,33	< 0,01
2011	0,37	0,33	0,30	15,71	< 0,01	0,36	0,33	0,31	8,57	0,01
2012	0,33	0,32	0,35	2,48	0,29	0,32	0,34	0,34	3,18	0,20
2013	0,28	0,37	0,35	31,04	< 0,01	0,26	0,36	0,37	49,90	< 0,01
2014	0,31	0,34	0,35	9,73	< 0,01	0,28	0,35	0,38	40,84	< 0,01
2015	0,28	0,36	0,36	27,26	< 0,01	0,28	0,38	0,33	37,33	< 0,01
2016	0,29	0,33	0,38	32,41	< 0,01	0,27	0,39	0,34	53,12	< 0,01
2017	0,28	0,38	0,34	38,75	< 0,01	0,25	0,41	0,34	83,48	< 0,01
2018	0,31	0,39	0,30	34,27	< 0,01	0,23	0,39	0,38	101,71	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za sve godine u promatranom razdoblju, osim 2012. godine, statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba*

zaposlenih na nepuno radno vrijeme svih razina obrazovanja za sve godine u promatranom razdoblju, osim 2012. godine, statistički značajna.
Time je hipoteza H 2. za Cipar potvrđena.

U tablici 118. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Češku. U tablici 118. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Češku.
U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 118. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Češku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,14	0,72	0,14	5361,23	< 0,01	0,12	0,71	0,17	3734,61	< 0,01
2009	0,12	0,72	0,16	5352,04	< 0,01	0,11	0,70	0,19	3787,75	< 0,01
2010	0,12	0,73	0,15	5644,76	< 0,01	0,09	0,70	0,21	3908,10	< 0,01
2011	0,11	0,74	0,16	1042,07	< 0,01	0,09	0,72	0,19	747,74	< 0,01
2012	0,10	0,73	0,17	1081,02	< 0,01	0,09	0,69	0,22	764,46	< 0,01
2013	0,11	0,73	0,16	1060,94	< 0,01	0,09	0,67	0,25	628,77	< 0,01
2014	0,10	0,70	0,21	922,08	< 0,01	0,08	0,66	0,26	629,02	< 0,01
2015	0,09	0,72	0,18	1091,74	< 0,01	0,08	0,65	0,26	628,52	< 0,01
2016	0,10	0,72	0,18	1076,37	< 0,01	0,08	0,65	0,27	695,10	< 0,01
2017	0,12	0,67	0,21	845,86	< 0,01	0,09	0,62	0,29	650,68	< 0,01
2018	0,10	0,70	0,20	834,01	< 0,01	0,08	0,67	0,25	811,80	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja

P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Češku potvrđena.

U tablici 119. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Dansku. U tablici 119. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba*

zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja za Dansku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 119. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Dansku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,36	0,35	0,30	24,87	< 0,01	0,35	0,38	0,28	218,74	< 0,01
2009	0,40	0,34	0,27	110,39	< 0,01	0,38	0,37	0,25	500,24	< 0,01
2010	0,42	0,31	0,27	160,77	< 0,01	0,43	0,35	0,22	1055,04	< 0,01
2011	0,43	0,30	0,27	216,74	< 0,01	0,45	0,33	0,22	1387,09	< 0,01
2012	0,41	0,30	0,29	117,05	< 0,01	0,43	0,34	0,22	1181,07	< 0,01
2013	0,40	0,30	0,29	103,27	< 0,01	0,42	0,36	0,23	932,63	< 0,01
2014	0,41	0,30	0,29	124,70	< 0,01	0,40	0,37	0,23	810,88	< 0,01
2015	0,41	0,32	0,26	165,67	< 0,01	0,40	0,36	0,24	745,54	< 0,01
2016	0,32	0,38	0,30	55,63	< 0,01	0,36	0,37	0,28	211,44	< 0,01
2017	0,41	0,32	0,27	186,54	< 0,01	0,35	0,37	0,27	235,64	< 0,01
2018	0,41	0,32	0,26	192,67	< 0,01	0,35	0,37	0,27	231,65	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba*

zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Dansku potvrđena.

U tablici 120. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Estoniju. U tablici 120. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Estoniju.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 120. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Estoniju

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,33	0,57	0,10	83,68	< 0,01	0,14	0,50	0,36	169,08	< 0,01
2009	0,29	0,54	0,17	45,11	< 0,01	0,12	0,54	0,33	247,52	< 0,01
2010	0,21	0,59	0,20	87,95	< 0,01	0,11	0,53	0,36	243,70	< 0,01
2011	0,26	0,58	0,17	106,05	< 0,01	0,10	0,50	0,39	255,31	< 0,01
2012	0,27	0,59	0,14	118,35	< 0,01	0,10	0,47	0,42	280,74	< 0,01
2013	0,20	0,62	0,17	146,44	< 0,01	0,10	0,49	0,41	283,96	< 0,01
2014	0,28	0,51	0,21	50,33	< 0,01	0,12	0,49	0,39	231,75	< 0,01
2015	0,31	0,47	0,22	32,91	< 0,01	0,15	0,45	0,40	196,10	< 0,01
2016	0,29	0,54	0,17	82,46	< 0,01	0,14	0,46	0,40	220,31	< 0,01
2017	0,33	0,48	0,20	44,67	< 0,01	0,14	0,45	0,41	252,34	< 0,01
2018	0,31	0,46	0,23	35,92	< 0,01	0,15	0,44	0,41	279,73	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Estoniju potvrđena.

U tablici 121. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Finsku. U tablici 121. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja*

osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Finsku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 121. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Finsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,27	0,47	0,27	266,89	< 0,01	0,33	0,43	0,24	179,72	< 0,01
2009	0,23	0,47	0,30	284,96	< 0,01	0,30	0,44	0,26	183,82	< 0,01
2010	0,2	0,44	0,31	189,31	< 0,01	0,31	0,42	0,27	134,05	< 0,01
2011	0,24	0,45	0,30	228,28	< 0,01	0,29	0,44	0,27	188,48	< 0,01
2012	0,24	0,45	0,30	216,76	< 0,01	0,29	0,44	0,28	164,09	< 0,01
2013	0,24	0,46	0,30	228,48	< 0,01	0,27	0,46	0,27	228,40	< 0,01
2014	0,21	0,46	0,33	286,15	< 0,01	0,26	0,45	0,28	216,07	< 0,01
2015	0,25	0,44	0,31	162,42	< 0,01	0,28	0,45	0,27	194,41	< 0,01
2016	0,21	0,46	0,33	287,09	< 0,01	0,25	0,45	0,30	228,46	< 0,01
2017	0,22	0,45	0,33	221,40	< 0,01	0,25	0,45	0,30	222,26	< 0,01
2018	0,22	0,44	0,34	214,62	< 0,01	0,25	0,44	0,31	186,33	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
P	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno*

zaposlenih osoba svih razina obrazovanja za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Finsku potvrđena.

U tablici 122. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Francusku. U tablici 122. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Francusku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 122. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Francusku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,28	0,46	0,26	1392,66	< 0,01	0,31	0,43	0,26	1141,97	< 0,01
2009	0,27	0,46	0,27	1507,47	< 0,01	0,30	0,42	0,27	1135,79	< 0,01
2010	0,27	0,46	0,27	1993,48	< 0,01	0,29	0,43	0,27	1623,65	< 0,01
2011	0,27	0,47	0,27	2191,28	< 0,01	0,28	0,43	0,29	1702,83	< 0,01
2012	0,26	0,46	0,28	1910,86	< 0,01	0,27	0,43	0,30	1561,39	< 0,01

2013	0,24	0,47	0,28	2290,09	< 0,01	0,25	0,45	0,30	2246,72	< 0,01
2014	0,25	0,48	0,27	2650,35	< 0,01	0,27	0,44	0,30	2012,94	< 0,01
2015	0,24	0,48	0,28	2919,49	< 0,01	0,26	0,44	0,30	2119,96	< 0,01
2016	0,23	0,49	0,29	3142,71	< 0,01	0,24	0,45	0,31	2756,57	< 0,01
2017	0,23	0,49	0,28	3342,02	< 0,01	0,24	0,45	0,31	2665,18	< 0,01
2018	0,22	0,49	0,29	3119,84	< 0,01	0,23	0,45	0,32	2755,29	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
P	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Francusku potvrđena.

U tablici 123. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba*

koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Grčku. U tablici 123. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Grčku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 123. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Grčku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,39	0,38	0,23	417,82	< 0,01	0,51	0,34	0,15	1349,42	< 0,01
2009	0,40	0,39	0,21	604,88	< 0,01	0,50	0,34	0,16	1364,09	< 0,01
2010	0,40	0,39	0,21	649,20	< 0,01	0,50	0,35	0,15	1429,53	< 0,01
2011	0,42	0,37	0,21	521,89	< 0,01	0,50	0,35	0,15	1275,73	< 0,01
2012	0,40	0,36	0,24	183,72	< 0,01	0,45	0,38	0,16	872,67	< 0,01
2013	0,37	0,36	0,27	98,49	< 0,01	0,42	0,41	0,17	763,35	< 0,01
2014	0,33	0,41	0,26	200,91	< 0,01	0,40	0,41	0,19	640,90	< 0,01
2015	0,30	0,44	0,26	284,61	< 0,01	0,36	0,43	0,21	526,07	< 0,01
2016	0,28	0,45	0,27	363,94	< 0,01	0,34	0,45	0,20	686,87	< 0,01
2017	0,30	0,44	0,27	303,40	< 0,01	0,30	0,48	0,22	823,32	< 0,01
2018	0,29	0,45	0,26	398,43	< 0,01	0,30	0,47	0,24	587,92	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
P	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Grčku potvrđena.

U tablici 124. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Hrvatsku. U tablici 124. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Hrvatsku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 124. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Hrvatsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,15	0,71	0,14	1059,17	< 0,01	0,57	0,36	0,07	594,76	< 0,01
2009	0,14	0,73	0,13	1042,28	< 0,01	0,56	0,37	0,06	587,11	< 0,01
2010	0,11	0,72	0,17	956,05	< 0,01	0,54	0,40	0,06	535,22	< 0,01
2011	0,11	0,72	0,18	900,48	< 0,01	0,52	0,42	0,06	490,79	< 0,01
2012	0,11	0,69	0,20	742,87	< 0,01	0,50	0,43	0,07	354,68	< 0,01
2013	0,10	0,66	0,24	674,97	< 0,01	0,48	0,44	0,08	278,02	< 0,01
2014	0,13	0,66	0,22	872,13	< 0,01	0,43	0,46	0,11	213,03	< 0,01
2015	0,11	0,67	0,22	1208,40	< 0,01	0,39	0,49	0,13	230,28	< 0,01
2016	0,12	0,68	0,20	1182,75	< 0,01	0,36	0,48	0,16	141,80	< 0,01
2017	0,13	0,68	0,20	1087,80	< 0,01	0,33	0,48	0,19	94,12	< 0,01
2018	0,12	0,69	0,19	1285,49	< 0,01	0,34	0,43	0,23	59,21	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Hrvatsku potvrđena.

U tablici 125. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Irsku. U tablici 125. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Irsku.
U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 125. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Irsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,27	0,40	0,33	186,79	< 0,01	0,34	0,40	0,25	870,00	< 0,01
2009	0,23	0,40	0,38	399,58	< 0,01	0,30	0,43	0,27	1139,75	< 0,01
2010	0,21	0,40	0,39	474,03	< 0,01	0,27	0,44	0,29	1076,93	< 0,01
2011	0,20	0,42	0,38	602,77	< 0,01	0,27	0,44	0,29	1115,16	< 0,01
2012	0,18	0,42	0,40	733,37	< 0,01	0,25	0,45	0,30	1313,19	< 0,01
2013	0,17	0,41	0,42	744,10	< 0,01	0,24	0,44	0,32	1201,85	< 0,01
2014	0,17	0,45	0,39	828,31	< 0,01	0,22	0,47	0,31	1814,44	< 0,01
2015	0,19	0,44	0,37	564,10	< 0,01	0,23	0,45	0,32	1403,88	< 0,01
2016	0,19	0,43	0,38	445,59	< 0,01	0,24	0,46	0,31	1221,81	< 0,01
2017	0,17	0,46	0,37	620,75	< 0,01	0,21	0,47	0,32	1384,77	< 0,01
2018	0,17	0,45	0,38	625,20	< 0,01	0,21	0,47	0,32	1343,40	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa

P	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Irsku potvrđena.

U tablici 126. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Italiju. U tablici 126. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Italiju.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 126. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Italiju

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,39	0,44	0,17	2881,06	< 0,01	0,39	0,47	0,15	5885,22	< 0,01
2009	0,38	0,45	0,17	2744,71	< 0,01	0,38	0,48	0,15	5685,27	< 0,01
2010	0,39	0,45	0,16	3007,60	< 0,01	0,37	0,48	0,15	5812,37	< 0,01
2011	0,39	0,45	0,16	3062,43	< 0,01	0,36	0,48	0,16	5721,72	< 0,01
2012	0,37	0,45	0,18	2624,36	< 0,01	0,36	0,48	0,16	5450,43	< 0,01
2013	0,36	0,45	0,19	2155,02	< 0,01	0,36	0,47	0,17	5360,53	< 0,01
2014	0,35	0,46	0,19	2234,33	< 0,01	0,35	0,48	0,17	5469,61	< 0,01
2015	0,35	0,46	0,19	2404,74	< 0,01	0,35	0,48	0,18	5242,84	< 0,01
2016	0,35	0,46	0,19	2384,64	< 0,01	0,34	0,48	0,18	5138,09	< 0,01
2017	0,35	0,46	0,19	2505,20	< 0,01	0,33	0,47	0,19	4519,40	< 0,01
2018	0,35	0,46	0,19	2987,17	< 0,01	0,34	0,47	0,20	4206,48	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
P	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba*

zaposlenih na nepuno radno vrijeme svih razina obrazovanja za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Italiju potvrđena.

U tablici 127. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Latviju. U tablici 127. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Latviju.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 127. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Latviju

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,36	0,55	0,09	181,42	< 0,01	0,23	0,58	0,19	346,94	< 0,01
2009	0,30	0,61	0,09	265,34	< 0,01	0,23	0,59	0,18	486,22	< 0,01
2010	0,25	0,66	0,09	502,91	< 0,01	0,16	0,61	0,22	540,31	< 0,01
2011	0,23	0,67	0,11	470,12	< 0,01	0,14	0,61	0,25	468,06	< 0,01
2012	0,24	0,62	0,14	236,77	< 0,01	0,12	0,61	0,27	504,89	< 0,01
2013	0,22	0,62	0,17	226,40	< 0,01	0,12	0,62	0,27	537,44	< 0,01
2014	0,21	0,65	0,14	226,42	< 0,01	0,11	0,62	0,27	549,51	< 0,01
2015	0,21	0,60	0,19	171,57	< 0,01	0,12	0,61	0,27	531,21	< 0,01
2016	0,19	0,62	0,18	220,76	< 0,01	0,12	0,59	0,29	566,11	< 0,01
2017	0,20	0,60	0,20	60,65	< 0,01	0,08	0,59	0,33	236,71	< 0,01
2018	0,16	0,64	0,21	76,45	< 0,01	0,08	0,54	0,38	194,54	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja

P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
P	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Latviju potvrđena.

U tablici 128. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Litvu. U tablici 128. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba*

zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja za Litvu.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 128. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Litvu

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,22	0,66	0,12	262,78	< 0,01	0,09	0,66	0,24	1044,52	< 0,01
2009	0,20	0,69	0,11	311,97	< 0,01	0,11	0,67	0,22	1243,68	< 0,01
2010	0,12	0,75	0,13	431,98	< 0,01	0,09	0,65	0,26	1105,40	< 0,01
2011	0,11	0,75	0,14	508,22	< 0,01	0,07	0,63	0,29	1217,36	< 0,01
2012	0,11	0,73	0,15	427,35	< 0,01	0,07	0,64	0,29	1405,46	< 0,01
2013	0,11	0,73	0,16	490,39	< 0,01	0,07	0,67	0,26	1542,77	< 0,01
2014	0,15	0,70	0,15	398,19	< 0,01	0,08	0,62	0,30	1212,41	< 0,01
2015	0,14	0,71	0,15	294,28	< 0,01	0,08	0,60	0,32	1022,26	< 0,01
2016	0,14	0,67	0,19	238,28	< 0,01	0,07	0,61	0,32	1105,73	< 0,01
2017	0,14	0,69	0,17	239,72	< 0,01	0,06	0,60	0,34	1201,83	< 0,01
2018	0,18	0,69	0,14	222,28	< 0,01	0,07	0,56	0,37	974,84	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
P	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba*

zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Litvu potvrđena.

U tablici 129. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Luksemburg. U tablici 129. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Luksemburg.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 129. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Luksemburg

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,39	0,40	0,21	21,04	< 0,01	0,35	0,42	0,23	59,93	< 0,01
2009	0,26	0,36	0,38	11,99	< 0,01	0,26	0,44	0,30	88,98	< 0,01
2010	0,26	0,36	0,38	12,09	< 0,01	0,25	0,47	0,28	140,09	< 0,01
2011	0,28	0,35	0,38	8,59	0,01	0,25	0,45	0,30	107,07	< 0,01
2012	0,31	0,32	0,37	3,61	0,16	0,25	0,44	0,30	125,40	< 0,01
2013	0,26	0,30	0,44	23,31	< 0,01	0,21	0,44	0,35	127,61	< 0,01
2014	0,25	0,33	0,42	18,12	< 0,01	0,21	0,43	0,36	92,02	< 0,01
2015	0,32	0,29	0,39	20,33	< 0,01	0,28	0,40	0,32	56,65	< 0,01
2016	0,33	0,30	0,37	7,44	0,02	0,26	0,41	0,33	83,65	< 0,01
2017	0,35	0,30	0,36	4,44	0,11	0,27	0,41	0,32	76,63	< 0,01
2018	0,34	0,27	0,39	19,72	< 0,01	0,25	0,40	0,36	80,66	< 0,01
Oznaka	Opis oznake									

P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za sve godine u promatranom razdoblju osim 2012. i 2017. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Luksemburg potvrđena.

U tablici 130. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Mađarsku. U tablici 130. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju*

osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Mađarsku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 130. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Mađarsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,30	0,59	0,11	2879,72	< 0,01	0,27	0,60	0,13	1816,38	< 0,01
2009	0,32	0,57	0,11	2806,68	< 0,01	0,25	0,61	0,13	2239,22	< 0,01
2010	0,31	0,59	0,11	3484,11	< 0,01	0,23	0,63	0,14	2361,58	< 0,01
2011	0,30	0,58	0,12	2960,68	< 0,01	0,26	0,60	0,14	2469,94	< 0,01
2012	0,33	0,56	0,11	3094,21	< 0,01	0,21	0,64	0,15	3022,16	< 0,01
2013	0,34	0,56	0,10	3610,19	< 0,01	0,20	0,66	0,14	3133,01	< 0,01
2014	0,36	0,56	0,08	4077,44	< 0,01	0,22	0,64	0,15	2698,07	< 0,01
2015	0,40	0,52	0,08	4028,44	< 0,01	0,22	0,64	0,14	2553,84	< 0,01
2016	0,46	0,48	0,06	3808,47	< 0,01	0,23	0,63	0,14	2043,15	< 0,01
2017	0,47	0,47	0,05	3541,67	< 0,01	0,24	0,61	0,15	1656,28	< 0,01
2018	0,48	0,46	0,06	2821,74	< 0,01	0,21	0,61	0,18	1534,50	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
P	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Mađarsku potvrđena.

U tablici 131. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Maltu. U tablici 131. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Maltu.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 131. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Maltu

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0	0	0	0,00	1,00	0	0	0	0,00	1,00
2009	0,46	0,38	0,16	62,82	< 0,01	0,56	0,29	0,15	310,48	< 0,01
2010	0,36	0,40	0,23	21,75	< 0,01	0,52	0,32	0,16	262,85	< 0,01
2011	0,35	0,40	0,25	20,51	< 0,01	0,49	0,35	0,16	219,38	< 0,01
2012	0,41	0,33	0,26	20,32	< 0,01	0,50	0,33	0,17	238,38	< 0,01
2013	0,42	0,37	0,21	47,56	< 0,01	0,50	0,35	0,16	284,43	< 0,01
2014	0,43	0,37	0,20	59,27	< 0,01	0,47	0,35	0,18	223,73	< 0,01
2015	0,39	0,35	0,26	18,00	< 0,01	0,44	0,37	0,19	163,82	< 0,01

2016	0,33	0,40	0,27	18,27	< 0,01	0,41	0,40	0,19	148,44	< 0,01
2017	0,36	0,37	0,26	11,58	< 0,01	0,43	0,38	0,19	163,60	< 0,01
2018	0,32	0,40	0,28	12,92	< 0,01	0,44	0,37	0,19	156,38	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
P	nivo statističke značajnosti

Izvor: izrada autorice

Podaci za Maltu za 2008. godinu nisu dostupni. Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja*, *udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja*, *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Maltu potvrđena.

U tablici 132. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja*, *udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u*

ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja za Nizozemsku. U tablici 132. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Nizozemsku.
U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 132. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Nizozemsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,40	0,40	0,20	740,61	< 0,01	0,30	0,43	0,27	1264,84	< 0,01
2009	0,40	0,40	0,20	711,10	< 0,01	0,31	0,43	0,26	1251,87	< 0,01
2010	0,38	0,40	0,22	420,27	< 0,01	0,30	0,43	0,27	1021,86	< 0,01
2011	0,38	0,41	0,22	479,01	< 0,01	0,29	0,43	0,28	1085,93	< 0,01
2012	0,37	0,41	0,22	445,82	< 0,01	0,29	0,43	0,28	1053,37	< 0,01
2013	0,34	0,41	0,25	279,11	< 0,01	0,26	0,42	0,32	988,21	< 0,01
2014	0,34	0,41	0,25	273,81	< 0,01	0,26	0,42	0,32	923,83	< 0,01
2015	0,35	0,41	0,25	261,13	< 0,01	0,26	0,42	0,32	890,61	< 0,01
2016	0,36	0,40	0,24	286,80	< 0,01	0,26	0,42	0,33	857,47	< 0,01
2017	0,34	0,40	0,26	244,79	< 0,01	0,25	0,42	0,34	964,37	< 0,01
2018	0,34	0,40	0,26	245,44	< 0,01	0,25	0,41	0,35	1036,09	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
P	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja*

privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Nizozemsku potvrđena.

U tablici 133. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Njemačku. U tablici 133. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Njemačku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 133. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Njemačku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,35	0,48	0,17	395,14	< 0,01	0,17	0,63	0,20	2320,47	< 0,01
2009	0,36	0,46	0,18	353,32	< 0,01	0,17	0,62	0,21	2362,91	< 0,01
2010	0,34	0,49	0,17	438,93	< 0,01	0,16	0,63	0,21	2420,54	< 0,01
2011	0,32	0,50	0,18	430,39	< 0,01	0,16	0,63	0,22	2385,46	< 0,01

2012	0,31	0,48	0,20	3340,72	< 0,01	0,16	0,62	0,23	22900,34	< 0,01
2013	0,31	0,49	0,21	3214,23	< 0,01	0,15	0,61	0,24	23259,82	< 0,01
2014	0,30	0,50	0,19	3860,64	< 0,01	0,15	0,64	0,21	28063,57	< 0,01
2015	0,31	0,48	0,21	3104,32	< 0,01	0,15	0,63	0,22	27257,35	< 0,01
2016	0,30	0,49	0,21	3682,85	< 0,01	0,15	0,63	0,22	29431,14	< 0,01
2017	0,29	0,49	0,22	3416,17	< 0,01	0,14	0,62	0,23	30012,18	< 0,01
2018	0,30	0,48	0,22	3240,89	< 0,01	0,14	0,62	0,24	29907,27	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Njemačku potvrđena.

U tablici 134. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno*

zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Poljsku. U tablici 134. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Poljsku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 134. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Poljsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,12	0,72	0,15	11270,48	< 0,01	0,27	0,60	0,14	2529,86	< 0,01
2009	0,12	0,71	0,17	10893,83	< 0,01	0,24	0,60	0,17	2434,77	< 0,01
2010	0,11	0,70	0,19	20618,63	< 0,01	0,21	0,61	0,18	4952,11	< 0,01
2011	0,11	0,70	0,19	20297,13	< 0,01	0,21	0,60	0,19	4595,19	< 0,01
2012	0,10	0,69	0,20	19831,05	< 0,01	0,20	0,60	0,20	4454,83	< 0,01
2013	0,10	0,68	0,22	17486,02	< 0,01	0,18	0,60	0,22	4018,12	< 0,01
2014	0,10	0,68	0,23	16952,62	< 0,01	0,15	0,60	0,25	3870,51	< 0,01
2015	0,10	0,67	0,23	14982,57	< 0,01	0,14	0,62	0,24	4056,52	< 0,01
2016	0,09	0,67	0,25	13978,62	< 0,01	0,12	0,61	0,27	3701,34	< 0,01
2017	0,09	0,64	0,27	11850,20	< 0,01	0,11	0,60	0,29	3430,12	< 0,01
2018	0,09	0,64	0,27	9944,67	< 0,01	0,11	0,60	0,29	3275,22	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Poljsku potvrđena.

U tablici 135. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Portugal. U tablici 135. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Portugal.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 135. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Portugal

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,65	0,18	0,17	5574,48	< 0,01	0,87	0,07	0,07	12334,31	< 0,01
2009	0,61	0,20	0,19	4137,27	< 0,01	0,86	0,07	0,07	11770,10	< 0,01
2010	0,60	0,21	0,19	3780,20	< 0,01	0,86	0,07	0,07	11370,25	< 0,01
2011	0,56	0,23	0,21	2591,48	< 0,01	0,83	0,09	0,08	11507,31	< 0,01
2012	0,53	0,25	0,23	1660,47	< 0,01	0,82	0,10	0,09	11670,69	< 0,01
2013	0,49	0,28	0,23	1119,83	< 0,01	0,79	0,11	0,11	9456,80	< 0,01
2014	0,47	0,29	0,24	1008,14	< 0,01	0,75	0,13	0,12	7874,07	< 0,01
2015	0,46	0,29	0,24	921,92	< 0,01	0,73	0,14	0,12	6873,46	< 0,01
2016	0,46	0,30	0,24	896,07	< 0,01	0,73	0,14	0,13	6537,88	< 0,01
2017	0,44	0,32	0,24	681,86	< 0,01	0,72	0,15	0,13	5978,53	< 0,01
2018	0,42	0,33	0,25	488,82	< 0,01	0,69	0,17	0,14	4739,43	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Portugal potvrđena.

U tablici 136. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Rumunjsku. U tablici 136. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Rumunjsku.
U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 136. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Rumunjsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,27	0,63	0,10	338,31	< 0,01	0,63	0,36	0,01	6606,39	< 0,01
2009	0,26	0,63	0,11	252,57	< 0,01	0,62	0,36	0,01	6326,09	< 0,01
2010	0,27	0,61	0,12	250,29	< 0,01	0,62	0,37	0,01	6731,28	< 0,01
2011	0,22	0,67	0,11	485,87	< 0,01	0,59	0,39	0,02	5570,82	< 0,01
2012	0,23	0,66	0,11	468,83	< 0,01	0,57	0,42	0,02	5378,39	< 0,01
2013	0,24	0,63	0,13	346,18	< 0,01	0,56	0,43	0,02	5085,86	< 0,01
2014	0,25	0,64	0,11	398,94	< 0,01	0,60	0,38	0,02	5576,88	< 0,01
2015	0,26	0,66	0,08	529,72	< 0,01	0,58	0,40	0,02	5500,71	< 0,01
2016	0,28	0,64	0,08	485,21	< 0,01	0,56	0,43	0,01	4508,63	< 0,01
2017	0,27	0,66	0,07	474,06	< 0,01	0,55	0,43	0,01	4165,20	< 0,01
2018	0,28	0,65	0,07	425,79	< 0,01	0,56	0,42	0,02	4024,05	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja

P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Rumunjsku potvrđena.

U tablici 137. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Slovačku. U tablici 137. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Slovačku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 137. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Slovačku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,18	0,72	0,10	1252,29	< 0,01	0,24	0,62	0,14	510,60	< 0,01
2009	0,18	0,69	0,12	928,71	< 0,01	0,19	0,68	0,13	881,23	< 0,01
2010	0,22	0,67	0,11	1056,42	< 0,01	0,26	0,61	0,14	608,72	< 0,01
2011	0,22	0,65	0,13	1076,73	< 0,01	0,25	0,60	0,15	619,93	< 0,01
2012	0,24	0,65	0,11	1108,83	< 0,01	0,27	0,59	0,14	559,24	< 0,01
2013	0,25	0,65	0,10	1145,86	< 0,01	0,28	0,61	0,11	751,72	< 0,01
2014	0,22	0,68	0,10	1649,34	< 0,01	0,28	0,60	0,12	738,37	< 0,01
2015	0,19	0,69	0,12	1951,54	< 0,01	0,25	0,61	0,14	845,31	< 0,01
2016	0,22	0,66	0,12	1675,98	< 0,01	0,27	0,61	0,13	921,14	< 0,01
2017	0,27	0,61	0,12	1202,04	< 0,01	0,28	0,57	0,15	715,00	< 0,01
2018	0,25	0,60	0,15	906,53	< 0,01	0,25	0,57	0,18	582,47	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja te udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja i udio ukupnog broja osoba

zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Slovačku potvrđena.

U tablici 138. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Sloveniju. U tablici 138. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Sloveniju.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 138. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Sloveniju

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,14	0,68	0,18	2598,01	< 0,01	0,30	0,59	0,11	1088,10	< 0,01
2009	0,13	0,67	0,20	2297,59	< 0,01	0,29	0,58	0,12	1198,21	< 0,01
2010	0,13	0,65	0,22	2047,02	< 0,01	0,26	0,58	0,16	1089,59	< 0,01
2011	0,12	0,65	0,24	1911,40	< 0,01	0,24	0,59	0,17	916,05	< 0,01
2012	0,10	0,65	0,25	1768,93	< 0,01	0,22	0,59	0,19	769,12	< 0,01
2013	0,10	0,62	0,29	1498,14	< 0,01	0,21	0,57	0,23	664,20	< 0,01
2014	0,10	0,61	0,29	1423,93	< 0,01	0,24	0,55	0,21	708,17	< 0,01
2015	0,10	0,62	0,29	1627,42	< 0,01	0,21	0,57	0,22	755,20	< 0,01
2016	0,09	0,61	0,30	1613,21	< 0,01	0,17	0,58	0,25	791,72	< 0,01
2017	0,10	0,59	0,31	1627,45	< 0,01	0,19	0,57	0,24	837,73	< 0,01
2018	0,11	0,59	0,30	1384,19	< 0,01	0,19	0,54	0,27	649,36	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja

P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Sloveniju potvrđena.

U tablici 139. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Španjolsku. U tablici 139. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba*

zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Španjolsku.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 139. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Španjolsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,47	0,23	0,30	971,80	< 0,01	0,47	0,25	0,28	460,53	< 0,01
2009	0,45	0,21	0,34	756,31	< 0,01	0,47	0,24	0,29	517,48	< 0,01
2010	0,43	0,23	0,34	515,29	< 0,01	0,45	0,25	0,30	370,18	< 0,01
2011	0,42	0,23	0,35	411,18	< 0,01	0,45	0,24	0,31	383,53	< 0,01
2012	0,40	0,23	0,37	396,53	< 0,01	0,44	0,24	0,32	332,82	< 0,01
2013	0,41	0,23	0,36	370,76	< 0,01	0,43	0,24	0,33	357,98	< 0,01
2014	0,40	0,23	0,37	345,46	< 0,01	0,42	0,24	0,34	295,06	< 0,01
2015	0,39	0,23	0,38	415,06	< 0,01	0,40	0,24	0,35	259,38	< 0,01
2016	0,39	0,23	0,37	351,84	< 0,01	0,39	0,25	0,36	196,77	< 0,01
2017	0,38	0,24	0,38	308,10	< 0,01	0,38	0,26	0,36	162,60	< 0,01
2018	0,37	0,24	0,38	309,29	< 0,01	0,37	0,26	0,37	137,61	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.
Time je hipoteza H 2. za Španjolsku potvrđena.

U tablici 140. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za Švedsku. U tablici 140. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Švedsku.
U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 140. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Švedsku

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,21	0,51	0,27	3031,83	< 0,01	0,22	0,49	0,29	4754,48	< 0,01
2009	0,21	0,51	0,28	2737,33	< 0,01	0,21	0,49	0,29	4848,62	< 0,01
2010	0,21	0,51	0,29	3817,53	< 0,01	0,21	0,49	0,30	6307,18	< 0,01
2011	0,22	0,50	0,28	3499,27	< 0,01	0,21	0,48	0,31	5742,24	< 0,01
2012	0,23	0,48	0,29	2751,58	< 0,01	0,21	0,48	0,31	5589,82	< 0,01
2013	0,22	0,48	0,30	2737,82	< 0,01	0,20	0,48	0,32	5568,41	< 0,01
2014	0,22	0,47	0,31	2513,82	< 0,01	0,19	0,48	0,34	5474,80	< 0,01
2015	0,22	0,46	0,32	1949,38	< 0,01	0,19	0,47	0,35	4840,17	< 0,01

2016	0,23	0,45	0,32	1660,44	< 0,01	0,18	0,45	0,36	4322,91	< 0,01
2017	0,24	0,44	0,32	1327,15	< 0,01	0,18	0,46	0,36	4222,70	< 0,01
2018	0,26	0,41	0,33	736,93	< 0,01	0,18	0,44	0,38	3736,65	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Švedsku potvrđena.

U tablici 141. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja te udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u*

ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja za Ujedinjeno Kraljevstvo. U tablici 141. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja i udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za Ujedinjeno Kraljevstvo.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 141. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Ujedinjeno Kraljevstvo

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	0,17	0,42	0,41	456,94	< 0,01	0,28	0,45	0,27	1386,58	< 0,01
2009	0,18	0,41	0,41	187,93	< 0,01	0,29	0,43	0,29	425,19	< 0,01
2010	0,16	0,42	0,42	242,57	< 0,01	0,26	0,44	0,30	536,30	< 0,01
2011	0,16	0,38	0,45	232,38	< 0,01	0,24	0,43	0,32	585,46	< 0,01
2012	0,13	0,43	0,44	342,08	< 0,01	0,23	0,44	0,33	698,85	< 0,01
2013	0,15	0,39	0,46	261,26	< 0,01	0,23	0,43	0,34	595,17	< 0,01
2014	0,16	0,41	0,43	229,91	< 0,01	0,23	0,43	0,33	649,34	< 0,01
2015	0,13	0,41	0,46	307,01	< 0,01	0,22	0,43	0,35	670,67	< 0,01
2016	0,16	0,43	0,42	227,58	< 0,01	0,22	0,43	0,36	689,07	< 0,01
2017	0,15	0,40	0,45	235,42	< 0,01	0,22	0,42	0,36	619,24	< 0,01
2018	0,14	0,40	0,46	256,22	< 0,01	0,22	0,42	0,36	681,55	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u*

ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za Ujedinjeno Kraljevstvo potvrđena.

Tablica 142. prikazuje ukupne rezultate istraživanja i analize podataka za hipotezu H2. po državama.

Tablica 142. Ukupni rezultati empirijskog istraživanja po državama i hipotezi H2.

Država	Hipoteza H2.	Država	Hipoteza H2.	Država	Hipoteza H2.
Austrija	Potvrđena	**Hrvatska**	Potvrđena	**Njemačka**	Potvrđena
Belgija	Potvrđena	**Irska**	Potvrđena	**Poljska**	Potvrđena
Bugarska	Potvrđena	**Italija**	Potvrđena	**Portugal**	Potvrđena
Cipar	Potvrđena	**Latvija**	Potvrđena	**Rumunjska**	Potvrđena
Češka	Potvrđena	**Litva**	Potvrđena	**Slovačka**	Potvrđena
Danska	Potvrđena	**Luksemburg**	Potvrđena	**Slovenija**	Potvrđena
Estonija	Potvrđena	**Mađarska**	Potvrđena	**Španjolska**	Potvrđena
Finska	Potvrđena	**Malta**	Potvrđena	**Švedska**	Potvrđena
Francuska	Potvrđena	**Nizozemska**	Potvrđena	**Ujedinjeno Kraljevstvo**	Potvrđena
Grčka	Potvrđena				

Izvor: izrada autorice

Tablica 142. prikazuje ukupne rezultate empirijskog istraživanja po državama i hipotezi H2. Rezultati pokazuju da je hipoteza potvrđena za svih 28 analiziranih država.

7.3.5. Vremensko trajanje nezaposlenosti u korelaciji s dobnom strukturom radnika

U statističkoj obradi hipoteze $H3_1$ za svaku zemlju EU-a, identificirana je statistički značajna povezanost između varijabli *dobna struktura radnika* i *vremensko trajanje nezaposlenosti*.

Hipoteza $H3_1$ će biti prihvaćena u slučaju da je ista potvrđena za sve države ili njih 27 od 28. U slučaju da je hipoteza $H3_1$ potvrđena ili parcijalno potvrđena za 15 do 26 zemalja, ista će biti parcijalno potvrđena. Hipoteza $H3_1$ će biti odbačena ako je potvrđena za 14 ili manje zemalja.

U tablici 143. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Austriju te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Austriju.

Tablica 143. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Austriju

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	7496	1916	1483
DS_R 2	14426	4901	7228
DS_R 3	1171	600	1757
$\chi^2 = 2109.69$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Austriju statistički značajna.
Time je hipoteza $H3_1$ za Austriju potvrđena.

U tablici 144. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Belgiju te su prikazani rezultati χ^2-testa kojim se

testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Belgiju.

Tablica 144. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Belgiju

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	4037	1425	2371
DS_R 2	8200	3828	12942
DS_R 3	460	304	2301
$\chi^2 = 2105.89$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Belgiju statistički značajna.
Time je hipoteza $H3_1$ za Belgiju potvrđena.

U tablici 145. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Bugarsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Bugarsku.

Tablica 145. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Bugarsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	610	344	917
DS_R 2	2119	1398	5715
DS_R 3	508	378	1880
$\chi^2 = 181.94$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		

DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Bugarsku statistički značajna.
Time je hipoteza $H3_1$ za Bugarsku potvrđena.

U tablici 146. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Cipar te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Cipar.

Tablica 146. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Cipar

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	2548	888	988
DS_R 2	6579	2857	5748
DS_R 3	971	441	1541
$\chi^2 = 737.21$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Cipar statistički značajna.
Time je hipoteza $H3_1$ za Cipar potvrđena.

U tablici 147. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Češku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Češku.

Tablica 147. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Češku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	3115	1201	1513
DS_R 2	7700	3952	8314
DS_R 3	1558	948	1869
$\chi^2 = 593.46$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2 . mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Češku statistički značajna.
Time je hipoteza $H3_1$ za Češku potvrđena.

U tablici 148. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Dansku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Dansku.

Tablica 148. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Dansku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	13837	1872	1156
DS_R 2	12213	4074	4941
DS_R 3	2687	1286	2039
$\chi^2 = 4071.97$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Dansku statistički značajna.
Time je hipoteza $H3_1$ za Dansku potvrđena.

U tablici 149. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Estoniju te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Estoniju.

Tablica 149. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Estoniju

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	1505	447	723
DS_R 2	2939	1140	3167
DS_R 3	573	255	786
$\chi^2 = 304.41$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Estoniju statistički značajna.
Time je hipoteza $H3_1$ za Estoniju potvrđena.

U tablici 150. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Finsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Finsku.

Tablica 150. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Finsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3

DS_R 1	6359	645	433
DS_R 2	5491	1613	2549
DS_R 3	1092	479	1228
$\chi^2 = 2726.64$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Finsku statistički značajna.

Time je hipoteza $H3_1$ za Finsku potvrđena.

U tablici 151. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Francusku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Francusku.

Tablica 151. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Francusku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	27531	10234	16341
DS_R 2	52316	27906	70305
DS_R 3	5248	3722	14893
$\chi^2 = 8931.00$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Francusku statistički značajna.

Time je hipoteza $H3_1$ za Francusku potvrđena.

U tablici 152. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Grčku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Grčku.

Tablica 152. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Grčku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	10271	5766	15240
DS_R 2	36947	21206	105840
DS_R 3	3396	1909	15076
$\chi^2 = 236230.38$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka od 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka od 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka od 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Grčku statistički značajna.
Time je hipoteza $H3_1$ za Grčku potvrđena.

U tablici 153. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Hrvatsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Hrvatsku.

Tablica 153. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Hrvatsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	1940	1124	2634
DS_R 2	3619	2010	8768
DS_R 3	374	233	1748
$\chi^2 = 629.63$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		

V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Hrvatsku statistički značajna.
Time je hipoteza $H3_1$ za Hrvatsku potvrđena.

U tablici 154. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Irsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Irsku.

Tablica 154. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Irsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	11826	4792	9242
DS_R 2	21701	12580	40155
DS_R 3	2217	1475	6882
$\chi^2 = 3916.33$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Irsku statistički značajna.
Time je hipoteza $H3_1$ za Irsku potvrđena.

U tablici 155. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Italiju te su prikazani rezultati χ^2-testa kojim se testirala,

u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Italiju.

Tablica 155. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Italiju

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	19322	7908	26081
DS_R 2	55297	25142	100795
DS_R 3	5336	2495	12146
$\chi^2 = 1134.07$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Italiju statistički značajna.
Time je hipoteza $H3_1$ za Italiju potvrđena.

U tablici 156. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Latviju te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Latviju.

Tablica 156. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Latviju

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	2044	845	1101
DS_R 2	5033	2925	6909
DS_R 3	900	588	1694
$\chi^2 = 659.61$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		

χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Latviju statistički značajna.
Time je hipoteza $H3_1$ za Latviju potvrđena.

U tablici 157. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Litvu te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Litvu.

Tablica 157. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Litvu

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	3002	1098	1135
DS_R 2	9030	5003	10822
DS_R 3	1784	1103	2813
$\chi^2 = 1199.96$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Litvu statistički značajna.
Time je hipoteza $H3_1$ za Litvu potvrđena.

U tablici 158. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Luksemburg te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Luksemburg.

Tablica 158. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Luksemburg

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	783	169	175
DS_R 2	1569	696	1206
DS_R 3	129	63	177
$\chi^2 = 265.67$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Luksemburg statistički značajna.

Time je hipoteza $H3_1$ za Luksemburg potvrđena.

U tablici 159. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Mađarsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Mađarsku.

Tablica 159. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Mađarsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	9211	5046	6543
DS_R 2	23533	14999	33555
DS_R 3	2700	1839	6173
$\chi^2 = 2374.67$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Mađarsku statistički značajna.
Time je hipoteza $H3_1$ za Mađarsku potvrđena.

U tablici 160. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Maltu te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Maltu.

Tablica 160. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Maltu

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	1174	357	572
DS_R 2	1116	544	1708
DS_R 3	182	88	352
$\chi^2 = 382.99$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Maltu statistički značajna.
Time je hipoteza $H3_1$ za Maltu potvrđena.

U tablici 161. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Nizozemsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Nizozemsku.

Tablica 161. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Nizozemsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	5540	1127	999

DS_R 2	5872	2638	5215
DS_R 3	1261	988	4044
$\chi^2 = 4635.89$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Nizozemsku statistički značajna.

Time je hipoteza $H3_1$ za Nizozemsku potvrđena.

U tablici 162. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Njemačku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Njemačku.

Tablica 162. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Njemačku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	8132	2204	3040
DS_R 2	21727	8158	23878
DS_R 3	4069	2155	9773
$\chi^2 = 4715.09$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Njemačku statistički značajna.

Time je hipoteza $H3_1$ za Njemačku potvrđena.

U tablici 163. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Poljsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Poljsku.

Tablica 163. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Poljsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	16311	6672	8100
DS_R 2	33218	16878	33009
DS_R 3	4579	2650	6452
$\chi^2 = 94073.44$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Poljsku statistički značajna.
Time je hipoteza $H3_1$ za Poljsku potvrđena.

U tablici 164. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Portugal te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Portugal.

Tablica 164. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Portugal

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	9702	3617	5827
DS_R 2	18350	10041	35104
DS_R 3	2361	1564	9783
$\chi^2 = 6325.34$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		

V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Portugal statistički značajna.
Time je hipoteza $H3_1$ za Portugal potvrđena.

U tablici 165. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Rumunjsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Rumunjsku.

Tablica 165. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Rumunjsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	7404	3766	6819
DS_R 2	18104	8012	20057
DS_R 3	1935	816	2325
$\chi^2 = 231.45$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Rumunjsku statistički značajna.
Time je hipoteza $H3_1$ za Rumunjsku potvrđena.

U tablici 166. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Slovačku te su prikazani rezultati χ^2-testa kojim se

testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Slovačku.

Tablica 166. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Slovačku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	3104	2093	5856
DS_R 2	6892	5555	26999
DS_R 3	1099	850	5186
$\chi^2 = 1117.67$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
P	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Slovačku statistički značajna.
Time je hipoteza $H3_1$ za Slovačku potvrđena.

U tablici 167. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Sloveniju te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Sloveniju.

Tablica 167. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Sloveniju

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	2171	856	1457
DS_R 2	6073	3350	9267
DS_R 3	518	388	1402
$\chi^2 = 691.01$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		

χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Sloveniju statistički značajna.
Time je hipoteza $H3_1$ za Sloveniju potvrđena.

U tablici 168. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Španjolsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Španjolsku.

Tablica 168. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Španjolsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	9722	3694	5810
DS_R 2	29447	13168	32404
DS_R 3	2960	1665	7665
$\chi^2 = 3277.64$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Španjolsku statistički značajna.
Time je hipoteza $H3_1$ za Španjolsku potvrđena.

U tablici 169. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Švedsku te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Švedsku.

Tablica 169. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Švedsku

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	33611	5208	2563
DS_R 2	36689	13562	14581
DS_R 3	10633	5899	9489
$\chi^2 = 13532.00$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Švedsku statistički značajna.
Time je hipoteza $H3_1$ za Švedsku potvrđena.

U tablici 170. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za Ujedinjeno Kraljevstvo te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Ujedinjeno Kraljevstvo.

Tablica 170. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Ujedinjeno Kraljevstvo

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	6066	1662	2146
DS_R 2	8014	2754	5100
DS_R 3	1304	502	1255
$\chi^2 = 589.37$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
p	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Ujedinjeno Kraljevstvo statistički značajna. Time je hipoteza $H3_1$ za Ujedinjeno Kraljevstvo potvrđena.

Tablica 171. prikazuje ukupne rezultate istraživanja i analize podataka za hipotezu $H3_1$ po državama.

Tablica 171. Ukupni rezultati empirijskog istraživanja po državama i hipotezi $H3_1$

Država	Hipoteza $H3_1$	Država	Hipoteza $H3_1$	Država	Hipoteza $H3_1$
Austrija	Potvrđena	**Hrvatska**	Potvrđena	**Njemačka**	Potvrđena
Belgija	Potvrđena	**Irska**	Potvrđena	**Poljska**	Potvrđena
Bugarska	Potvrđena	**Italija**	Potvrđena	**Portugal**	Potvrđena
Cipar	Potvrđena	**Latvija**	Potvrđena	**Rumunjska**	Potvrđena
Češka	Potvrđena	**Litva**	Potvrđena	**Slovačka**	Potvrđena
Danska	Potvrđena	**Luksemburg**	Potvrđena	**Slovenija**	Potvrđena
Estonija	Potvrđena	**Mađarska**	Potvrđena	**Španjolska**	Potvrđena
Finska	Potvrđena	**Malta**	Potvrđena	**Švedska**	Potvrđena
Francuska	Potvrđena	**Nizozemska**	Potvrđena	**Ujedinjeno Kraljevstvo**	Potvrđena
Grčka	Potvrđena				

Izvor: izrada autorice

Tablica 171. prikazuje ukupne rezultate empirijskog istraživanja po državama i hipotezi $H3_1$ Rezultati pokazuju da je hipoteza potvrđena za svih 28 analiziranih država.

7.3.6. Vremensko trajanje nezaposlenosti u korelaciji s motivacijom radnika za traženjem novog posla

U statističkoj obradi hipoteze $H3_2$ za svaku zemlju EU-a bit će identificirana statistički značajna povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Hipoteza $H3_2$ će biti prihvaćena u slučaju da je ista potvrđena za sve države ili njih 27 od 28. U slučaju da je hipoteza $H3_2$ potvrđena ili parcijalno potvrđena za 15 do 26 zemalja, ista će biti parcijalno potvrđena. Hipoteza $H3_2$ će biti odbačena ako je potvrđena za 14 ili manje zemalja.

U kontingencijskoj tablici 172. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Austriju. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 172. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Austriju

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	656	1110	1589	2549	3288	4042	2855	1032
V_{TN} 2	122	315	421	704	994	1419	1107	380
V_{TN} 3	275	616	849	1213	1618	1991	1298	442
$\chi^2 = 151.95$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Austrije statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Austriju potvrđena.

U kontingencijskoj tablici 173. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Belgiju. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 173. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Belgiju

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	2721	2895	2625	1654	945	531	159	76
V_{TN} 2	1082	1244	1240	850	433	255	71	44
V_{TN} 3	3888	4334	4092	2432	1250	733	156	92
$\chi^2 = 66.77$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Belgije statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Belgiju potvrđena.

U kontingencijskoj tablici 174. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Bugarsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 174. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Bugarsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	590	860	697	389	241	131	16	4
V_{TN} 2	386	586	472	318	169	90	14	7
V_{TN} 3	1627	2605	1957	1090	677	320	44	15
$\chi^2 = 20.40$; $p = 0,12$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu

M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Bugarske nije statistički značajna (p = 0,12) te time hipoteza $H3_2$ za Bugarsku nije potvrđena.

U kontingencijskoj tablici 175. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Cipar. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 175. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Cipar

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	412	1563	1814	1930	1364	741	164	23
V_{TN} 2	136	588	909	1015	730	406	62	13
V_{TN} 3	365	1303	1809	2137	1464	708	78	15
$\chi^2 = 110.33$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Cipra statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Cipar potvrđena.

U kontingencijskoj tablici 176. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Češku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 176. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Češku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	331	434	1146	1981	2185	2055	989	609
V_{TN} 2	184	210	561	1087	1135	1029	478	286
V_{TN} 3	509	719	1571	2266	2224	1843	651	322
$\chi^2 = 415.06$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Češke statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Češku potvrđena.

U kontingencijskoj tablici 177. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Dansku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 177. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Dansku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	2527	3884	4620	5660	5299	2898	357	61
V_{TN} 2	271	469	921	1522	1826	1184	216	40

V_{TN} 3	308	486	924	1708	2173	1350	226	82
$\chi^2 = 1824.66$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Danske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Dansku potvrđena.

U kontingencijskoj tablici 178. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Estoniju. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 178. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Estoniju

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	989	1280	1424	795	307	105	18	4
V_{TN} 2	300	448	584	324	121	45	10	0
V_{TN} 3	1007	1306	1337	637	302	97	9	2
$\chi^2 = 55.80$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Estonije statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Estoniju potvrđena.

U kontingencijskoj tablici 179. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Finsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 179. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Finsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	1124	2218	2406	2438	1555	781	0	0
V_{TN} 2	294	511	554	509	399	228	1	0
V_{TN} 3	730	999	862	702	498	249	0	1
$\chi^2 = 243.72$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Finske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Finsku potvrđena.

U kontingencijskoj tablici 180. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Francusku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 180. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Francusku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	4390	9505	14445	17869	14983	8610	1047	40
V_{TN} 2	2197	4971	7445	9124	7808	4569	520	22
V_{TN} 3	9588	17453	21812	21174	15235	7686	811	47
$\chi^2 = 3813.76$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Francuske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Francusku potvrđena.

U kontingencijskoj tablici 181. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Grčku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 181. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Grčku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	1614	5359	8443	10574	10394	6132	1598	597
V_{TN} 2	589	2188	4756	6296	6811	3898	1203	460
V_{TN} 3	2935	10472	23281	29077	33315	19433	4895	2219
$\chi^2 = 1023.78$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							

M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Grčke statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Grčku potvrđena.

U kontingencijskoj tablici 182. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Hrvatsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 182. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Hrvatsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	288	710	1175	1109	856	618	339	106
V_{TN} 2	131	377	658	643	561	372	179	83
V_{TN} 3	784	1672	2457	2236	1938	1467	972	328
$\chi^2 = 89.26$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Hrvatske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Hrvatsku potvrđena.

U kontingencijskoj tablici 183. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Irsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 183. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Irsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	1198	3038	5668	6622	6407	5048	1841	822
V_{TN} 2	717	1554	2647	3315	3599	2831	1145	515
V_{TN} 3	2945	6528	8971	10143	10069	7639	2652	1216
$\chi^2 = 592.82$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Irske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Irsku potvrđena.

U kontingencijskoj tablici 184. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Italiju. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 184. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Italiju

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	6096	9807	12265	13110	11340	8415	2504	907
V_{TN} 2	2849	4634	6111	6668	5727	4278	1267	475
V_{TN} 3	16587	22615	26677	26153	20321	13306	3471	1295

$\chi^2 = 1790.40$; $p < 0,01$	
Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Italije statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Italiju potvrđena.

U kontingencijskoj tablici 185. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Latviju. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 185. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Latviju

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	300	801	1628	1930	1474	846	150	65
V_{TN} 2	114	376	814	1095	932	504	127	31
V_{TN} 3	404	1367	2384	2657	1527	749	140	59

$\chi^2 = 338.81$; $p < 0,01$	
Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Latvije statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Latviju potvrđena.

U kontingencijskoj tablici 186. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Litvu. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 186. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Litvu

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	1419	1775	2749	2734	2034	1377	355	117
V_{TN} 2	574	748	1417	1574	1201	799	213	78
V_{TN} 3	1423	1769	3238	2764	2226	1664	433	202
$\chi^2 = 136.82$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Litve statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Litvu potvrđena.

U kontingencijskoj tablici 187. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Luksemburg. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 187. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Luksemburg

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	66	127	223	284	408	376	225	96
V_{TN} 2	15	28	59	91	143	161	120	72
V_{TN} 3	43	69	138	199	246	261	135	94
$\chi^2 = 57.12$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Luksemburga statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Luksemburg potvrđena.

U kontingencijskoj tablici 188. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Mađarsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 188. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Mađarsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	1012	2506	4447	7281	7562	5627	1269	509
V_{TN} 2	553	1514	2731	4535	4858	3889	797	354
V_{TN} 3	1245	3704	6684	9946	10293	8128	1450	559
$\chi^2 = 137.41$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							

M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Mađarske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Mađarsku potvrđena.

U kontingencijskoj tablici 189. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Maltu. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 189. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Maltu

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	239	343	393	395	324	235	24	2
V_{TN} 2	77	131	143	168	170	162	19	0
V_{TN} 3	244	303	359	461	461	497	35	2
$\chi^2 = 106.13$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Malte statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Maltu potvrđena.

U kontingencijskoj tablici 190. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Nizozemsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 190. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Nizozemsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	1875	2108	1838	1850	1698	1421	530	0
V_{TN} 2	423	657	612	729	754	731	267	0
V_{TN} 3	1126	1633	1537	1715	1685	1309	383	0
$\chi^2 = 277.73$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Nizozemske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Nizozemsku potvrđena.

U kontingencijskoj tablici 191. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Njemačku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 191. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Njemačku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	7135	4788	6020	5705	4192	2638	460	8

V_{TN} 2	2403	1701	2274	2322	1750	1086	195	4
V_{TN} 3	9631	5597	6911	6367	4217	2406	436	12
$\chi^2 = 418.80$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Njemačke statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Njemačku potvrđena.

U kontingencijskoj tablici 192. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Poljsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 192. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Poljsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	4011	7902	12141	10264	7381	4450	1490	510
V_{TN} 2	1478	3533	6090	5469	3853	2334	883	264
V_{TN} 3	2874	7031	11480	10429	6881	4021	1356	440
$\chi^2 = 274.02$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							

p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Poljske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Poljsku potvrđena.

U kontingencijskoj tablici 193. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Portugal. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 193. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Portugal

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	795	4947	4708	5428	4697	3842	1714	854
V_{TN} 2	270	2299	2236	2692	2358	2192	998	475
V_{TN} 3	1601	8448	8218	9576	8115	6415	2581	1221
$\chi^2 = 233.40$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Portugala statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Portugal potvrđena.

U kontingencijskoj tablici 194. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za

Rumunjsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 194. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Rumunjsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	8	123	12091	5853	3313	2240	978	539
V_{TN} 2	7	64	5450	2283	1569	1152	594	362
V_{TN} 3	3	165	10752	5665	3799	3162	1570	969
$\chi^2 = 576.56$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Rumunjske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Rumunjsku potvrđena.

U kontingencijskoj tablici 195. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Slovačku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 195. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Slovačku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	1075	1756	2716	2613	1517	661	112	28
V_{TN} 2	759	1377	2080	2038	1237	518	104	19
V_{TN} 3	5648	7310	8898	8636	4805	1679	258	80
$\chi^2 = 502.57$; $p < 0,01$								
Oznaka	Opis oznake							

V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Slovačke statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Slovačku potvrđena.

U kontingencijskoj tablici 196. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Sloveniju. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 196. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Sloveniju

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	127	299	503	808	1119	1365	1602	687
V_{TN} 2	32	98	161	321	473	700	1112	529
V_{TN} 3	70	241	455	834	1219	1900	3118	1558
$\chi^2 = 464.87$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Slovenije statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Sloveniju potvrđena.

U kontingencijskoj tablici 197. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Španjolsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 197. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Španjolsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	2133	4806	6268	7058	6459	5100	1728	535
V_{TN} 2	884	2027	3031	3365	3150	2416	853	266
V_{TN} 3	2753	6201	8110	9050	7726	5636	1609	489
$\chi^2 = 240.39$; $p < 0,01$								

Oznaka	Opis oznake
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje
M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Španjolske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Španjolsku potvrđena.

U kontingencijskoj tablici 198. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Švedsku. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 198. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Švedsku

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	21831	20014	14508	7780	4023	1886	106	8
V_{TN} 2	5674	7213	5585	3123	1684	829	55	1
V_{TN} 3	6414	8019	5936	3232	1675	781	37	2
$\chi^2 = 784.62$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla							
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla							
χ^2	vrijednost χ^2 testa							
p	nivo statističke značajnosti							

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Švedske statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Švedsku potvrđena.

U kontingencijskoj tablici 199. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za Ujedinjeno Kraljevstvo. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 199. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Ujedinjeno Kraljevstvo

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	3099	2767	2834	2292	1874	1419	68	3
V_{TN} 2	775	903	920	845	692	542	29	4
V_{TN} 3	1557	1563	1857	1326	1071	807	30	2
$\chi^2 = 112.15$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							

M_{TNP} 3	osoba se obratila izravno poslodavcu
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima
M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika iz Ujedinjenog Kraljevstva statistički značajna ($p < 0,01$) te je hipoteza $H3_2$ za Ujedinjeno Kraljevstvo potvrđena.

Tablica 200. prikazuje ukupne rezultate istraživanja i analize podataka za hipotezu $H3_2$ po državama.

Tablica 200. Ukupni rezultati empirijskog istraživanja po državama i hipotezi $H3_2$

Država	Hipoteza $H3_2$	Država	Hipoteza $H3_2$	Država	Hipoteza $H3_2$
Austrija	Potvrđena	**Hrvatska**	Potvrđena	**Njemačka**	Potvrđena
Belgija	Potvrđena	**Irska**	Potvrđena	**Poljska**	Potvrđena
Bugarska	Odbačena	**Italija**	Potvrđena	**Portugal**	Potvrđena
Cipar	Potvrđena	**Latvija**	Potvrđena	**Rumunjska**	Potvrđena
Češka	Potvrđena	**Litva**	Potvrđena	**Slovačka**	Potvrđena
Danska	Potvrđena	**Luksemburg**	Potvrđena	**Slovenija**	Potvrđena
Estonija	Potvrđena	**Mađarska**	Potvrđena	**Španjolska**	Potvrđena
Finska	Potvrđena	**Malta**	Potvrđena	**Švedska**	Potvrđena
Francuska	Potvrđena	**Nizozemska**	Potvrđena	**Ujedinjeno Kraljevstvo**	Potvrđena
Grčka	Potvrđena				

Izvor: izrada autorice

Tablica 200. prikazuje ukupne rezultate empirijskog istraživanja po državama i hipotezi $H3_2$. Rezultati pokazuju da je hipoteza odbačena jedino u slučaju Bugarske, a potvrđena za preostalih 27 analiziranih država.

DODATNA ANALIZA

U tablici 201. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *bruto domaći proizvod po stanovniku* s varijablom *fleksibilnost tržišta radne snage* za sve promatrane zemlje. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Varijabla *bruto domaći proizvod po stanovniku* izračunat je kao prosječna vrijednost od ukupnog zbroja iznosa GDP p.c. za sve države po godinama podijeljen s brojem država.

Tablica 201. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za sve promatrane zemlje

Linearni model FLEX = $b_0 + b_1 \bullet$ GDP p. c.			
R = -0,62; R^2 = 0,38; t = -2,37; p = 0,04			
	b_0	b_1	
GDP p. c.	0,68	-0,000005	
Nelinearni model FLEX = $b_1 \bullet$ GDP p. c. + $b_2 \bullet$ GDP p. $c.^2$			
R = 0,62; R^2 = 0,38; F = 19856,32; p < 0,01			
	b_1	b_2	p
GDP p. c.	0,0049	0,000000	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
FLEX	fleksibilnost tržišta radne snage
GDP p. c.	GDP per capita, odnosno bruto domaći proizvod po stanovniku

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu *fleksibilnost tržišta radne snage*.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla GDP p. c. ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1. za sve promatrane zemlje potvrđena.

U tablici 202. prikazani su rezultati linearne i nelinearne regresijske analize povezanosti varijabli *udio privremeno zaposlenih osoba*, *udio zaposlenih osoba na nepuno radno vrijeme* te *stopa zaposlenosti* za sve promatrane zemlje. U tablici su k tomu navedeni i koeficijent višestruke korelacije (R), koeficijent višestruke determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri regresijskih analiza.

Varijabla *stopa zaposlenosti*, u okviru hipoteze H1.1., kao agregatna vrijednost upotrijebljena je za analizu kao decimalan broj dobiven od ukupnog zbroja iznosa stopa zaposlenosti za sve države po godinama.

Tablica 202. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za sve promatrane zemlje

Linearni model $SZ = b_1 \bullet PZ + b_2 \bullet NRV$					
$R = 0{,}75$; $R^2 = 0{,}57$; $F = 5{,}30$; $p = 0{,}03$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
Intercept			1271,80	364,76	< 0,01
PZ	1,05	0,33	498,36	159,50	0,01
NRV	-0,54	0,33	-190,827	118,13	0,14
Nelinearni model $SZ = b_1 \bullet PZ + b_2 \bullet PZ^2 + b_3 \bullet NRV + b_4 \bullet NRV^2$					
$R = 0{,}79$; $R^2 = 0{,}62$; $F = 4523{,}0$; $p < 0{,}01$					
	b*	St. gr. (b*)	b	St. gr. (b)	p
PZ	-0,01	0,03	-6,23	10,08	0,55
PZ^2	0,25	0,34	4,90	6,22	0,51
NRV	-0,19	0,33	-44,27	65,11	0,49
NRV^2	1,00	0,07	0,00	0,00	< 0,01

Oznaka	Opis oznake
R	koeficijent višestruke korelacije
R^2	koeficijent višestruke determinacije
F	vrijednost testne statistike
p	nivo statističke značajnosti
b	koeficijent regresijskog modela kad varijable nisu standardizirane
St. gr. (b)	standardna greška koeficijenta b
b*	koeficijent regresijskog modela kad su varijable standardizirane
St. gr. (b*)	standardna greška koeficijenta b*
SZ	stopa zaposlenosti
PZ	udio privremeno zaposlenih osoba
NRV	udio zaposlenih osoba na nepuno radno vrijeme

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model statistički značajan. Nadalje, u linearnom modelu varijabla PZ ima statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, a varijabla NRV nema statistički značajan utjecaj na kriterijsku varijablu.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijable PZ, PZ^2 i NRV nemaju statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti*, dok varijabla NRV^2 ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.1. za sve promatrane zemlje potvrđena.

U tablici 203. prikazani su rezultati linearne korelacijske analize s jednim prediktorom i jednim kriterijem te rezultati nelinearne regresijske analize povezanosti varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s varijablom *stopa nezaposlenosti* za sve promatrane zemlje. U tablici su navedeni i koeficijent korelacije (R), koeficijent determinacije (R^2), nivo statističke značajnosti (p) te ostali parametri korelacijske, odnosno regresijske analize.

Varijabla *stopa nezaposlenosti* u okviru hipoteze H1.2. kao agregatna vrijednost upotrijebljena je za analizu kao decimalan broj dobiven od ukupnog zbroja iznosa stopa nezaposlenosti za sve države po godinama.

Tablica 203. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za sve promatrane zemlje

Linearni model SNZ = $b_0 + b_1 \bullet$ SENSSH			
R = 0,55; R^2 = 0,30; t = 1,96; p = 0,08			
	b_0	b_1	
SENSSH	-244,68	0,000472	
Nelinearni model SNZ = $b_1 \bullet$ SENSSH + $b_2 \bullet$ $SENSSH^2$			
R = 0,61; R^2 = 0,35; F = 227,11; p < 0,01			
	b_1	b_2	p
SENSSH	-0,000021	0,000000	< 0,01

Oznaka	Opis oznake
R	koeficijent korelacije
R^2	koeficijent determinacije
t	vrijednost testne statistike za koeficijent
F	vrijednost testne statistike za model
p	nivo statističke značajnosti
SNZ	stopa nezaposlenosti
SENSSH	ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa

Izvor: izrada autorice

Iz tablice je vidljivo da je linearni model na granici statističke značajnosti. Nadalje, u linearnom modelu varijabli *SENSSH* statistički značajan utjecaj na kriterijsku varijablu *stopa zaposlenosti* je na granici.

Iz tablice je vidljivo da je nelinearni model statistički značajan. U nelinearnom modelu varijabla *SENSSH* ima statistički značajan utjecaj na kriterijsku varijablu.

Time je hipoteza H 1.2. za sve promatrane zemlje potvrđena.

U tablici 204. prikazani su rezultati testa značajnosti razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja*, *udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za sve promatrane zemlje. U tablici 204. su također prikazani i rezultati testa značajnosti razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja*, *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za sve promatrane zemlje.

U tablici je navedena i vrijednost hi-kvadrat testa (χ^2) i nivo statističke značajnosti (p).

Tablica 204. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za sve promatrane zemlje

	P^1_1	P^1_2	P^1_3	χ^2	p	P^2_1	P^2_2	P^2_3	χ^2	p
2008	8,34	13,22	5,44	16183,18	< 0,01	9,04	12,03	5,34	26089,92	< 0,01
2009	8,06	13,10	5,84	15407,69	< 0,01	8,66	12,19	5,54	26107,59	< 0,01
2010	7,76	13,24	6,01	22608,94	< 0,01	8,39	12,21	5,77	29033,36	< 0,01
2011	7,61	13,29	6,11	19705,06	< 0,01	8,19	12,19	6,01	25985,20	< 0,01
2012	7,44	13,18	6,38	21026,62	< 0,01	7,83	12,25	6,28	39778,09	< 0,01
2013	7,17	13,12	6,71	19943,69	< 0,01	7,52	12,28	6,54	39990,56	< 0,01
2014	7,17	13,06	6,78	20858,86	< 0,01	7,44	12,15	6,77	39389,94	< 0,01
2015	7,21	12,99	6,80	19014,30	< 0,01	7,35	12,17	6,85	38208,94	< 0,01
2016	7,17	13,04	6,79	18407,18	< 0,01	7,04	12,21	7,13	40912,37	< 0,01

2017	7,37	12,81	6,82	16908,35	< 0,01	6,96	12,16	7,27	42158,97	< 0,01
2018	7,28	12,78	6,93	15147,04	< 0,01	6,73	12,02	7,64	39168,00	< 0,01

Oznaka	Opis oznake
P^1_1	udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_2	udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^1_3	udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja
P^2_1	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_2	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
P^2_3	udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja, udio ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* te *udio ukupnog broja privremeno zaposlenih osoba koje su visokoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Nadalje, iz tablice je vidljivo da je razlika između proporcija *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja, udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* i *udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su visokoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja* za razdoblje od 2008. do 2018. godine statistički značajna.

Time je hipoteza H 2. za sve promatrane zemlje potvrđena.

U tablici 205. nalaze se podaci o učestalosti ispitanika u ovisnosti o vremenskom periodu u kojem traže posao i o dobnoj skupini za sve promatrane zemlje te su prikazani rezultati χ^2-testa kojim se testirala, u kontekstu hipoteze H3, povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za sve promatrane zemlje.

Tablica 205. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za sve promatrane zemlje

	V_{TN} 1	V_{TN} 2	V_{TN} 3
DS_R 1	228374	76976	131265
DS_R 2	454214	220890	636281
DS_R 3	62005	35683	132729
$\chi^2 = 68463.29$; $p < 0,01$			
Oznaka	Opis oznake		
V_{TN} 1	Vremensko trajanje nezaposlenosti do 1. mjeseca		
V_{TN} 2	Vremensko trajanje nezaposlenosti od 1. do 2. mjeseca		
V_{TN} 3	Vremensko trajanje nezaposlenosti od 3 do 5 mjeseci		
DS_R 1	Ukupan broj nezaposlenih osoba iz uzorka 15-24 godine		
DS_R 2	Ukupan broj nezaposlenih osoba iz uzorka 25-54 godine		
DS_R 3	Ukupan broj nezaposlenih osoba iz uzorka 55-64 godine		
χ^2	vrijednost χ^2 testa		
P	nivo statističke značajnosti		

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za sve promatrane zemlje statistički značajna.
Time je hipoteza H 3.1 za sve promatrane zemlje potvrđena.

U kontingencijskoj tablici 206. nalaze se frekvencije ispitanika u ovisnosti o vremenskom periodu u kojem traže posao te metoda korištenih za pronalaženje novog zaposlenja za sve promatrane zemlje. U kontekstu hipoteze H3, korištenjem χ^2-testa, ispitivala se povezanost nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla*.

Tablica 206. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za sve promatrane zemlje

	M_{TNP} 1	M_{TNP} 2	M_{TNP} 3	M_{TNP} 4	M_{TNP} 5	M_{TNP} 6	M_{TNP} 7	M_{TNP} 8
V_{TN} 1	68061	97725	131384	128955	107239	73590	22698	8242
V_{TN} 2	23296	40764	60882	63025	55137	38619	12639	4784
V_{TN} 3	76584	124528	173556	173825	147030	96237	28834	11765
$\chi^2 = 3685.92$; $p < 0,01$								
Oznaka	Opis oznake							
V_{TN} 1	vremensko trajanje nezaposlenosti do 1. mjeseca							
V_{TN} 2	vremensko trajanje nezaposlenosti od 1. do 2. mjeseca							
V_{TN} 3	vremensko trajanje nezaposlenosti od 3 do 5 mjeseci							
M_{TNP} 1	osoba je kontaktirala javni zavod za zapošljavanje							
M_{TNP} 2	osoba je kontaktirala privatnu agenciju za zapošljavanje							
M_{TNP} 3	osoba se obratila izravno poslodavcu							
M_{TNP} 4	osoba je pitala prijatelje, rodbinu, sindikat,..							
M_{TNP} 5	osoba je objavila oglas ili odgovorila na oglas za posao							
M_{TNP} 6	osoba je proučavala oglase u novinama ili časopisima							

M_{TNP} 7	osoba je tražila zemljište, prostore ili opremu zbog posla
M_{TNP} 8	osoba je tražila dozvole, licence, financijska sredstva zbog posla
χ^2	vrijednost χ^2 testa
p	nivo statističke značajnosti

Izvor: izrada autorice

Iz tablice je vidljivo da je povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* na uzorku ispitanika svih promatranih zemalja statistički značajna ($p < 0,01$) te je hipoteza H 3.2 za sve promatrane zemlje potvrđena.

U tablici 207. prikazani su svi rezultati empirijskog istraživanja po državama i hipotezama koje su istraživanjem potvrđene, parcijalno potvrđene ili odbačene. Pri tome, navedeni su i sumarno rezultati po hipotezama za sve zemlje označeni sa ∑ EU.

Tablica 207. Ukupni rezultati empirijskog istraživanja po državama i hipotezama koje su istraživanjem potvrđene, parcijalno potvrđene ili odbačene

Hipoteza / Država	Hipoteza H1.	Hipoteza H1.1.	Hipoteza H1.2.	Hipoteza H2.	Hipoteza 3_1	Hipoteza 3_2
Austrija	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Belgija	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Bugarska	Potvrđena	Odbačena	Parcijalno potvrđena	Potvrđena	Potvrđena	Odbačena
Cipar	Potvrđena	Potvrđena	Parcijalno potvrđena	Potvrđena	Potvrđena	Potvrđena
Češka	Parcijalno potvrđena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Danska	Parcijalno potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Estonija	Odbačena	Odbačena	Parcijalno potvrđena	Potvrđena	Potvrđena	Potvrđena
Finska	Parcijalno potvrđena	Parcijalno potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Francuska	Potvrđena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Grčka	Odbačena	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Hrvatska	Potvrđena	Odbačena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Irska	Odbačena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Italija	Parcijalno potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Latvija	Parcijalno potvrđena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena

Litva	Potvrđena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Luksemburg	Parcijalno potvrđena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Mađarska	Parcijalno potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Malta	Odbačena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Nizozemska	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Njemačka	Parcijalno potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Poljska	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Portugal	Odbačena	Potvrđena	Parcijalno potvrđena	Potvrđena	Potvrđena	Potvrđena
Rumunjska	Potvrđena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Slovačka	Odbačena	Parcijalno potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Slovenija	Odbačena	Odbačena	Potvrđena	Potvrđena	Potvrđena	Potvrđena
Španjolska	Potvrđena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Švedska	Potvrđena	Potvrđena	Odbačena	Potvrđena	Potvrđena	Potvrđena
Ujedinjeno Kraljevstvo	Odbačena	Odbačena	Odbačena	Potvrđena	Potvrđena	Potvrđena
∑ EU	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena	Potvrđena

Izvor: izrada autorice

Tablica 207. prikazuje ukupne rezultate empirijskog istraživanja po državama i hipotezama koje su istraživanjem potvrđene, parcijalno potvrđene ili odbačene. Rezultati pokazuju da je hipoteza H1. potvrđena za: Austriju, Belgiju, Bugarsku, Cipar, Francusku, Hrvatsku, Litvu, Nizozemsku, Poljsku, Rumunjsku, Španjolsku i Švedsku. Hipoteza H1. je parcijalno potvrđena za sljedeće države: Češku, Dansku, Finsku, Italiju, Latviju, Luksemburg, Mađarsku i Njemačku. Za države: Estoniju, Grčku, Irsku, Maltu, Portugal, Slovačku, Sloveniju i Ujedinjeno Kraljevstvo hipoteza H1. je odbačena.

Hipoteza H1.1. potvrđena je za 19 država i to za: Austriju, Cipar, Češku, Dansku, Francusku, Grčku, Irsku, Italiju, Latviju, Litvu, Luksemburg, Mađarsku, Maltu, Njemačku, Poljsku, Portugal, Rumunjsku, Španjolsku i Švedsku. Hipoteza H1. je parcijalno potvrđena za države Finsku i Slovačku. Za države: Belgiju, Bugarsku, Estoniju, Hrvatsku, Nizozemsku, Sloveniju i Ujedinjeno Kraljevstvo hipoteza H1. je odbačena.

Hipoteza H1.2. potvrđena je za 11 država i to za: Austriju, Belgiju, Dansku, Finsku, Grčku, Italiju, Mađarsku, Nizozemsku, Njemačku, Poljsku i Sloveniju. Hipoteza H1.2. je parcijalno potvrđena za sljedeće države: Bugarsku, Cipar, Estoniju i Portugal. Za države: Češku,

Francusku, Hrvatsku, Latviju, Litvu, Luksemburg, Maltu, Rumunjsku, Slovačku, Španjolsku, Švedsku i Ujedinjeno Kraljevstvo hipoteza H1.2. je odbačena.
Hipoteze H2. i $H3_1$ potvrđene su za svih 28 analiziranih država.
Hipoteza $H3_2$ odbačena je jedino u slučaju Bugarske, a potvrđena za preostalih 27 analiziranih država.

Hipoteze su jednako tako analizirane i ukupno, na razini svih promatranih država, a izračun za agregirane vrijednosti u istraživanje uključenih zemalja pokazuje kako su sve hipoteze u okviru ovog izračuna potvrđene.

8. RASPRAVA

Ovo poglavlje je sazdano od analize postojećih informacija u teorijskom aspektu teme, provjere postavljenih hipoteza na dobivenim rezultatima provedenog istraživanja, sinteze postignutih saznanja te interpretacije generiranog prediktivnog modela.

8.1. Teorijski aspekti fleksibilnosti tržišta rada EU-a

Tržište rada Europske unije promatra se kumulativno te ga u tom kontekstu čine tržišta rada svih država članica EU-a. Ta tržišta rada su heterogena, kao i politike tržišta rada te direktive vezane uz iste svake od država članica. Shodno tomu, direktive omogućuju državama članicama definirati radni odnos ili ugovor o radu u skladu s njihovim nacionalnim zakonom i praksom. Europska unija ih nastoji kroz zakonsku regulativu i ugovore homogenizirati kako bi stvorila jednake uvjete za sve građane Europske unije. Jednaki uvjeti se ogledaju u pravu na jednake mogućnosti u obrazovanju za sve građane EU-a, veću zapošljivost radnika - poglavito ranjivijih skupina, smanjenje vremenskog intervala nezaposlenosti između dvaju zaposlenja, pojednostavljivanje mobilnosti radne snage te modernizaciju zakona o radu čime bi se, između ostalog, osigurao jednak tretman svih radnika te sigurnost onih koji imaju fleksibilne ugovorne aranžmane.

Na razini Europske unije postoji tendencija za osiguranjem učinkovite suradnje, ne samo međudržavne, nego i one na nacionalnoj razini, između različitih subjekata uključenih u kreiranje politika tržišta rada. Time se, među inim, žele ostvariti lisabonski ciljevi, poglavito cilj 6. u smislu jačanja socijalne kohezije utemeljene na promicanju zapošljavanja te cilj 7. kroz unaprjeđenje vještina i modernizaciju sustava socijalne zaštite. Sve to iziskuje veću sigurnost u radnim odnosima te potrebu za fleksibilnošću.

Pojam fleksibilnosti u radnom odnosu pojavio se sredinom 20. stoljeća u SAD-u. Za razliku od europskih država, u SAD-u se fleksibilnost gradila na temelju zakonom propisanih minimalnih standarada čime se otvorio prostor za uređenje odnosa između poslodavaca i radnika temeljem slobodnog ugovaranja. Na taj je način fleksibilnost na tržištu rada bila potaknuta ekonomskom liberalizacijom kojom su međusobni odnosi relevantnih subjekata mogli biti regulirani bez intervencije države te bez potrebe očuvanja rigidnosti zakonskih regulativa u pogledu radnih odnosa. Europa je jedno vrijeme stvarala otpor fleksibilnosti i deregulaciji tržišta rada jer se smatralo kako navedene politike nisu u tolikoj mjeri učinkovite u povećanju razine zaposlenosti kao što je to stvaranje stimulirajuće poduzetničke okoline kroz djelotvornu vladinu politiku.

Međutim, ubrzo se pokazalo kako se konzervativanim sustavom radnopravnih odnosa, jakim utjecajem sindikata te minimalnom mobilnosti radnika ne može konkurirati u novonastalom globalizacijskom okruženju potaknutom ubrzanim razvojem informacijske tehnologije. Brze promjene u društvu i u radnom okruženju uzrokovane pojačavajućom globalizacijskom polugom te akceleriranim razvojem i širenjem informacijsko-komunikacijske tehnologije jednako tako pridonose socijalnoj i ekonomskoj nejednakosti, što je posljedično dovelo do niza strukturnih promjena u gospodarstvima europskih država. Promjene su, između ostaloga, morale nastati zbog pojačane potrebe za većom tržišnom inkluzijom na tržištu rada Europske unije te kvalitetom, kako radnog, tako kauzalno, i obiteljskog života. Sve je to iziskivalo uvođenje različitih fleksibilnih oblika rada koji nude određene prednosti usporedno s radom na puno radno vrijeme kao što su, primjerice, bolja ravnoteža između posla i života za zaposlenike, više slobodnog vremena, bolja koncentracija i produktivnost na radnom mjestu. Od strane poslodavca prednosti su vidljive u aspektu smanjenja fluktuacije i apsentizma, povećanja lojalnosti zaposlenika, poboljšanja imidža tvrtke te uštede novca u vidu korištenja kapaciteta poduzeća.

Određene zemlje, mahom nordijske zemlje EU-a, su uz fleksibilnost na tržištu rada prepoznale važnost segmenta sigurnosti za zaposlenike od brojnih rizika na tržištu rada. Taj koncept se naziva fleksigurnost te predstavlja integriranu strategiju za istovremeno povećanje fleksibilnosti i sigurnosti na tržištu rada u kojoj se pokušavaju pomiriti potrebe poslodavaca za fleksibilnom radnom snagom s potrebom radnika za sigurnošću.

Mjerama koncepta fleksigurnosti nastoji se anticipativno djelovati u pogledu konstantnih promjena na tržištu rada koje neminovno sa sobom nose stanovite izazove.

Navedena problematika se u disertaciji istražila, kako teorijski, tako i na temelju opsežne analize prikazane u empirijskom dijelu disertacije.

8.2. Istraživački problem i emprijsko potvrđivanje i/ili odbacivanje postavljenih hipoteza

Istraživanjem u doktorskoj disertaciji htjelo se ispitati do koje mjere su se navedene strukturne promjene u gospodarstvima europskih država do 2018. godine operacionalizirale te jesu li time tržišta radne snage u promatranim državama postala fleksibilnija.

Dostupni radovi dosadašnjih istraživanja pridonose jednim dijelom boljem razjašnjenju ukupne varijance mjerenja utjecaja fleksibilnosti radne snage na gospodarski razvoj pojedine države članice EU-a. Međutim, najveći dio te varijance je neistražen i samim time nepoznat. Stoga je istraživanje od istaknutog značaja s obzirom na to da će pokušati preciznije utvrditi postoje li razlike u fleksibilnosti tržišta rada promatranih država EU-a te utječu li iste na gospodarski razvoj država i u kojoj mjeri.

Ova disertacija ima za svrhu identificirati koja su tržišta i u kojoj mjeri fleksibilna te ukazati na čimbenike koji utječu na višu razinu fleksibilnosti na tržištima rada zemalja EU-a.

Glavni cilj empirijskog istraživanja u ovoj disertaciji bio je analizirati relevantna obilježja tržišta radne snage EU-a te raspon fleksibilnosti radne snage na tržištu rada zemalja EU-a. Time se nastojalo definirati utječe li fleksibilnost tržišta rada na kretanje zaposlenosti i nezaposlenosti na tržištu rada EU-a.

Prvo istraživačko pitanje vezano je uz utjecaj fleksibilnosti tržišta rada na gospodarski razvoj zemalja EU-a. Prema rezultatima istraživanja dobivenih u disertaciji, u 72 % analiziranih zemalja vidljiv je pozitivan učinak implementacije fleksibilnih oblika rada na stimuliranje dinamike na tržištu rada i gospodarski razvoj zemalja EU-a, čime je hipoteza H1 parcijalno potvrđena. Fleksibilni oblici rada koji su bili podloga za analizu su rad u smjenama, večernji rad, noćni rad, rad subotom, rad nedjeljom i rad od kuće od 2008. do 2018. godine. Uz navedene fleksibilne oblike rada u disertaciji su u teorijskom dijelu navedeni i drugi fleksibilni oblici rada te svakako pojava novih fleksibilnih oblika kao što su *freelancer*, grupno zapošljavanje i dijeljenje posla koji su nakon 2020. godine i početka krize uzrokovane pandemijom dobili više na značaju te bi ih svakako trebalo uvrstiti u analize u budućim istraživanjima.

Kroz drugo istraživačko pitanje u disertaciji razmatra se stopa zaposlenosti u zemljama EU-a te se analizira utječe li na istu pozitivno povećanje udjela privremenog zapošljavanja i zapošljavanja na nepuno radno vrijeme. Evaluacijom rezultata analize podataka ustanovljeno je kako navedeni fleksibilni oblici ne utječu pozitivno na stope zaposlenosti samo u 8 od analiziranih 28 zemalja u promatranom razdoblju i utvrđenom uzorku, čime je hipoteza H1.1 parcijalno potvrđena. Prema dobivenim rezultatima, može se zaključiti kako se uvođenjem fleksibilnih oblika radnih mjesta ne samo povećava stopa zaposlenosti, nego i afirmira otvaranje novih radnih mjesta koja omogućuju zapošljavanje novih te zadržavanje trenutnih radnika.

Treće istraživačko pitanje vezano je uz utjecaj povećanja udjela fleksibilnih oblika rada na stopu nezaposlenosti. Rezultati ukazuju na činjenicu kako je u 14 % analiziranih zemalja djelomično, a u 39 % zemalja u potpunosti primjetno smanjenje stope nezaposlenosti s

porastom udjela fleksibilnih oblika rada kao što su rad u smjenama, večernji i noćni rad, rad subotom i nedjeljom te rad od kuće, što parcijalno potvrđuje hipotezu H1.2.

Rezultati impliciraju tvrdnju kako se promijenio stav ljudi vezan uz fleksibilne oblike rada. Ljudi danas ne streme isključivo zapošljavanju na stalne poslove s punim radnim vremenom pošto sve veći broj ljudi želi ostvariti koherenciju između poslovnog i privatnog života.

Četvrtim istraživačim pitanjem ocjenjuje se utjecaj razine obrazovanja na spremnost osoba na zapošljavanje na određeno radno vrijeme i na rad na nepuno radno vrijeme. Rezultati analize skupa relevantnih podataka vezanih uz razinu obrazovanja ispitanika ukazuju na apsolutnu potvrdu o razlici u proporciji zaposlenosti u fleksibilnim oblicima rada kod osoba različitih razina obrazovanja i to u svim promatranim zemljama, čime je hipoteza H2 potvrđena. Rezultati ukazuju na evidentnu razliku među proporcijama zaposlenosti u fleksibilnim oblicima rada kod osoba koje su niskoobrazovane, srednjeobrazovane i visokoobrazovane. Na temelju dobivenih rezultata, može se zaključiti kako su visokoobrazovane osobe u periodu od 2008. do 2018. godine bile manje sklone zapošljavanju na određeno radno vrijeme od srednjeobrazovanih te niskoobrazovanih osoba. U istom analiziranom periodu utvrdilo se kako su visokoobrazovane osobe bile daleko manje zaposlene na radnim mjestima na nepuno radno vrijeme nego što su to bile srednjeobrazovane te niskoobrazovane osobe.

Petim istraživačkim pitanjem razmatra se korelacija vremenskog razdoblja trajanja nezaposlenosti i dobne strukture radnika te njihove motivacije za traženjem novog posla. Analizom podataka za varijable dobna struktura radnika i vremensko razdoblje trajanja nezaposlenosti potvrdilo se postojanje korelacije između istih i to u svim analiziranim državama u razdoblju od 2008. do 2018. godine čime je prvi dio hipoteze H3 potvrđen. Rezultati analize ukazuju na činjenicu da je u svim državama udio ukupnog broja osoba od 25 do 54 godine nezaposlenih u trajanju od 3 do 5 mjeseci u ukupnom broju osoba od 15 do 64 godine koji su nezaposleni do 5 mjeseci veći od udjela ukupnog broja osoba od 15 do 24 godine nezaposlenih u trajanju od 3 do 5 mjeseci te udjela ukupnog broja osoba od 55 do 64 godine nezaposlenih u trajanju od 3 do 5 mjeseci.

U disertaciji se analizirala i korelacija između varijabli vremensko razdoblje trajanja nezaposlenosti i motivacija radnika za traženjem novog posla, gdje se potvrdila povezanost između nominalnih varijabli vremensko trajanje nezaposlenosti i motivacija radnika za traženjem novog posla te je ona statistički značajna, osim u slučaju Bugarske, čime je drugi dio hipoteze H3 potvrđen. Dobiveni rezultati ukazuju na činjenicu da je motivacija radnika za traženjem novog posla najveća u prvih mjesec dana od nastanka nezaposlenosti te se u tom periodu i najviše koriste različite metode za pronalaženje posla kao što su: odlazak na testiranja

i/ili intervjue, proučavanje oglasa u novinama ili časopisima te objava oglasa ili odgovor na oglas za posao.

U narednom potpoglavlju će se usporediti prethodno navedeni rezultati sa spoznajama drugih autora koji su proveli istraživanja u okviru fleksibilnosti tržišta rada.

8.3. Sinteza postignutih saznanja u doktorskoj disertaciji

Na temelju rezultata relevantnih studija koje će biti prikazane u nastavku argumentirat će se i istaknuti implikacije rezultata po postavljenim hipotezama.

Dugoročno gledano, demografska raspodjela (Otoiu, 2017), razvoj obrazovnog sustava (Jez, 2015, Amaral i suautori, 2015), dobna struktura stanovništva (Batyra i suautori, 2016, Anghelache i suautori, 2016) te učinak socijalnih normi na rad (Zweig, 2015, Balleer i suautori, 2014) važni su čimbenici koji utječu na tržište rada. Prema istraživanju Détang-Dessendre i suautora (2016) navedeno u Oliskevych & Lukianenko (2019: 1259), fleksibilnost radne snage, a koja se znatno razlikuje u različitim europskim zemljama, ima značajan utjecaj na svojstva tržišta rada.

Postoje oprečna mišljenja vezana uz koncept fleksibilnosti tržišta rada, a koja su navedena i u istraživanjima Grekousis & Gialis (2018) i Keune & Jepsen (2007), koji pojašnjavaju kako određene zemlje fleksibilizaciju vide kao lijek za gospodarsku recesiju i instrument koji potiče zapošljavanje i produktivnost, a s druge strane u pojedinim zemljama se nalaze dokazi o negativnim učincima fleksibilizacije zapošljavanja u EU-u na gospodarski rast.

Činjenica da fleksibilizacija tržišta rada ne dolazi uvijek s relevantnim poboljšanjem ukupnih stopa zaposlenosti i gospodarskog rasta nije nova (Gebel & Giesecke, 2011, 2016; Noelke, 2015; Barbieri & Cutuli, 2015; Boeri 2010). To se pokazalo i u analizi hipoteze H1. koja je djelomično potvrđena, a u kojoj je navedeno da je fleksibilnost tržišta radne snage pozitivno korelirana sa stupnjem razvijenosti zemlje. Prema Europskoj komisiji, države članice koje su primijenile sveobuhvatne reforme tržišta rada mogle su bolje podržati zapošljavanje. (Europska komisija, 2016) Alonson i suautori (2004) navode kako zemlje sa fleksibilnim tržištem rada imaju malu nezaposlenost, visoke dohotke te visok kapital po radniku. Štoviše, u istraživanju autora Di Tella i MacCulloch (2005) navedeno u Sahnoun i Abdennadher (2019: 104) ističe se kako zemlje s fleksibilnim tržištem rada imaju bolje ekonomske performanse (povećanje zaposlenosti i stope participacije) od rigidnih tržišta rada.

Često se tvrdi da su razlike između stopa nezaposlenosti u zemljama ili regijama djelomično objašnjive u smislu različitih stupnjeva "krutosti" na tržištu rada - ili pozitivno rečeno,

"fleksibilnosti". Smatra se da cjenovni šokovi koji nastaju u uvjetima "krutih" tržišta rada dovode do veće strukturne nezaposlenosti, dok "fleksibilna" tržišta rada omogućuju prilagodbe takvim šokovima bez gubitka zaposlenosti ili s malim gubitkom zaposlenosti. (Klau i Mittelstadt, 1986: 8)

Autori Bande i Karanassou (2009) te Baráth i Wojčák (2020) u svom radu također navode kako razlike u regionalnim stopama nezaposlenosti ovise o stupnju regionalne fleksibilnosti tržišta rada, što je parcijalno potvrđeno hipotezama H1.1 i H1.2 u kojima je navedeno da fleksibilni oblici rada imaju pozitivan utjecaj na stopu nezaposlenosti, odnosno da se porastom udjela takvih oblika rada smanjuje stopa nezaposlenosti.

Među svim osobnim karakteristikama, razina obrazovanja ima najveći utjecaj na pristup i upotrebu fleksibilnih radnih aranžmana. U istraživanju OECD-a 2016. navedeno je kako je vjerojatnije da će zaposlenici s fakultetskom diplomom imati veću kontrolu nad svojim radnim vremenom te da će barem povremeno raditi od kuće. Jednako tako, istraživanje Henlyja i suautora (2006) te Lamberta i Waxmana (2005) navedeno u O'Sullivan i suautori (2020: 50) potvrđuje kako će osobe sa zanimanjima na nižoj razini vjerojatnije raditi prema privremenim zahtjevima poslodavaca i rjeđe će imati pristup fleksibilnim aranžmanima prilagođenim radnicima od osoba sa zanimanjima na visokoj razini. Westerheide & Kauermann (2012: 16) u svom radu navode kako, gledajući razlike u obrazovanju, postaje jasno da visokoobrazovani pojedinci imaju veće šanse za ponovno zapošljavanje.

Giovanis (2018: 60) analizira primjenu fleksibilnog radnog vremena u kontekstu razine obrazovanja ispitanika. Za razliku od rezultata istraživanja prethodnih autora, rezultati istraživanja Giovanisa ukazuju na negativnu korelaciju visokoobrazovanih sa sažetim radnim tjednom kao fleksibilnim oblikom rada. Shodno tome, u istom istraživanju, prediktorska varijabla *razina obrazovanja – magisterij i doktorat* nema statistički zančajan utjecaj na kriterijsku varijablu *fleksibilno radno vrijeme*.

Isto je potvrđeno i hipotezom H2 u kojoj se ističe da se proporcija zaposlenosti na određeno radno vrijeme i proporcija zaposlenosti na nepuno radno vrijeme razlikuje kod osoba različitih razina obrazovanja te su visokoobrazovane osobe daleko manje zaposlene na radnim mjestima na nepuno radno vrijeme te na privremenim radnim mjestima.

Baumann (2016: 99) ističe kako postoje znatne razlike u duljini traženja posla prema dobi te stopi nezaposlenosti. Autori Pissarides (1992), Flückiger (2002: 15), Eriksson and Rooth (2014: 1029), Kroft i suautori (2013: 1128) u svom radu ističu kako duži periodi nezaposlenosti smanjuju izglede za ponovno zapošljavanje jer radnici gube znanje, motivaciju i samopouzdanje. Jednako tako, ističu činjenicu kako poslodavci percipiraju duge periode

nezaposlenosti kao negativan signal sposobnosti radnika. Navedeno je potvrđeno hipotezom H3 u kojoj se navodi da je vremensko razdoblje trajanja nezaposlenosti u korelaciji s dobnom strukturom radnika i njihovom motivacijom za traženjem novog posla. Rezultati analize hipoteze H3, jednako kao u istraživanjima Pissaridesa, Flückigera, Erikssona i Rootha, Krofta i suautora, ukazuju na činjenicu kako je motivacija za traženjem novog posla najveća u prvih mjesec dana od nastanka nezaposlenosti te nakon toga blago opada, ali se nanovo od trećeg do petog mjeseca povećava, no ne do razine koja je bila u prvom mjesecu.

8.4. Prediktivni model utjecaja fleksibilnosti tržišta rada na gospodarski razvoj zemalja EU-a

Na slici 7. prikazan je prediktivni model kojim se manifestira utjecaj fleksibilnosti tržišta rada na gospodarski razvoj zemalja, što je ujedno tercijarni cilj disertacije, a kojim se potvrđuju te parcijalno potvrđuju, ovisno o analiziranoj zemlji, prethodno navedene hipoteze u disertaciji.

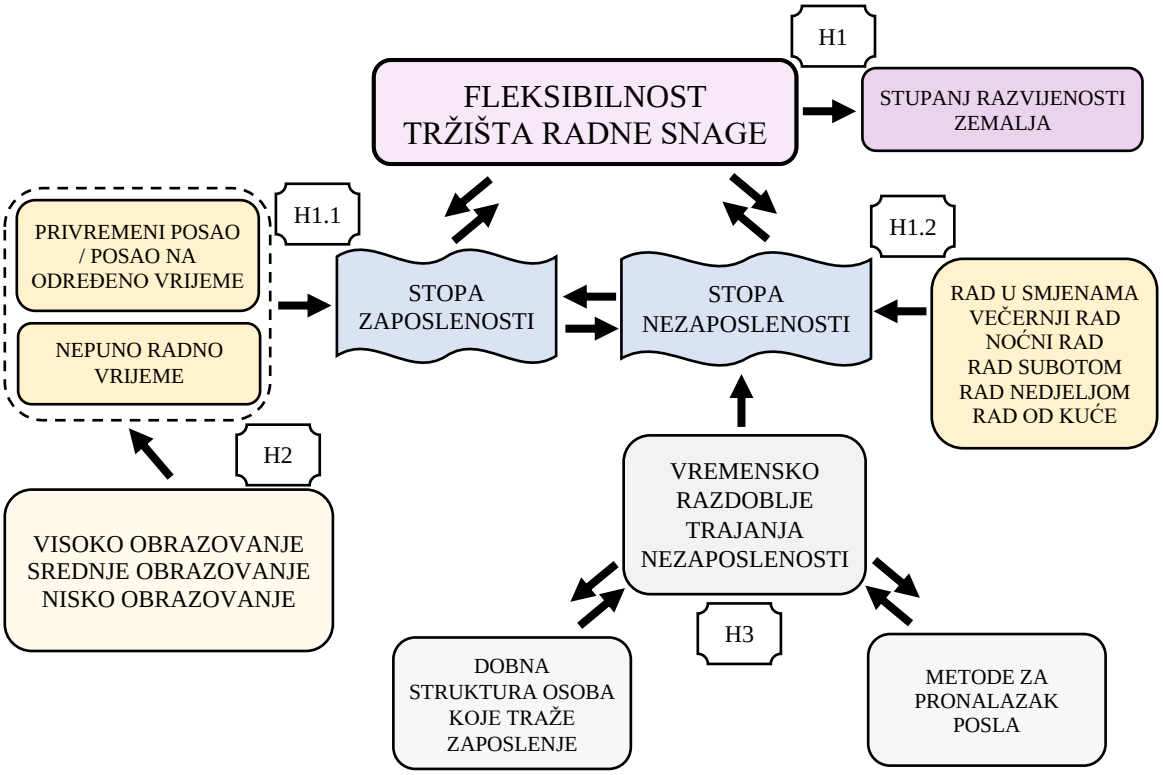

Slika 7. Prediktivni model utjecaja fleksibilnosti tržišta rada na gospodarski razvoj zemalja EU-a

Izvor: izrada autorice

Rezultati istraživanja u disertaciji pokazuju da su čimbenici koji nedvojbeno utječu na fleksibilnost tržišta radne snage povezani s razinom obrazovanja, dobnom strukturom radnika te motivacijom za pronalaženjem novog zaposlenja. Razina obrazovanja je bitan čimbenik jer se kroz istraživanje u disertaciji ono javlja kao ključan faktor u odluci o zapošljavanju na određeno vrijeme / na privremene poslove te o zapošljavanju na nepuno radno vrijeme. To posljedično utječe na stopu zaposlenosti te, u konačnici, na fleksibilnost tržišta radne snage.
Dobna struktura osoba koje traže zaposlenje je presudan faktor koji neprijeporno utječe na fleksibilnost tržišta radne snage u vidu spremnosti na participiranje u pojedinim fleksibilnim oblicima na tržištu rada, uz motivaciju za pronalaženjem novog zaposlenja koja se analizirala u kontekstu metoda za pronalazak posla kod osoba koje su u trenutku provođenja istraživanja bile nezaposlene na tržištu rada.
Dva bitna čimbenika koja su inicijalno navedena, uzročno-posljedično utječu na vremensko razdoblje trajanja nezaposlenosti. Ono se izravno reflektira na stopu nezaposlenosti. Povećanje, odnosno smanjenje fleksibilnih oblika rada kao što su rad u smjenama, večernji i noćni rad, rad subotom i nedjeljom te rad od kuće utječu na stopu nezaposlenosti koja se odražava na fleksibilnost tržišta radne snage.

U svrhu korištenja ovakvog modela, potrebno je napraviti predobradu u vidu podatkovnog rudarenja - tehnike koja pomaže analizirati empirijski velike izvore podataka, kao što je to slučaj u ovoj disertaciji i na toj osnovi donijeti zaključke ili potvrditi zaključke, koji bi inače mogli biti diskutabilni ili intuitivni. Za modeliranje u predobradi su korištene sljedeće statističke tehnike: linearna korelacijska analiza, višestruka linearna regresija te višestruka nelinearna regresija, test značajnosti razlike između proporcija te test povezanosti nominalnih varijabli.
S obzirom na to da je jedna od izlaznih varijabli u obliku kategorije stupanj razvijenosti zemalja, prediktivni model se transformira u problem klasifikacije.
Ovaj se model može primjenjivati na razini Europske unije, pošto izračun za agregirane vrijednosti svih zemalja EU-a pokazuje kako su sve hipoteze potvrđene, kao podloga nositeljima političkih odluka u kreiranju novih strategija i politika zapošljavanja te u osmišljavanju pravog miksa političkih mjera koje se bave dimenzijama fleksibilnosti i sigurnosti rada.
S druge strane, ako se promatra svaka zemlja pojedinačno, ovaj prediktivni model mogu koristiti sljedeće zemlje: Austrija, Cipar, Danska, Finska, Italija, Mađarska, Njemačka i Poljska.

9. ZAKLJUČAK

Tržište rada Europske unije dinamična je integracija koju takvom čini skup zemalja članica EU-a te radno aktivno stanovništvo kao pripadajuća fluidna varijabla. Uz navedene relevantne čimbenike, veliki utjecaj na promjene koje se događaju na tržištu rada svakako imaju obrazovanje, njegova dostupnost te institucije i zakonodavni okvir tržišta rada Europske unije te aktivne politike tržišta rada EU-a. U okviru kategorije obrazovanja, Europska unija nastoji svim građanima omogućiti pravo na obrazovanje, pravo na strukovno osposobljavanje, profesionalno usmjeravanje te raznovrsne prekvalifikacije. Također, veliki naglasak se stavlja na cjeloživotno obrazovanje koje radnicima pomaže ostati konkurentnima te im omogućuje kontinuiranu prilagodljivost promjenama na tržištu rada.

Iako u Europskoj uniji postoji cijeli niz podzakonskih akata na razini svake zemlje članice te je svakoj zemlji dopušteno imati slobodu u njihovoj provedbi, u Europskoj uniji se nastojalo unificirati navedene akte Zakonom o radu Europske unije kako bi se spriječilo nepropisno tumačenje i provođenje akata te svojevrsne manipulacije istima, a s druge strane, omogućiti i potaknuti kretanje ljudi i ostvarivanje jednakih prava svih građana EU-a u području radnog prava.

U neizvjesnom okruženju u kakvom se nalaze sva tržišta rada pa tako i tržište rada Europske unije, koje je, kao i ostala tržišta, neotporno na globalizacijske tijekove, ključnu ulogu u upravljanju navedenim promjenama imaju upravo koherentne aktivne politike tržišta rada koje imaju anticipativan učinak te, s druge strane, pomažu pojedincima u smanjenju vremenskog intervala nezaposlenosti između dvaju poslova i, svakako, u povećanju prilika za zapošljavanje. Još jedna relevantna stavka neminovno je i sigurnost u radnom i relevantnom socijalnom pravu na tržištu rada Europske unije. Kao jedan od lisabonskih ciljeva navodi se modernizacija sustava socijalne zaštite u okviru kojeg se, između ostalog, želi pružiti odgovarajuća prestacija za slučajeve nezaposlenosti, potaknuti nezaposlene ka aktivnijoj potrazi za zapošljavanjem te olakšati mobilnost na tržištu rada.

Ne tako davno, kreatori politika su spoznali važnost uvođenja koncepta fleksibilnosti. Sukus samog koncepta čine različiti fleksibilni oblici procesa rada, radnopravnog statusa, radnog vremena te organizacije rada. Upravo različiti netipični, jednako kao i tipični fleksibilni ugovorni aranžmani osiguravaju efikasniju te bržu prilagodbu radnika, kao i poduzetnika, novim okolnostima i uvjetima na tržištu rada.

Uz koncept fleksibilnosti, pojavljuje se i blizak mu koncept fleksigurnosti koji, za razliku od prethodnog, kompenzira komponentu sigurnosti. U disertaciji je prikazan danski model

fleksigurnosti kojim je, u kratkom vremenskom razdoblju, postignuto rastuće strukturno zapošljavanje i niska strukturna nezaposlenost.

Empirijski dio ove disertacije temelji se na analizi službenih podataka o istraživanju radne snage Europske unije (EU-LFS) dobivenih na temelju odobrenog projekta RPP 35/2020-LFS od Europske komisije i Eurostata te preuzetih s platforme S-CIRCABC. Podaci obuhvaćaju približno 2 milijuna ispitanika u razdoblju od 2008. godine do 2018. godine. EU-LFS službeni podaci sadrže podatke za sve države članice EU-a. Podaci pokrivaju sve industrije i profesije. U disertaciji su analizirani podaci zaposlenih i nezaposlenih osoba starijih od 15 godina i mlađih od 64 koji žive u kućanstvima. Osobe koje obavljaju obvezni vojni rok ili rad u javnom interesu nisu uključene u ciljanu skupinu istraživanja.

Provedeno istraživanje dalo je odgovore na postavljena istraživačka pitanja, i to kako slijedi:

1) prema rezultatima istraživanja tržišta rada Austrije, Belgije, Bugarske, Cipra, Francuske, Hrvatske, Litve, Nizozemske, Poljske, Rumunjske, Španjolske i Švedske fleksibilna su na način da osiguravaju viši stupanj razvijenosti zemlje (mjereno prema BDP-u po stanovniku)
2) povećanje udjela privremeno zaposlenih i zaposlenih na nepuno radno vrijeme utječe pozitivno na stopu zaposlenosti u ovim zemljama: Austriji, Cipru, Češkoj, Danskoj, Francuskoj, Grčkoj, Irskoj, Italiji, Latviji, Litvi, Luksemburgu, Mađarskoj, Malti, Njemačkoj, Poljskoj, Portugalu, Rumunjskoj, Španjolskoj i Švedskoj
3) porast udjela rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće u Austriji, Belgiji, Danskoj, Finskoj, Grčkoj, Italiji, Mađarskoj, Nizozemskoj, Njemačkoj, Poljskoj i Sloveniji djeluje na smanjenje stope nezaposlenosti
4) razina obrazovanja utječe na spremnost osoba na zapošljavanje na određeno radno vrijeme i na rad na nepuno radno vrijeme u svim državama te su rezultati istraživanja pokazali kako je udio niskoobrazovanih osoba koje rade u navedenim fleksibilnim oblicima rada veći od udjela osoba koje su srednjeobrazovane i visokoobrazovane u svakoj od 28 država članica EU-a u razdoblju od 2008. do 2018. godine
5) vremensko razdoblje trajanja nezaposlenosti u korelaciji je s dobnom strukturom radnika te je istraživanje pokazalo kako je u svim državama udio ukupnog broja osoba od 25-54 godine nezaposlenih u trajanju od 3 do 5 mjeseci najveći u odnosu na ukupni broj osoba od 15-64 godine koje su nezaposlene do 5 mjeseci.

Jednako tako, vremensko razdoblje trajanja nezaposlenosti u korelaciji je s motivacijom radnika za traženjem novog posla u svim državama, osim u slučaju Bugarske, te rezultati istraživanja ukazuju na činjenicu kako je motivacija radnika za traženjem novog posla najveća u prvih mjesec dana od nastanka nezaposlenosti te se u tom periodu i najviše koriste različite metode za pronalaženje posla kao što su odlazak na testiranja i/ili intervjue, proučavanje oglasa u novinama ili časopisima te objava oglasa ili odgovor na oglas za posao. Nakon mjesec dana motivacija za pronalaženjem posla blago opada, ali se nanovo od trećeg do petog mjeseca povećava, no ne do razine koja je bila u prvom mjesecu.

Na temelju postavljenih istraživačkih pitanja u emprijskom dijelu disertacije analizirane su postavljene hipoteze.

U hipotezi H1 korištena je linearna korelacijska analiza te je za svaku analiziranu zemlju izračunat koeficijent korelacije, koeficijent determinacije te pridružena statistička značajnost. Nadalje, koristila se regresijska analiza – model višestruke regresije i to: višestruka linearna regresija te višestruka nelinearna regresija pri čemu se odredila značajnost modela, koeficijent determinacije, pravac regresije i pripadajući ponderi prediktorskih varijabli.

Analizom hipoteze H1, kojom se navodi kako je fleksibilnost tržišta radne snage pozitivno korelirana sa stupnjem razvijenosti zemlje, uočena je anulacija iste u sljedećim državama: Estonija, Grčka, Irska, Malta, Portugal, Slovenija i Ujedinjeno Kraljevstvo od ukupno 28 promatranih država u vremenskom periodu od jedanaest godina, točnije od 2008. do 2018. godine. Time je hipoteza H1 parcijalno potvrđena. Može se zaključiti kako većina promatranih zemalja, njih čak 72 %, primjenjuje koncept fleksibilnosti te vidi pozitivne učinke samog koncepta bilo da se radi o većoj implementaciji fleksibilnih oblika zapošljavanja, čime se pružaju poslovne prilike nezaposlenima te smanjuje neprijavljeni nezakoniti rad, ili o evaluaciji dotadašnjih radnopravnih regulativa te definiranju novog fleksibilnijeg smjera radnih odnosa. Jednako tako, konceptom fleksibilnosti dolazi do same reorganizacije radnog vremena u organizacijama, potrebe za boljim poslovnim upravljanjem, učećom organizacijom i stimulativnijom poslovnom klimom, što vodi ka bržoj prilagodbi gospodarskim transformacijama te, u konačnici, intenzivnijoj gospodarskoj aktivnosti iz čega se može razaznati potreba za širenjem koncepta fleksibilnosti u tako velikom broju promatranih država. Kao pokazatelj razvijenosti zemalja u analizi hipoteze H1., korištena je varijabla BDP po stanovniku, što je jedno od ograničenja u disertaciji. Iako se ista koristi kao najčešća varijabla putem koje se mjeri gospodarski rast, preporuka da daljnje istraživanje bila bi analizirati

podatke za sve zemlje EU-a koristeći varijable kao što su rast populacije, profesionalna struktura radne snage, urbanizacija, potrošnja po stanovniku, infrastruktura i društveni uvjeti kao pokazatelje razvijenosti zemalja. Jednako tako, preporuka za daljnje istraživanje bi bila analizirati podatke korištene u hipotezi H1 putem regresijske analize koja je primijenjena na panel podacima te usporediti rezultate i utvrditi imaju li potonji veći utjecaj u potvrđivanju promatrane hipoteze.

Jednake statističke metode koristile su se za analizu podataka u hipotezi H1.1 kojom se predviđao pozitivan utjecaj povećanja udjela privremenog zapošljavanja i zapošljavanja na nepuno radno vrijeme na stopu zaposlenosti te u hipotezi H1.2 u kojoj je navedeno da se s porastom udjela rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće smanjuje se stopa nezaposlenosti.

Evaluacijom rezultata analize podataka u hipotezi H1.1 ustanovljeno je kako navedeni fleksibilni oblici ne utječu pozitivno na stope zaposlenosti sljedećih zemalja: Belgija, Bugarska, Estonija, Hrvatska, Island, Nizozemska, Slovenija i Ujedinjeno Kraljevstvo, u promatranom razdoblju i utvrđenom uzorku. Time je hipoteza H1.1 parcijalno potvrđena. Zanimljivo je istaknuti da u 75 % analiziranih zemalja fleksibilni oblici rada pozitivno utječu na stope zaposlenosti, što implicira činjenicu da tržište rada time postaje dinamičnije i inkluzivnije posebno za socijalno osjetljive skupine, kao što su nezaposlene mlade osobe, žene, dugotrajno nezaposlene osobe, osobe s niskim stupnjem obrazovanja, osobe s invaliditetom te pripadnici nacionalnih manjina. Prema dobivenim rezultatima može se zaključiti kako se uvođenjem fleksibilnih oblika radnih mjesta ne samo povećava stopa zaposlenosti, nego i afirmira otvaranje novih radnih mjesta koja omogućuju zapošljavanje novih te zadržavanje trenutnih radnika u slučaju masovnih otpuštanja.

U hipotezi H1.1. kao ograničenje može se navesti analiza podataka o udjelu privremeno zaposlenih osoba te zaposlenih na nepuno radno vrijeme. Uz privremeno zaposlene kao segment fleksibilnosti radnopravnog statusa preporuke za istraživanje su svakako usmjerene ka analizi rada na određeno vrijeme te, uz zaposlene na nepuno radno vrijeme kao aspekta fleksibilnosti radnog vremena, preporuka bi bila usmjerena ka analizi prekovremenog rada u kontekstu utjecaja na stope zaposlenosti.

Validacijom dobivenih rezultata u hipotezi H1.2 u odnosu na pretpostavku kako se s porastom udjela rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće smanjuje stopa nezaposlenosti, uočena je interesantna činjenica kako je ova hipoteza potvrđena

za zemlje: Austriju, Belgiju, Dansku, Finsku, Grčku, Italiju, Mađarsku, Nizozemsku, Njemačku, Poljsku i Sloveniju ili parcijalno potvrđena, ovisno o modelu, i to za sljedeće zemlje: Bugarsku, Cipar, Estoniju i Portugal. Time je hipoteza H1.2 parcijalno potvrđena.

Rezultati ukazuju na to kako je u većini analiziranih zemalja primjetno smanjenje stope nezaposlenosti s porastom udjela fleksibilnih oblika rada kao što su rad u smjenama, večernji i noćni rad, rad subotom i nedjeljom te rad od kuće, što ukazuje na činjenicu kako se promijenio stav ljudi vezan uz fleksibilne oblike rada. Ljudi danas ne streme isključivo zapošljavanju na stalne poslove s punim radnim vremenom pošto sve veći broj ljudi želi ostvariti koherenciju između poslovnog i privatnog života. Jednako tako, kroz rad na određeno vrijeme, kojemu u zadnje vrijeme sve više teže mlade osobe, ljudi imaju više vremena posvetiti se drugim aktivnostima ili kroz rad s nepunim radnim vremenom roditelji su u mogućnosti posvetiti se djeci ili brizi o starijim roditeljima. Iz perspektive poslodavaca, fleksibilni oblici rada omogućuju veću kontrolu fluktuacije zaposlenika te utječu na smanjenje troškova vezanih uz nova zapošljavanja te obuku novih zaposlenika.

U hipotezi H1.2. postoji ograničenje vezano uz korištenje stope nezaposlenosti koja se, prema smjernicama Međunarodne organizacije rada, odnosi na osobe u dobi od 15 do 74 godine (iznimno u Italiji, Španjolskoj i Ujedinjenom Kraljevstvu od 16 do 74 godine). U uzorku koji se analizira u disertaciji uključene su osobe od 15 do 64 godine u razdoblju od 2008. do 2018. godine. U tom razdoblju brojka koja se odnosi na osobe iznad 64 godine ne bi bitno utjecala i doprinijela promjeni, kroz analizu dobivenih rezultata pošto do 2018. udio osoba u EU-u koje su starije od 64 godine, a još uvijek participiraju na tržištu rada, nije značajan. U Europskoj Uniji u 2018. godini stope iznad 15 % zabilježene su samo u Estoniji (koja ujedno ima najvišu stopu od 26 %), Rumunjskoj, Litvi, Portugalu, Ujedinjenom Kraljevstvu, Irskoj, Švedskoj i Latviji. Stoga, preporuka za daljnje istraživanje bi svakako bila analizirati udio radne snage u dobi iznad 65 godina u svim zemljama EU-a nakon 2018. godine.

S ciljem analize hipoteze H2 korišten je test značajnosti razlike između proporcija. Hipotezom H2 se ispitalo razlikuje li se proporcija zaposlenosti na određeno radno vrijeme i proporcija zaposlenosti na nepuno radno vrijeme kod osoba različitih razina obrazovanja. Rezultati analize skupa relevantnih podataka za hipotezu H2 ukazuju na apsolutnu potvrdu prethodno navedene konstatacije o razlici u proporciji zaposlenosti u fleksibilnim oblicima rada kod osoba različitih razina obrazovanja i to u svim promatranim zemljama. Time je hipoteza H2 potvrđena.

Kao što je prethodno navedeno, rezultati ukazuju na evidentnu razliku među proporcijama zaposlenosti u fleksibilnim oblicima rada kod osoba koje su niskoobrazovane,

srednjeobrazovane i visokoobrazovane. U svim analiziranim državama može se primijetiti kako je udio ukupnog broja privremeno zaposlenih osoba koje su niskoobrazovane u ukupnom broju privremeno zaposlenih osoba svih razina obrazovanja veći od udjela ukupnog broja privremeno zaposlenih osoba koje su srednjeobrazovane te potom visokoobrazovane. Jednako tako, rezultati pokazuju kako je udio ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su niskoobrazovane u ukupnom broju osoba zaposlenih na nepuno radno vrijeme svih razina obrazovanja veći od udjela ukupnog broja osoba zaposlenih na nepuno radno vrijeme koje su srednjeobrazovane i visokoobrazovane. Na temelju dobivenih rezultata može se zaključiti kako su visokoobrazovane osobe u periodu od 2008. do 2018. godine bile manje sklone zapošljavanju na određeno radno vrijeme od srednjeobrazovanih te niskoobrazovanih osoba. U istom analiziranom periodu utvrdilo se kako su visokoobrazovane osobe bile daleko manje zaposlene na radnim mjestima na nepuno radno vrijeme nego što su to bile srednjeobrazovane te niskoobrazovane osobe, što se može povezati s iskrivljenom percepcijom o sigurnosti i stabilnosti radnog mjesta te perspektivnijem i stimulativnijem radnom okruženju s mogućnošću daljnje edukacije isključivo kod stalnih poslova s punim radnim vremenom. Preporuka za daljnje istraživanje u ovom aspektu bi bila utvrditi je li se nakon 2018. godine do danas promijenila percepcija o fleksibilnim oblicima rada kod visokoobrazovanih osoba.

U hipotezi H3 su određene kontingencijske tablice te se primijenio χ^2-test za ispitivanje povezanosti dviju nominalnih varijabli. Hipoteza je načelno podijeljena na dva dijela jer se u analizi separativno promatrao utjecaj dviju varijabli na varijablu vremensko razdoblje trajanja nezaposlenosti. U prvom dijelu hipoteze H3 analizirala se korelacija između varijabli dobna struktura radnika i vremensko razdoblje trajanja nezaposlenosti. Evaluacijom rezultata analize podataka za dane varijable potvrđuje se postojanje korelacije između istih i to u svim analiziranim državama u razdoblju od 2008. do 2018. godine.

Rezultati analize ukazuju na činjenicu da je u svim državama udio ukupnog broja osoba od 25-54 godine nezaposlenih u trajanju od 3 do 5 mjeseci u ukupnom broju osoba od 15 do 64 godine koje su nezaposlene do 5 mjeseci veći od udjela ukupnog broja osoba od 15 do 24 godine nezaposlenih u trajanju od 3 do 5 mjeseci te udjela ukupnog broja osoba od 55 do 64 godine nezaposlenih u trajanju od 3 do 5 mjeseci. Iz dobivenih rezultata može se zaključiti kako je najveći udio nezaposlenih osoba između 25 i 54 godine jer je to razdoblje u kojem je ujedno i najviši udio radne snage te poslodavci sebi traže najperspektivnije radnike, pokušavaju održavati ravnotežu između ponude i potražnje za poslom i/ili to jednostavno može biti efekt povremenih poremećaja u poslovnim ciklusima u kojima su poslodavci primorani smanjiti broj

radnih mjesta kao jednu od mjera izlaska iz krize. Jednako tako, osobe prelaze s jednog posla na drugi, ili, u slučaju napretka i usavršavanja tehnologije u poduzećima, mogu postati tehnološki višak. S druge strane, manji je udio u nezaposlenima kod osoba u dobi od 15 do 24 godine jer veliki dio istih nije završio svoje formalno obrazovanje te time još uvijek ne participira na tržištu rada. Preporuka za daljnje istraživanje u ovom kontekstu bi bila analizirati u periodu nakon 2018. godine koliko mladih osoba u dobi od 15 do 24 godine prakticira neki od fleksibilnih oblika rada uz formalno obrazovanje kao izvor prihoda.

Jednako tako, na temelju rezultata provedene analize se može konstatirati kako osobe u dobi od 55 do 64 godine prolaze vrhunac svoje karijere i približavaju se mirovini te u tom periodu teže ostaju bez posla ili napuštaju svoje radno mjesto te je zbog toga i u tom razredu evidentan manji udio nezaposlenih. Od 1. siječnja 2023. stupaju na snagu izmjene u mirovinskom sustavu Republike Hrvatske te će se osobama koje su u mirovini omogućiti pravo na rad do pola radnog vremena. Preporuka za daljnje istraživanje bi bila analiziranje podataka o broju osoba koje će koristiti ovaj fleksibilni oblik rada te usporedba s podacima drugih članica EU-a.

U drugom dijelu hipoteze H3 analizirala se korelacija između varijabli vremensko razdoblje trajanja nezaposlenosti i motivacija radnika za traženjem novog posla. Jednako kao i u analizi rezultata u prvom dijelu hipoteze H3, povezanost između nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* je statistički značajna, osim u slučaju Bugarske. Time je hipoteza H3 potvrđena.

Dobiveni rezultati ukazuju na činjenicu kako je motivacija radnika za traženjem novog posla najveća u prvih mjesec dana od nastanka nezaposlenosti te se u tom periodu i najviše koriste različite metode za pronalaženje posla kao što su odlazak na testiranja i/ili intervjue, proučavanje oglasa u novinama ili časopisima te objava oglasa ili odgovor na oglas za posao. Nakon mjesec dana motivacija za pronalaženjem posla blago opada, ali se nanovo od trećeg do petog mjeseca povećava, no ne do razine koja je bila u prvom mjesecu.

Preporuke za buduća istraživanja u ovom aspektu se odnose na targetiranje razine motivacije u vremenskom periodu nakon šest mjeseci od nastanka nezaposlenosti te analiziranje učinka drugih metoda za pronalaženje posla kao što je izravno obraćanje poslodavcu, kontaktiranje privatnih agencija za zapošljavanje i javnog zavoda za zapošljavanje te obraćanje prijateljima, rodbini i/ili sindikatu. Zanimljivo bi bilo doći i do podatka kolika je motivacija za ulazak u poduzetnički pothvat jer su svakako metode za pronalaženje posla i traženje zemljišta, prostora ili opreme zbog posla te traženje dozvola, licenci i financijskih sredstva zbog posla. U nekim zemljama je, nažalost, ulazak u poduzetnički pothvat u većoj mjeri obilježen pothvatima iz nužde što se dugoročno pokazuje pogrešno, a dovodi do niskog doprinosa stvaranju nove

vrijednosti i novog zapošljavanja. Vladine politike bi trebale biti djelotvornije u vidu pojednostavljenja regulatorne okoline te na stvaranje poduzetničke okoline djelovati više stimulirajuće nego ograničavajuće.

Na temelju prethodno navedenog može se istaknuti doprinos ekonomskoj znanosti u teorijskom smislu kroz istraživanjem dobivenih spoznaja koje bi trebale poslužiti boljem razumijevanju implementacije fleksibilnih oblika rada na tržište rada EU-a i na taj način dodatno objasniti ukupan varijabilitet u dosad slabije istraženim segmentima procesa zapošljavanja osoba u pojedinim fleksibilnim oblicima na tržištu rada EU-a.

Znanstveni doprinos disertacije u aplikativnom smislu očituje se kroz rezultate istraživanja koji mogu biti temelj za prosudbe i kreiranje novih strategija i politika zapošljavanja nositelja političkih odluka te učinkovitije kombiniranje mjera kojim bi se potaknula fleksibilnost tržišta rada. Prethodno je navedeno iz sljedećih razloga:

H1. 72 % tržišta rada Europske unije primjenjuje koncept fleksibilnosti u potpunosti (43 %) ili djelomično (29 %), što posljedično pozitivno utječe na gospodarski razvoj tih zemalja (validirano na temelju BDP-a po stanovniku)

H1.1. u 75 % analiziranih država povećanje udjela privremenog zapošljavanja i zapošljavanja na nepuno radno vrijeme ima u potpunosti (68 %) ili djelomično (7 %) pozitivan utjecaj na stopu zaposlenosti

H1.2. s porastom udjela rada u smjenama, večernjeg i noćnog rada, rada subotom i nedjeljom te rada od kuće u analiziranim zemljama Europske unije smanjuje se stopa nezaposlenosti u potpunosti (39 %) ili djelomično (14 %)

H2. u 100 % analiziranih država proporcija zaposlenosti na određeno radno vrijeme i proporcija zaposlenosti na nepuno radno vrijeme razlikuje se kod osoba različitih razina obrazovanja, s tim da je potvrđeno kako su visokoobrazovane osobe daleko manje zaposlene na određeno vrijeme i na nepuno radno vrijeme (analizirano od 2008. do 2018. godine)

$H3_1$ u 100 % analiziranih država vremensko razdoblje trajanja nezaposlenosti u izravnoj je korelaciji s dobnom strukturom radnika, s tim da je manji udio nezaposlenih zapažen kod osoba u dobi od 15 do 24 godine te od 55 do 64 godine

$H3_2$ u 96 % analiziranih država (u svim državama, osim Bugarske) vremensko razdoblje trajanja nezaposlenosti u izravnoj je korelaciji s motivacijom radnika za traženjem novog posla, s tim da treba naglasiti kako su zaključci dobiveni kroz analizu podataka sljedeći - motivacija radnika za traženjem novog posla najveća je u prvih mjesec dana od nastanka nezaposlenosti te se u tom periodu i najviše koriste različite metode za pronalaženje posla.

Jednako tako, preporuka kreatorima politike bi bila usmjerena ka uvođenju mjera kojima bi se minimalizirale nejednakosti i isključila diskriminacija osoba koje su zaposlene u fleksibilnim radnim oblicima te općenito uklonila stigmatizacija vezana uz fleksibilne oblike rada, osobito iz razloga što pretodno navedeni rezultati ukazuju na činjenicu kako fleksibilni oblici rada doprinose ekonomskom razvoju država EU-a. Osim navedenog, rezultati mogu biti podloga za generiranje inicijativa za promicanje ravnoteže na tržištu rada ovisno o analizi i stanju na nacionalnim razinama, kao i u osmišljavanju pravog miksa političkih mjera koje se bave dimenzijama fleksibilnosti i sigurnosti rada.

Preporuka je buduća istraživanja usmjeriti na analizu implementacije koncepta fleksibilnosti u zemljama koje u ovoj analizi nisu bile toliko uspješne u tome, bilo da je to iz razloga otpornosti promjenama koje za sobom povlače problematiku izmjene zakonskih regulativa, nužnosti uvođenja korjenite prilagodbe obrazovnog sustava potrebama tržišta rada ili redefiniranja modela socijalne zaštite u vezi s radnim odnosom, a povrh toga, zbog spornog financijskog faktora kao jedne od najvažnijih stavki u provođenju reformi ovakvog tipa.

Istodobno, trebalo bi ispitati neopravdanu i ozbiljnu segregaciju među radnicima na temelju vrste ugovora koji imaju, poglavito u uklanjanju oštre podvojenosti u zaštiti zaposlenja između ugovora o radu na neodređeno vrijeme i na određeno vrijeme.

Buduća istraživanja bi također trebala targetirati poboljšanja kvalitete osposobljavanja i prekvalifikacije na tržištu rada. Viša razina sigurnosti zaposlenja sigurno bi se postigla boljim programima osposobljavanja koji povećavaju zapošljivost tražitelja posla. Na prethodno navedeno se nadovezuje činjenica kako bi se na određenim tržištima rada trebale utvrditi neophodne vještine potrebne za uravnoteženje tržišta rada koje bi uključivalo relevantno, međusobno konzistentno, ekonomsko i socijalno pravo, socijalne partnere te važne dijelove civilnog društva.

Nastavno na detektirano ograničenje u disertaciji koje se ogleda u limitiranosti promatranog razdoblja na 11 godina, točnije od 2008. do 2018. godine, može se rezonirati kako bi ove pojave bilo interesantno analizirati za razdoblje od 2019. godine do danas kako bi se istražili efekti promjena nastalih u tom razdoblju na operacionalizaciju koncepta fleksibilnosti, poglavito fleksibilnih oblika rada, te, usporedno, koncepta fleksigurnosti čije je postulate formulirala te uspješnim primjerom dokazala Danska.

Jednako tako, u empirijskom dijelu disertacije analiza je ograničena na fleksibilnost radnog vremena i fleksibilnost radnopravnog statusa u kontekstu narednih varijabli: *rad na određeno vrijeme, rad s nepunim radnim vremenom, privremeno zapošljavanje, rad u smjenama, večernji*

rad, noćni rad, rad subotom, rad nedjeljom i rad od kuće. Preporuka za daljnje istraživanje u ovom kontekstu, a u sferi konstantnog rasta i razvoja digitalnih platformi, bi trebala ići u smjeru istraživanja implementacije i učinka novih oblika zapošljavanja kao što su: *freelancer*, grupno zapošljavanje[41], dijeljenje posla, privremeno upravljanje i druge vrste novih oblika rada u digitalnoj ekonomiji EU-a.

[41] engl. *crowd employment* - novi oblik zapošljavanja koji koristi digitalne platforme kako bi se organizacijama ili pojedincima omogućio pristup neodređenoj i nepoznatoj skupini drugih organizacija ili pojedinaca za rješavanje određenih problema ili pružanje određenih usluga ili proizvoda u zamjenu za plaćanje

10. LITERATURA

1. Alonso-Villar, O., Chamorro-Rivas, J. M., & González-Cerdeira, X. (2004). Agglomeration economies in manufacturing industries: The case of Spain. *Applied Economics*, 36. 2103-2116.
2. Amaral, E., Queiroz, B., Calazans, J. (2015). Demographic changes, educational improvements, and earnings in Brazil and Mexico. *IZA Journal of Labor & Development*. Vol. 4 No. 1. pp. 1-21.
3. Anderson, C. J. (2009). The private consequences of public policies: active labor market policies and social ties in Europe. *European Political Science Review*, 1(03), 341. doi:10.1017/s1755773909990130
4. Anderson, S. K., Mailand, M. (2005). *The Danish Flexicurity Model*: *The Role of the Collective Bargaining System*. Department of Sociology. University of Copenhagen.
5. Anghelache, C., Manole, A., Anghel, M., Sacala, C. (2016). The analysis of the labor force resources market. *Romanian Statistical Review*. Vol. 64 No. 12, pp. 132-139.
6. Atkinson, T., Cantillon, B., Marlier, E., Nolan, B. (2002). *Social Indicators: The EU and Social Inclusion*. Oxford University Press. ISBN 0-19-925349-8
7. Atkinson, T., Cantillon, B., Marlier, E., Nolan, B. (2005). *Taking Forward the EU Social Inclusion Process*. An Independent Report commissioned by the Luxembourg Presidency of the Council of the European Union. Dostupno na: https://travail-emploi.gouv.fr/IMG/pdf/final_report.pdf [pristupljeno: 23. studenog 2020.]
8. Ayouba, K., Le Gallo, J., Vallone, A.: (2019). *Beyond GDP: an analysis of the socio-economic diversity of European regions*. Applied Economics, doi:10.1080/00036846.2019.1646885
9. Babos, P. (2014). *Step or trap? Transition from fixed-term contracts in Central Eastern Europe*. Post-Communist Economies. Vol. 26, No. 1, 39–52. doi: 10.1080/14631377.2014.874230
10. Baglioni, S., Giugni, M., Bacia, E., Bassoli, M., Cinalli, M., Eriksson, B., Grimmer, B., Hobbins, J., Lahusen, C., Lorenzini, J., Mosca, L., Mota, L., Mourão, M.V., Theiss, M. (2014). *Civil Society Organizations, Unemployment, and Precarity in Europe - Between Service and Policy*. PALGRAVE MACMILLAN.
DOI 10.1057/9780230391437. ISBN 978-1-349-35158-9

11. Baitenizov, D. T., Dubina, I. N., Campbell, D. F. J., Carayannis, E. G., Azatbek, T. A. (2018). Freelance as a Creative Mode of Self-employment in a New Economy (a Literature Review). *Journal of the Knowledge Economy*. doi:10.1007/s13132-018-0574-5
12. Bajzíková, L., Bajzík, P. (2020). *Mobility and working opportunities in the EU and Slovakia*. Journal of Contemporary Management Issues, Vol. 25, 2020, No.1, pp. 103-115.
13. Ball, L., Moffittm, R. (2001). *Productivity Growth and the Phillips Curve*. Cambridge: National Bureau of Economic Research. pp. 1–52.
14. Balan, M. (2014). *Analysis of unemployment among young individuals from Romania by econometric methods*. Internal Auditing and Risk Management. 9(3). pp. 90-97.
15. Balleer, A., Gomez-Salvador, R., Turunen, J. (2014). Labour force participation across europe: a cohort-based analysis. *Empirical Economics*. Vol. 46 No. 4, pp. 1385-1415.
16. Bande, R., Karanassou, M. (2009). *Labour market flexibility and regional unemployment rate dynamics: Spain 1980–1995*. Papers in Regional Science. Volume 88 Number 1
17. Baráth, M., Wojčák, E. (2020). Effects of Changing Unemployment Rate, GDP per capita nad Part-time in Selected European Countries During 2008-2017. Vision 2020: Sustainable Economic Development and Application of Innovation Management
18. Barbieri, P. (2009). Flexible Employment and Inequality in Europe. *European Sociological Review*, 25(6), 621–628. doi:10.1093/esr/jcp020
19. Barca, F. (2009). *Towards a territorial social agenda for the European Union*. Ministry of Economy and Finance, Italy
20. Barnichon, R. (2010). Productivity and unemployment over the business cycle. *Journal of Monetary Economics*. Vol. 57. pp. 1013–1025.
21. Barslund, M., Busse, M. (2014). *Labour Mobility in the EU: Dynamics, Patterns and Policies*. Intereconomics. ZBW – Leibniz Information Centre for Economics. doi: 10.1007/s10272-014-0495-x
22. Batyra, A., Croix, D., Pierrard, O., Sneessens, H. (2016). Structural changes in the labor market and the rise of early retirement in Europe. *CREA Discussion Paper Series*. No. 16-13. Center for Research in Economic Analysis. University of Luxembourg.
23. Baumann, I. (2016). *Job Search Strategies and Unemployment Duration*. In book: The Plight of Older Workers. pp. 91-107. doi:10.1007/978-3-319-39754-2_5
24. Beck, W., van der Maesen, L., Thomese, F. and Walker, A. (2001). *Social Quality: A Vision for Europe*. The Hague/London/Boston, Kluwer Law International.

25. Becker, P. (2018). The reform of European cohesion policy or how to couple the streams successfully. *Journal of European Integration*. Volume 41, 2019 - Issue 2. pp. 147-168. doi.org/10.1080/07036337.2018.1553964. Dostupno na: https://www.tandfonline.com/doi/full/10.1080/07036337.2018.1553964 [pristupljeno: 14. siječnja 2021.]
26. Bečić, E., Ciglenečki, N., Ćavar, J., Čulo, I., Klapan, A., Leko, A., Matijević, M., Miščin, D., Rajić, V., Šarić, T., Škegro-Vdović, M., Vrcelj, S., Žiljak, O., Žiljak, T. (2009). *Međunarodne organizacije o obrazovanju odraslih*. I. dio. Vijeće Europe i Europska unija; Pojmovnik politika obrazovanja odraslih i dokumenti. Zagreb: Agencija za obrazovanje odraslih
27. Bečić, E., Ciglenečki, N., Ćavar, J., Čulo, I., Klapan, A., Tomić, A., Matijević, M., Miščin, D., Rajić, V., Šarić, T., Škegro-Vdović, M., Vrcelj, S., Žiljak, O., Žiljak, T. (2010). *Međunarodne organizacije o obrazovanju odraslih*. II. dio. Ujedinjeni narodi (UNESCO, Svjetska banka, Međunarodna organizacija rada), OECD i dokumenti. Zagreb: Agencija za obrazovanje odraslih
28. Berg, J. (2015). *Labour Markets, Institutions and Inequality*. Building Just Societies in the 21st Century. International Labour Office. Geneva. Dostupno na: https://www.ilo.org/wcmsp5/groups/public/---dgreports/---dcomm/---publ/documents/publication/wcms_347249.pdf [pristupljeno: 20. siječnja 2021.]
29. Blanpain, R. (1995). *European Labour Law*. Deventer: Kluwer Law and Taxation Publishers. ISBN: 9065448721
30. Bogunović, A. (2006). Europska unija - stanje i perspektive. *EKONOMSKI PREGLED*, Vol. 57 No. 1-2. str. 31-63. Dostupno na: https://hrcak.srce.hr/8014 [pristupljeno: 9. prosinca 2020.]
31. Boudalaoui-Buresi, Z., Szpejna, M. (2020). *The scope of EU labour law*. Policy Department for Economic, Scientific and Quality of Life Policies. Directorate-General for Internal Policies. European Parliament. PE 658.181 - October 2020. Dostupno na: https://www.europarl.europa.eu/RegData/etudes/IDAN/2020/658181/IPOL_IDA(2020)658181_EN.pdf [pristupljeno: 20. ožujka 2021.]
32. Bredgaard, T., Flemming, L., Madsen, P. K. (2005). The flexible Danish labour market. Centre for Comparative Welfare Studies, Institut for Økonomi, Politik og Forvaltning, Aalborg Universitet. ISBN 8789639278.

33. Bruno, R. L., Rovelli, R. (2010). Labour Market Policies and Outcomes in the Enlarged EU. JCMS: *Journal of Common Market Studies*, 48(3), pp. 661–685. doi:10.1111/j.1468-5965.2010.02068.x
34. Buddelmeyer, H., Mourre, G., Ward-Warmedinger, M. E. (2004). *The Determinants of Part-Time Work in EU Countries: Empirical Investigations with Macro-Panel Data*. Dostupno na: http://dx.doi.org/10.2139/ssrn.609924 [pristupljeno: 20. ožujka 2021.]
35. Buettner, T. (2007). *Unemployment disparities and regional wage flexibility: comparing EU members and EU-accession countries*. Empirica (2007) 34:287–297. doi: 10.1007/s10663-006-9032-x.
36. Buiter, W. H. (2001). *Globalisation and regional integration; A view from Eastern Europe and the FSU*. House of Lords, Session 2001-02, Select Committee on Economic Affairs. Globalisation, pp. 83-96, London. Dostupno na: https://www.academia.edu/6428263/Globalisation_and_regional_integration_A_view_from_Eastern_Europe_and_the_FSU [pristupljeno: 9. siječnja 2021.]
37. Burdin, G., Pérotin, V. (2019). *Employee representation and flexible working time*. Labour Economics 61 (2019) 101755.
38. Bušelić, M. (2014). *Tržište rada: teorijski pristup*. Pula: Sveučilište Jurja Dobrile, Fakultet za ekonomiju i turizam „Dr. Mijo Mirković“.
39. Bušelić, M. (2017). *Suvremeno tržište rada*. Pula: Sveučilište Jurja Dobrile, Fakultet za ekonomiju i turizam „Dr. Mijo Mirković“.
40. Butković, H., Samardžija, V. (2019). *Digitalna transformacija tržišta rada u Hrvatskoj*. Zagreb: Institut za razvoj i međunarodne odnose.
41. Butkus, M., Seputiene, J. (2019). The Output Gap and Youth Unemployment: An Analysis Based on Okun’s Law. *Economies*. 7(4), 108. doi:10.3390/economies7040108
42. Bux, U. (2020). *Građani Unije i njihova prava*. Europski parlament. Dostupno na: https://www.europarl.europa.eu/factsheets/hr/sheet/145/gra%C4%91ani-unije-i-njihova-prava [pristupljeno: 16. studenog 2020.]
43. Campbell, R., McConnell and Brue, S. L. (1994). *Suvremena ekonomija rada*. Treće izdanje. Zagreb: MATE d.o.o.
44. Canetta, E., Fries-Tersch, E., Mabilia – Milieu, V. (2014). *2014 Annual report on statistics on intra-EU movers*. European Commission.
45. Carr, A. E., Li-Ping Tang, T. (2005). Sabbaticals and Employee Motivation: Benefits, Concerns, and Implications. *Journal of Education for Business*. 80(3), pp. 160–164. doi:10.3200/joeb.80.3.160-164

46. Cazes, S., Nesporova, A. (2007). *Flexicurity, a relevant approach in Central and Eastern Europe*. ISBN 9221192156. Geneva: International Labor Office.
47. Chand, K., Tiwari, R., Phuyal, M. (2017). Economic growth and unemployment rate: an empirical study of Indian economy. *PRAGATI: Journal of Indian Economy*. Volume 4, Issue 2, July-December 2017, pp. 130-137. doi: 10.17492/pragati.v4i02.11468
48. Christopoulos, D. K., Le´on-Ledesma, M. A. (2010). *Revisiting the real wages–unemployment relationship. New results from non-linear models*. Bulletin of Economic Research 62:1. 0307-3378. DOI: 10.1111/j.1467-8586.2009.00311.x
49. Comi, S., Grasseni, M. (2011). Are Temporary Workers Discriminated Against? Evidence from Europe. Manchester School 80(1):28 – 50. DOI:10.1111/j.1467-9957.2011.02231.x
50. Commission of the European Communities (2007). *Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions - Towards Common Principles of Flexicurity: More and better jobs through flexibility and security*. Brussels. COM(2007) 359 final. Dostupno na: https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2007:0359:FIN:EN:PDF [pristupljeno: 2. ožujka 2021.]
51. Commission of the European Communities, (2006). *GREEN PAPER - Modernising labour law to meet the challenges of the 21st century*. COM(2006) 708 final. Brussels. Dostupno na: https://www.europarl.europa.eu/meetdocs/2004_2009/documents/com/com_com(2006)0708_/com_com(2006)0708_en.pdf [pristupljeno: 5. ožujka 2021.]
52. Commission of the European Communities (2008). *Renewed social agenda: Opportunities, access and solidarity in 21st century Europe*. Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions. pp. 19. Dostupno na: https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2008:0412:FIN:EN:PDF [pristupljeno: 2. prosinca 2020.]
53. Conti, G. (2005). *Training, productivity and wages in Italy*. Labour Economics. Vol. 12, issue 4. pp. 557–576.
54. Corominas, A., Lusa, A., Pastor, R. (2005). *Annualised Hours: A Real Flexibility Tool*. OR Insight, 18(1), 10–14. doi:10.1057/ori.2005.3

55. Crampton, S., Douglas, C., Hodge, J., Mishra, J. (2003). *Job Sharing: Challenges and Opportunities*. Seidman Business Review: Vol. 9: Iss. 1, Article 11. Dostupno na: http://scholarworks.gvsu.edu/sbr/vol9/iss1/11 [pristupljeno: 5. ožujka 2021.]
56. Cristea, A. M., Cristea, D. G., Balint, A. O., Boboc, L. S., Samoilă, E. P. (2014). *Mobility, demography and consumption in the European community*. Vision 2020: Sustainable Growth, Economic Development, and Global Competitiveness - Proceedings of the 23rd International Business Information Management Association Conference, IBIMA 2014. Volume 1, 2014, p.p. 1541-1552.
57. d'Addio, A. C., Cavelleri, M. C. (2015). Labour Mobility and the Portability of Social Rights in the EU. *CESifo Economic Studies*. Volume 61, Issue 2, June 2015, pp. 346–376. doi: 10.1093/cesifo/ifu014. Dostupno na: https://academic.oup.com/cesifo/article/61/2/346/296069 [pristupljeno: 10. siječnja 2021.]
58. Dearden, L., Reed, H., Van Reenen, J. (2006). *The impact of training on productivity and wages: Evidence from British panel data*. Oxford Bulletin of Economics and Statistics. Vol. 68. pp. 397–421.
59. Détang-Dessendre, C., Partridge, M. D., Piguet, V. (2016). Local labor market flexibility in a perceived low migration country: the case of French labor markets. *Regional Science and Urban Economics*. Vol. 58 No. C, pp. 89-103.
60. Dimitrova, T. (2014). Građanstvo Europske Unije – neki aspekti provedbe prava Europske unije u vezi s građanstvom - prikaz postupaka koje su pokrenuli bugarski državljani i bugarski sudovi. *Zbornik PFZ*, 64, (4) 687-700.
61. Di Tella, R., & MacCulloch, R. (2005). The consequences of labor market flexibility: Panel evidence based on survey data. *European Economic Review*, 49, 1225-1259.
62. Dixon, R., Lim, G. C., van Ours, J. C. (2016). Revisiting the Okun relationship. *Applied Economics*. 49(28), 2749–2765. doi:10.1080/00036846.2016.1245846
63. Domović, V., Gehrmann, S., Krüger-Potratz, M., Petravić, A. (2011). *Europsko obrazovanje*. Koncepti i perspektive iz pet zemalja. Zagreb: Školska knjiga d.d.
64. Domović, V., Gehrmann, S., Helmchen, J., Krüger-Potratz, M., Petravić, A. (2013). *Europsko obrazovanje učitelja i nastavnika – na putu prema novom obrazovnom cilju*. Izvještaji iz Zapadne i Jugoistočne Europe. Zagreb: Školska knjiga d.d.
65. Dragičević, A. (1979). Marxov pristup političkoj ekonomiji. *Politička misao: časopis za politologiju*, Vol. 16 No. 4, str. 549-561. Dostupno na: https://hrcak.srce.hr/114629 [pristupljeno: 22. prosinca 2020.]

66. Economou, A., Psarianos, I. N. (2016). Revisiting Okun's Law in European Union countries. *Journal of Economic Studies*, 43(2), 275–287. doi:10.1108/jes-05-2013-0063
67. Efrianti, R., Marwa, T., Tarmizi, N., Yuliana, S. (2018). Growth, unemployment and its implication on poverty: empirical study in districts/cities of south Sumatera province. *Eurasian Journal of Economics and Finance*. 6(4), pp. 27-37. DOI: 10.15604/ejef.2018.06.04.003
68. Eichhorst, W., Devisscher, S., Leoni, T., Marx, P., Mühlberger, U., Schulte, B., Vandeweghe, B. (2010). *Analysis of the Social Agendas*. Institute of Labor Economics. Dostupno na: http://ftp.iza.org/report_pdfs/iza_report_24.pdf [pristupljeno: 28. prosinca 2020.]
69. Eichhorst, W., Konle-Seidl, R. (2016). *Evaluating Labour Market*. Policy, IZA Discussion Papers, No. 9966, Institute for the Study of Labor (IZA). Bonn. Dostupno na: https://www.econstor.eu/bitstream/10419/142405/1/dp9966.pdf [pristupljeno: 22. veljače 2021.]
70. Eita, J. H., Ashipala, J. M. (2010). Determinants of Unemployment in Namibia. *International Journal of Business and Management*. 5 (10). pp. 1-13.
71. Eriksson, Å. (2005). *Wage Formation and the Relation between Real Wages and Unemployment in Sweden*. Working Paper, No. 2006:1. Lund University, School of Economics and Management, Department of Economics, Lund.
72. Ertman, A. (2011). *Zróz˙nicowanie elastycznos´ci rynków pracy w wybranych krajach europejskich oraz USA w s´wietle metody TOPSIS.Oecon*. Copernic. 3, 43–64.
73. EU Labour Force Survey (2020). *Database User Guide*. Dostupno na: https://ec.europa.eu/eurostat/documents/1978984/6037342/EULFS-Database-UserGuide.pdf [pristupljeno: 8. prosinca 2020.]
74. Eurobarometer (2008). *Discrimination in the European Union: Perceptions, Experiences and Attitudes*. Special Eurobarometer 296 / Wave 69.1 – TNS opinion & social. Dostupno na: https://ec.europa.eu/commfrontoffice/publicopinion/archives/ebs/ebs_296_sum_en.pdf [pristupljeno: 1. ožujka 2021.]
75. Eurofound (2021) *Labour market policies*. Dostupno na: https://www.eurofound.europa.eu/topic/labour-market-policies [pristupljeno: 22. veljače 2021.]
76. Eurofound (2020). *Migration and mobility*. European Foundation for the Improvement of Living and Working Conditions. Dostupno na:

https://www.eurofound.europa.eu/topic/migration-and-mobility [pristupljeno: 22. prosinca 2020.]

77. Eurofound (2018). *The social and employment situation of people with disabilities*. Publications Office of the European Union. Luxembourg. ISBN: 978-92-897-1759-5. doi: 10.2806/213629. Dostupno na: https://www.eurofound.europa.eu/sites/default/files/ef_publication/field_ef_document/ef18023en.pdf [pristupljeno: 25. studenog 2020.]
78. Europa (2021_a). *A Europe fit for the digital age*. Dostupno na: https://ec.europa.eu/info/strategy/priorities-2019-2024/europe-fit-digital-age_en [pristupljeno: 9. siječnja 2021.]
79. Europa (2020_a). *Fixed-term work*. Your Europe. Dostupno na: https://europa.eu/youreurope/business/human-resources/employment-contracts/fixed-term-work/index_en.htm [pristupljeno: 22. prosinca 2020.]
80. Europa, EUR-Lex (2015). *Nova strategija jedinstvenog digitalnog tržišta EU-a*. Dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=LEGISSUM:3102_3 [pristupljeno: 3. prosinca 2020.]
81. Europa (2020_b). *Obrazovanje, osposobljavanje i mladi*. Potpora kvalitetnom obrazovanju, osposobljavanju i socijalnoj koheziji. Dostupno na: https://europa.eu/european-union/topics/education-training-youth_hr [pristupljeno: 20. studenog 2020.]
82. Europa (2021_b). *Tržišno natjecanje*. Održavanje i promicanje poštenog tržišnog natjecanja. Dostupno na: https://europa.eu/european-union/topics/competition_hr [pristupljeno: 19. siječnja 2021.]
83. European Commission (2021_a). *Agencies and partners*. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?langId=en&catId=85 [pristupljeno: 19. siječnja 2021.]
84. European Commission (2017_a). *Aktivne politike tržišta rada*. Tematski informativni članak o europskom semestru. Dostupno na: https://ec.europa.eu/info/sites/info/files/file_import/european-semester_thematic-factsheet_active-labour-market-policies_hr.pdf [pristupljeno: 22. veljače 2021.]
85. European Commission (2021_b). *A new, stronger European Social Fund Plus*. European Social Fund. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/esf/main.jsp?catId=62&langId=en [pristupljeno: 18. siječnja 2021.]

86. European Commission (2021_c). *Chapters of the acquis*. Dostupno na: https://ec.europa.eu/neighbourhood-enlargement/policy/conditions-membership/chapters-of-the-acquis_en [pristupljeno: 10. siječnja 2021.]
87. European Commission (2013). *Co-creating European Union Citizenship*. Policy review. doi: 10.2777/10181. Luxembourg: Publications Office of the European Union. Dostupno na: https://ec.europa.eu/research/social-sciences/pdf/policy_reviews/co-creating_eu_citizenship.pdf [pristupljeno: 19. siječnja 2021.]
88. European Commission (2020_a). *Digital Economy and Society Index (DESI) 2020*. Thematic chapters. Dostupno na: https://ec.europa.eu/digital-single-market/en/digital-economy-and-society-index-desi [pristupljeno: 3. prosinca 2020.]
89. European Commission (2021_d). *Digital Scoreboard*. Dostupno na: https://digital-agenda-data.eu/charts/desi-components#chart={%22indicator%22:%22desi%22,%22breakdown-group%22:%22desi%22,%22unit-measure%22:%22egov_score%22,%22time-period%22:%222018%22} [pristupljeno: 18. veljače 2021.]
90. European Commission, Eurostat (2020_b). *Employment and unemployment (LFS)*. Database. Dostupno na: https://ec.europa.eu/eurostat/web/lfs/data/database [pristupljeno: 20. studenog 2020.]
91. European Commission (2021_e). *Employment package*. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?catId=1039&langId=en [pristupljeno: 10. siječnja 2021.]
92. European Commission (2021_f). *ESF budget by country: 2014-2020*. European Social Fund. Dostupno na: https://ec.europa.eu/esf/main.jsp?catId=443&langId=en [pristupljeno: 16. siječnja 2021.]
93. European Commission (2017_b). *EU competition policy in action*. Luxembourg: Publications Office of the European Union. doi: 10.2763/897035. Dostupno na: https://op.europa.eu/en/publication-detail/-/publication/b11a5d15-c5ca-11e7-9b01-01aa75ed71a1 [pristupljeno: 19. siječnja 2021.]
94. European Commission (2015). *EU Labour Market Policies: how active are we and how do we respond to unemployment?* Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?langId=en&catId=1196&newsId=2389&furtherNews=yes [pristupljeno: 20. veljače 2021.]

95. European Commission (2021$_g$). *EU policy in the field of adult learning*. Education and Training. Dostupno na: https://ec.europa.eu/education/policies/eu-policy-in-the-field-of-adult-learning_en [pristupljeno: 24. siječnja 2021.]
96. European Commission, (2021$_h$). *EU Programme for Employment and Social Innovation (EaSI).* Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?langId=en&catId=1081 [pristupljeno: 18. siječnja 2021.]
97. European Commission, (2020$_c$). *European Education Area*. Education and Training. Dostupno na: https://ec.europa.eu/education/education-in-the-eu/european-education-area_en [pristupljeno: 20. studenog 2020.]
98. European Commission (2019). *European Network of Public Employment Services*. Index on Quality of ALMP Implementation: Study Report. Directorate-General for Employment Social Affairs and Inclusion. Luxembourg: Publications Office of the European Union. doi: 10.2767/117185.
99. European Commission (2021$_i$). *External Relations*. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?catId=87&langId=en [pristupljeno: 18. siječnja 2021.]
100. European Commission (2021$_j$). *Inclusion of non-EU migrants*. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?catId=1274&langId=en [pristupljeno: 18. siječnja 2021.]
101. European Commission (2021$_k$). *Labour law*. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?catId=157&langId=en [pristupljeno: 18. siječnja 2021.]
102. European Commission (2021$_l$). *Long-term unemployment*. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?catId=1205&langId=en [pristupljeno: 28. veljače 2021.]
103. European Commission (2018). *New measures to boost key competences and digital skills, as well as the European dimension of education*. Dostupno na: https://ec.europa.eu/commission/presscorner/detail/en/IP_18_102 [pristupljeno: 20. studenog 2020.]
104. European Commission (2022). *Posted workers*. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?catId=471 [pristupljeno: 25. ožujka 2022.]

105. European Commission (2020$_d$). *PROGRESS axis of EaSI*. Employment, Social Affairs & Inclusion. EU Programme for Employment and Social Innovation (EaSI). Dostupno na: https://ec.europa.eu/social/main.jsp?catId=1082 [pristupljeno: 22. prosinca 2020.]
106. European Commission (2021$_m$). *Supporting entrepreneurs and the self-employed*. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?catId=952&langId=en [pristupljeno: 18. siječnja 2021.]
107. European Commission (2021$_n$). *Types of EU law*. Law-making process. Dostupno na: https://ec.europa.eu/info/law/law-making-process/types-eu-law_en [pristupljeno: 19. siječnja 2021.]
108. European Commission (2020$_e$). *What is the European Credit Transfer and Accumulation System?* Education and Training. Dostupno na: https://ec.europa.eu/education/resources-and-tools/european-credit-transfer-and-accumulation-system-ects_en [pristupljeno: 20. studenog 2020.]
109. European Commission (2021$_o$). *Women's situation in the labour market*. Labour market Participation. Dostupno na: https://ec.europa.eu/info/policies/justice-and-fundamental-rights/gender-equality/women-labour-market-work-life-balance/womens-situation-labour-market_en# [pristupljeno: 15. listopada 2021.]
110. European Commission (2021$_p$). *Youth employment support*. Employment, Social Affairs & Inclusion. Dostupno na: https://ec.europa.eu/social/main.jsp?catId=1036&langId=en [pristupljeno: 18. siječnja 2021.]
111. European Commision (2017$_c$). *Zaposlenost mladih*. Tematski informativni članak o europskom semestru. pp. 1-28. Dostupno na: https://ec.europa.eu/info/sites/info/files/file_import/european-semester_thematic-factsheet_youth_employment_hr.pdf [pristupljeno: 26. studenog 2020.]
112. European Commission (2017$_d$). *Žene na tržištu rada*. Tematski informativni članak o europskom semestru. pp. 1-18. Dostupno na: https://ec.europa.eu/info/sites/default/files/file_import/european-semester_thematic-factsheet_labour-force-participation-women_hr.pdf [pristupljeno: 15. listopada 2021.]
113. European Parliament (2021). *Lifelong Learning in the EU*. Dostupno na: https://www.europarl.europa.eu/thinktank/infographics/lifelonglearning/ [pristupljeno: 24. siječnja 2021.]

114. *European Social Fund* (2021). Dostupno na: https://ec.europa.eu/esf/main.jsp?catId=443&langId=en [pristupljeno: 16. veljače 2021.]
115. Europski fondovi (2021). *Europski socijalni fond*. Dostupno na: http://europski-fondovi.eu/program/europski-socijalni-fond [pristupljeno: 15. siječnja 2021.]
116. Europska komisija (2021_a). *Dugoročna strategija do 2050.* Dostupno na: https://ec.europa.eu/clima/policies/strategies/2050_hr [pristupljeno: 9. siječnja 2021.]
117. Europska komisija (2021_b). *EURES*. Život i rad. Dostupno na: https://ec.europa.eu/eures/main.jsp?acro=lw&lang=hr&catId=490&parentId=0 [pristupljeno: 10. siječnja 2021.]
118. Europska komisija (2021_c). *Europski socijalni fond*. Zapošljavanje, socijalna pitanja i uključenost. Dostupno na: https://ec.europa.eu/social/main.jsp?langId=hr&catId=325 [pristupljeno: 10. siječnja 2021.]
119. Europska komisija (2021_d). *Europski stup socijalnih prava i njegovih 20 načela*. Europski stup socijalnih prava. Dostupno na: https://ec.europa.eu/info/european-pillar-social-rights/european-pillar-social-rights-20-principles_hr [pristupljeno: 10. siječnja 2021.]
120. Europska komisija (2014). *Kohezijska politika 2014. – 2020*. Panorama. Zima 2014. BR. 48. Regionalna i urbana politika ISSN 2315-0823. Dostupno na: https://ec.europa.eu/regional_policy/sources/docgener/panorama/pdf/mag48/mag48_hr.pdf [pristupljeno: 2. prosinca 2020.]
121. Europska komisija (2017). *Pregled socijalnih pokazatelja*. Radni dokument službi Komisije. Bruxelles, 26.4.2017. Dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:52017SC0200&from=ro [pristupljeno: 10. siječnja 2021.]
122. Europska komisija (2021_e). *Provedba europskog stupa socijalnih prava*. Zapošljavanje, socijalna pitanja i uključenost. Dostupno na: https://ec.europa.eu/social/main.jsp?langId=hr&catId=1226 [pristupljeno: 10. siječnja 2021.]
123. Europska komisija (2020). *Zapošljavanje i tržište rada*. Regionalni i urbani razvoj EU-a. Regionalna politika. Dostupno na: https://ec.europa.eu/regional_policy/hr/policy/themes/employment/ [pristupljeno: 16. studenog 2020.]

124. Europska unija (2021). *Institucije EU-a i ostala tijela*. Dostupno na: https://europa.eu/european-union/about-eu/institutions-bodies_hr [pristupljeno: 9. siječnja 2021.]
125. Eurostat (2021_a). *Employed persons working on Sundays as a percentage of the total employment, by sex, age and professional status*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/LFSA_EWPSUN__custom_828456/default/table?lang=en [pristupljeno: 15. ožujka 2021.]
126. Eurostat (2020_a). *Employment and unemployment (LFS)*. Dostupno na: https://ec.europa.eu/eurostat/web/lfs/data/database [pristupljeno 20. studenog 2020.]
127. Eurostat (2020_b). *Employment rate*. Statistics Explained. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php/Glossary:Employment_rate [pristupljeno: 25. studenog 2020.]
128. Eurostat (2020_c). *Employment rate by age. % of total population.* Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/tepsr_wc110/default/table?lang=en [pristupljeno: 8. prosinca 2020.]
129. Eurostat (2020_d). *Employment rate by educational attainment level*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/tepsr_wc120/default/table?lang=en [pristupljeno: 25. studenog 2020.]
130. Eurostat (2021_b). *Immigration by age and sex*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/MIGR_IMM8__custom_840259/default/table?lang=en [pristupljeno: 15. ožujka 2021.]
131. Eurostat (2020_e). *Labour Market Areas*. Dostupno na: https://ec.europa.eu/eurostat/cros/content/labour-market-areas_en [pristupljeno: 16. studenog 2020.]
132. Eurostat (2018). *Labour market policy*. Dostupno na: https://ec.europa.eu/employment_social/employment_analysis/lmp/lmp_esms.htm [pristupljeno: 20. veljače 2021.]
133. Eurostat (2021_c). *Long-term unemployment (15-74 years) - percentage of active population*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/une_ltu_a/default/table?lang=en [pristupljeno: 25. veljače 2021.]
134. Eurostat (2020_f). *National accounts and GDP*. Statistics Explained. Dostupno na: https://ec.europa.eu/eurostat/statistics-

explained/index.php?title=National_accounts_and_GDP/hr [pristupljeno: 18. siječnja 2021.]

135. Eurostat (2021$_d$). *Part-time employment (20-64) as percentage of the total employment*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/LFSA_EPPGA__custom_825790/default/table?lang=en [pristupljeno: 15. ožujka 2021.]
136. Eurostat (2020$_g$). *Real GDP per capita*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/sdg_08_10/default/table?lang=en [pristupljeno: 31. kolovoza 2020.]
137. Eurostat (2021$_e$). *Self-employment by sex, age and educational attainment level*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/LFSA_ESGAED__custom_828471/default/table?lang=en [pristupljeno: 15. ožujka 2021.]
138. Eurostat (2021$_f$). *Social protection expenditure*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/SPR_EXP_SUM__custom_831559/default/table?lang=en [pristupljeno: 1. ožujka 2021.]
139. Eurostat (2021$_g$). *Temporary employees by sex, age and educational attainment level*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/LFSA_ETGAED__custom_828361/default/table?lang=en [pristupljeno: 15. ožujka 2021.]
140. Eurostat (2020$_h$). *Unemployment rate by age. %*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/tepsr_wc170/default/table?lang=en [pristupljeno: 8. prosinca 2020.]
141. Eurostat (2020$_i$). *Young people neither in employment nor in education and training (15-24 years) - % of the total population in the same age group*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/tipslm90/default/table?lang=en [pristupljeno: 25. studenog 2020]
142. Eurostat (2010). *Unemployment*. Statistics Explained. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php/Glossary:Unemployment [pristupljeno: 20. siječnja 2021.]
143. Eurostat (2020$_j$). *Zaposlenost – godišnja statistika*. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Employment_-_annual_statistics/hr&oldid=496986 [pristupljeno: 20. studenog 2020.]

144. Fadejeva, L. (2019). *Labour Market Reforms in the European Union: an Overview*. Dostupno na: https://www.macroeconomics.lv/labour-market-reforms-european-union-overview [pristupljeno: 28. studenog 2020.]

145. Fernández-Kranz, D., Paul, M., Rodríguez-Planas, N. (2015). Part-TimeWork, Fixed-Term Contracts, and the Returns to Experience. *Oxford Bulletin of Economics and Statistics*. 77, 4 (2015) 0305–9049. pp. 512-541.jezične doi: 10.1111/obes.12073.

146. Florida, R. (2002). *The rise of the creative class*. Basic Books, New York. ISBN-13: 9781541617742

147. Fries-Tersch, E., Tugran, T., Bradley, H. (2017). *2016 Annual Report on intra- EU Labour Mobility*. European Commission. 2nd edition May 2017. Directorate-General for Employment, Social Affairs and Inclusion. Directorate D — Labour mobility. Unit D1 — Free Movement of Workers, EURES. ISBN: 978-92-79-68953-6.

148. Fries-Tersch, E., Tugran, T., Markowska, A., Jones, M. (2019). *2018 Annual Report on intra EU Labour Mobility*. European Commission. Directorate-General for Employment Social Affairs and Inclusion. Directorate D - Labour mobility. Luxembourg: Publications Office of the European Union. ISBN: 978-92-79-99975-8.

149. Galik, A., Bąk, M., Bałandynowicz-Panfil, K., Cirella, G. T. (2022). *Evaluating Labour Market Flexibility Using the TOPSIS Method: Sustainable Industrial Relations*. Sustainability, 14, 526. https://doi.org/10.3390/su14010526

150. Gebel, M., Giesecke, J. (2016). Does Deregulation Help? The Impact of Employment Protection Reforms on Youths' Unemployment and Temporary Employment Risks in Europe. *European Sociological Review*. Volume 32, Issue 4, pp. 486–500. Dostupno na: https://doi.org/10.1093/esr/jcw022 [pristupljeno: 1. ožujka 2021.]

151. Giovanis, E. (2018). The relationship between flexible employment arrangements and workplace performance in Great Britain. *International Journal of Manpower*. Vol. 39 No. 1, pp. 51-70. Dostupno na: https://doi.org/10.1108/IJM-04-2016-0083[pristupljeno: 1. ožujka 2021.]

152. Giugni, M., Berclaz, M., Bonoli, G., Dwyer, P., Ellison, N., Faniel, J., Füglister, K., Furåker, B., Lahusen, C., Maeder, C., Nadai, E., Richards, A., Royall, F. (2009). *The Politics of Unemployment in Europe - Policy Responses and Collective Action*. Ashgate Publishing Limited. ISBN: 978 0 7546 7348 4

153. Glaude, M. (2007). *Statistics on discrimination within the context of social statistics*. Eurostat. Dostupno na: https://ec.europa.eu/eurostat/documents/1001617/4577877/0-4-KEYNOTE-EN.pdf [pristupljeno: 1. ožujka 2021.]

154. Goudswaard, A., de Nantieul, M. (2000). *Flexibility and Working Conditions*. European Foundation for the Improvement of Living and Working Conditions. Dublin
155. Gregg, P., Machin, S., Fernández-Salgado (2014). Real wages and unemployment in the big squeeze. *The Economic Journal*. 124. pp. 408–432. Doi: 10.1111/ecoj.12139©
156. Grekousis, G., Gialis, S. (2018). More Flexible Yet Less Developed? Spatio-Temporal Analysis of Labor Flexibilization and Gross Domestic Product in Crisis-Hit European Union Regions. Social Indicators Research. https://doi.org/10.1007/s11205-018-1994-0 [pristupljeno: 28. studenog 2020.]
157. Grgić, M., Bilas, V. (2008). *Međunarodna ekonomija*. Zagreb: GIPA d.o.o.
158. Habanabakize, T., Meyer, D. F., Oláh, J. (2019). *The Impact of Productivity, Investment and Real Wages on Employment Absorption Rate in South Africa*. Social Sciences. 8, 330. doi:10.3390/socsci8120330
159. Hafiz, Q., Nazir, Z., Abbas, N., Sana, I. (2014). Determinants of unemployment in Pakistan: a statistical study. *International Journal of Asian Social Science.* 4(12). pp. 1163–1175.
160. Harakal'ova, L., Lipkova, L., Gress, M. (2015). *Education policy of the European union and its reflection in the Strategy "Europe 2020"*. Actual Problems of Economics. Volume 170, Issue 8, pp. 318-326.
161. Hassan, M., Nassar, R. (2015). Effects of debt and GDP on the unemployment rate: An empirical study. *Journal of International Business Disciplines.* 10(2). pp. 52-69.
162. Hastings, T., Heyes, J. (2016). Farewell to flexicurity? Austerity and labour policies in the European Union. *Economic and Industrial Democracy*. 1-23. doi: 10.1177/0143831X16633756
163. Hatfield, I. (2015). *Self-employment in Europe*. Institute for Public Policy Research. IPPR. Dostupno na: http://www.ippr.org/publications/selfemployment-in-europe [pristupljeno: 25. siječnja 2021.]
164. Heinz, F. F., Ward-Warmedinger, M. (2006). *Cross-border labour mobility within an enlarged EU*. European Central Bank. Occasional paper series NO. 52 / OCTOBER 2006. ISSN 1607-1484. Dostupno na: https://www.ecb.europa.eu/pub/pdf/scpops/ecbocp52.pdf [pristupljeno: 28. studenog 2020.]
165. Hendrickx, F. (2019). *Regulating working conditions through EU directives – EU employment law outlook and challenges*. Policy Department for Economic, Scientific and Quality of Life Policies. Directorate-General for Internal Policies. European

Parliament. PE 638.430 - September 2019. Dostupno na: https://www.europarl.europa.eu/RegData/etudes/BRIE/2019/638430/IPOL_BRI(2019)638430_EN.pdf [pristupljeno: 20. ožujka 2021.]

166. Herwartz, H., Niebuhr, A. (2011). Growth, unemployment and labour market institutions: evidence from a cross-section of EU regions. *Applied Economics*. 43(30). 4663–4676. doi:10.1080/00036846.2010.493142
167. Heyes, J. (2015). Flexicurity, employment protection and the jobs crisis. *Work, employment and society*. 25(4) 642–657. doi: 10.1177/0950017011419723.
168. Holmes, M. J., Silverstone, B. (2006). Okun's law, asymmetries and jobless recoveries in the United States: a Markov-switching approach. *Economics Letters*. vol. 92, issue 2. pp. 293-299.
169. Hölscher, J., Perugini, C., Pompei, F. (2011). *Wage inequality, labour market flexibility and duality in Eastern and Western Europe*. Post-Communist Economies. 23:3, 271-310. doi: 10.1080/14631377.2011.595119.
170. Huneault, L., Mathieu, M.-È., Tremblay, A. (2011). *Globalization and modernization: an obesogenic combination*. Obesity Reviews, 12(5), e64–e72. doi:10.1111/j.1467-789x.2010.00817.x
171. Jacobson, T., Vredin, A., Warne, A. (1998). *Are real wages and unemployment related?*. Economica. 65. pp. 69-96.
172. Jadamus-Hacura, M., Melich-Iwanek, K. (2015). *Elastyczno´s´c współczesnych rynków pracy*. Stud. Ekon. 220, 36–57.
173. Janavičiūtė, L., Telešienė, A., Barynienė, J. (2017). *Migration of Highly Qualified Workers and Policies to Ensure Labour Market Sustainability in the European Union in 2013-2014*. PUBLIC POLICY AND ADMINISTRATION 2017, T. 16, Nr. 3/ 2017, Vol. 16, No 3, p. 502-519. ISSN 1648–2603.
174. Jardin, M., Gaétan, S. (2012). *How Okun's Law Is Non-linear in Europe: a Semi-parametric Approach*. University of Rennes, Rennes.
175. Jarvis, P. (2003). *Poučavanje*. Teorija i praksa. Zagreb: Andragoški centar.
176. Jesus, M. (2012). *Unemployment and Economic Growth in Peru: 2001-2012*. Economics.
177. Jez, R. (2015). Education vs economically active and inactive individuals on the labor market in European countries. *Economy and Sociology*. Vol. 2015 No. 2. pp. 19-23.
178. Jovančević, R. (2005). *Ekonomski učinci globalizacije i Europska unija*. Zagreb: Mekron promet d.o.o.

179. Južnik Rotar, L., Krsnik, S. (2020). *Analysing the relationship between unemployment benefits and unemployment duration*. Society and Economy. doi: 10.1556/204.2020.00009.
180. Kahanec, M. (2013). *Labor Mobility in an Enlarged European Union*. In: Zimmermann, K. F., Constant, A., editors. International Handbook on the Economics of Migration. Cheltenham: Edward Elgar. IZA DP No. 6485
181. Kenton, W. (2019). *Labor Market Flexibility*. Business – Business Essentials. Dostupno na: https://www.investopedia.com/terms/l/labor-market-flexibility.asp [pristupljeno: 4. ožujka 2021.]
182. Kersan-Škabić, I. (2015). *Ekonomija Europske unije*. II. izdanje. Pula: Sveučilište Jurja Dobrile, Fakultet za ekonomiju i turizam „Dr. Mijo Mirković".
183. Keynes, J. M. (1939). Relative movements of real wages and output. *Economic Journal*. 49. Reprinted as Appendix 3, to The general theory (1973). pp. 394-412.
184. Kim, S. S. (2000). *Korea's globalization*. Cambridge University Press. ISBN 0-521-77559-0
185. Kivimäki, M., Leino-Arjas, P., Kaila-Kangas, L., Luukkonen, R., Vahtera, J., Elovainio, M., Härmä, M., Kirjonen, J. (2006). *Is incomplete recovery from work a risk marker of cardiovascular death? Prospective evidence from industrial employees*. Psychosom. Med. 68. pp. 402–407. doi.org/10.3109/07420528.2011.565896
186. Klau, F., Mittelstadt, A. (1986). *Labour market flexibility*. OECD journal: economic studies. - Paris: OECD, ISSN 1995-2848, ZDB-ID 858174-5. - Vol. 6.1986, pp. 7-45.
187. Klein, N. (2012). *Real Wage, Labor Productivity, and Employment Trends in South Africa: A Closer Look*. Washington: International Monetary Fund.
188. Kónya, L. (2019). *Did the unemployment rates converge in the EU?*. Empirical Economics. doi: 10.1007/s00181-019-01678-5.
189. Koutroulis, A., Panagopoulos, Y., Tsouma, E. (2016). Asymmetry in the response of unemployment to output changes in Greece: evidence from hidden co-integration. *The Journal of Economic Asymmetries, Elsevier*. vol. 13(C). pp. 81-88.
190. Kulušić, J. (2009). *Isplati li se fleksibilnost*. Hrvatsko tržište rada. Zagreb: TIM press d.o.o.
191. Laleta, S., Bodiroga-Vukobrat, N. (2016). *Fleksigurnost i (de)regulacija tržišta rada*. Zbornik Pravnog fakulteta Sveučilišta Rijeka (1991) v. 37, br. 1, str. 33-69. Rijeka.
192. Lavoie, M. (2003). *Real Wages and Unemployment with Effective and Notional Demand for Labor*. Review of Radical Political Economics. pp. 166-182.

193. Lazear, E. P. (2006). *Productivity and wages*. Business Economics. Palgrave Macmillan; National Association for Business Economics. Vol. 41(4). pp. 39-45.
194. Lipková, Ľ. (2011). *Európska únia*. Bratislava: Sprint dva. 448 s. ISBN 9788089393336.
195. Lowther, J. (2003). *Fleksibilnost radne snage i uloga hrvatskih socijalnih partnera u njezinu povećanju*. Financijska teorija i praksa. 27 (4) str. 457-479
196. Maletić, I., Galinec, D., Japunčić, T., Župan, S. (2019). Pet godina Republike Hrvatske u europskom semestru. Ured zastupnice u Europskom parlamentu Ivane Maletić. ISBN: 978-953-48504-0-4. Zagreb: Sveučilišna tiskara d.o.o.
197. Mankiw, N. G. (2006). *Osnove ekonomije*. Treće izdanje. Zagreb: Mate d.o.o.
198. Mankiw, N. G., Romer, D., Weil, D. N. (1992). *A Contribution to the Empirics of Economic Growth*. The Quarterly Journal of Economics, 107, No. 2, pp. 407 – 437.
199. Marconi, G., Beblavý, M., Maselli, I. (2015). Age effects in Okun's law with different indicators of unemployment. *Applied Economics Letters*. 23(8). 580–583. doi: 10.1080/13504851.2015.1090540
200. Martin, J. P. (2015). Activation and active labour market policies in OECD countries: Stylised facts and evidence on their effectiveness. *IZA Journal of Labor Policy*. ISSN 2193-9004. Springer, Heidelberg. Vol. 4, pp. 1-29. doi: 10.1186/s40173-015-0032-y.
201. Martin, J. P. (2000). *What works among active labour market policies: evidence from OECD countries' experiences*. OECD Economic Studies No. 30, 2000/I. pp. 79-113. Dostupno na: https://www.oecd.org/economy/growth/2732343.pdf [pristupljeno: 20. veljače 2021.]
202. Marzocchi, O. (2020). *Slobodno kretanje osoba*. Europski parlament. Dostupno na: https://www.europarl.europa.eu/factsheets/hr/sheet/147/slobodno-kretanje-osoba [pristupljeno: 16. studenog 2020.]
203. Maslauskaite, K. (2014). Posted workers in the EU: State of play and regulatory evolution. Associate research fellow with Notre Europe – Jacques Delors Institute.
204. Mayes, D. G., Viren, M. (2002). Asymmetry and the problem of aggregation in the Euroarea. *Empirica*. 29 (1). pp. 47–73.
205. McConell, C. R., Brue, L. S. (1994). *Suvremena ekonomija rada*. Zagreb: MATE d.o.o.
206. McCormick, J. (2010). *Razumjeti Europsku uniju*. Zagreb: Mate d.o.o.
207. Meager, N., Speckesser, S. (2011). *Wages, Productivity and Employment: A review of Theory and International Data*. European Employment Observatory. pp. 1–73.

208. Michaud, M. L. (2004). *Welfare and the labour market in the EU*. European Network of Economic Policy Research Institutes. Occasional paper NO. 7. ISBN 92-9079-515-8
209. Mikić, M., Orsag, S., Pološki Vokić, N., Švaljek, S., Sunajko, G., Bogutovac, A., Crljenko, I., Čepo, D., Lončarić, S. (2011). *Ekonomski leksikon*. II. izdanje. Zagreb: Leksikografski zavod Miroslav Krleža i Masmedia Zagreb.
210. Mills, M. (2004). Demand for flexibility or generation of insecurity? The individualization of risk, irregular work shifts and Canadian youth. *Journal of Youth Studies*. Volume 7, 2004 - Issue 2. Dostupno na: https://doi.org/10.1080/1367626042000238677 [pristupljeno: 26. veljače 2021.]
211. Mintas Hodak, Lj., Bušić, Z., Horak, H., Leppee, M., Liszt, M., Mikuš, N., Mlikotin Tomić, D., Obradović, T., Petrović, S., Plenković, A., Prusina, I., Šonje, V., Vlašić Feketija, M., Vukorepa, I., Žigman, A. (2004). *Uvod u Europsku uniju*. Zagreb: Mate d.o.o.
212. Mintas Hodak, Lj., Cerovac, M., Faulend, M., Majić, H., Mataija, M., Mijatović, N., Ondelj, I., Sokol, T., Šimac, S., Škreb, M., Šošić, V., Vidović, B., Mikuš Žigman, N. (2010). *Europska unija*. Zagreb: Mate d.o.o.
213. Mosikari, T. J. (2013). The Effect of Unemployment Rate on Gross Domestic Product: Case of South Africa. *Mediterranean Journal of Social Sciences*. vol. 4. no. 6. doi:10.5901/mjss.2013.v4n6p429
214. Nebot, C., Beyaert, A., García-Solanes, J. (2019). New insights into the nonlinearity of Okun's law. Economic Modelling 82. pp. 202–210
215. Noe, R. A., Hollenbeck, J. R., Gerhart, B., Wright, P. M. (2006). *Menadžment ljudskih potencijala*. Postizanje konkurentske prednosti. Treće izdanje. Zagreb: MATE d.o.o.
216. Noor, Z. M., Nor, N. M., Ghani, J. A. (2007). The Relationship between Output and Unemployment in Malaysia: Does Okun's Law exist? *Int. Journal of Economics and Management*. 1 (3). pp. 337-344.
217. OECD (2021_a). *Active Labour Market Policies: Connecting People with Jobs*. Dostupno na: https://www.oecd.org/employment/activation.htm [pristupljeno: 20. veljače 2021.]
218. OECD (2016). *Be Flexible! Background brief on how workplace flexibility can help European employees to balance work and family*. Directorate for Employment, Labour and Social Affairs. Social Policy Division.

219. OECD (2020_a). *Employment rate by age group*. Dostupno na: https://data.oecd.org/emp/employment-rate-by-age-group.htm [pristupljeno: 31. kolovoza 2020.]
220. OECD (2022). *Hours worked*. OECD Data. Dostupno na: https://data.oecd.org/emp/hours-worked.htm [pristupljeno: 26. travnja 2022.]
221. OECD (2012). How does education affect employment rates? *Education at a Glance 2012: Highlights* OECD Publishing, Paris. doi: https://doi.org/10.1787/eag_highlights-2012-11-en
222. OECD (2021_b). *Long-term unemployment rate (indicator)*. doi: 10.1787/76471ad5-en Dostupno na: https://data.oecd.org/unemp/long-term-unemployment-rate.htm [pristupljeno: 22. veljače 2021.]
223. OECD.Stat (2021_c). *Public expenditure and participant stocks on LMP*. Dostupno na: https://stats.oecd.org/Index.aspx?DataSetCode=LMPEXP [pristupljeno: 22. veljače 2021.]
224. OECD (2003). *Unemployed – ILO*. Dostupno na: https://stats.oecd.org/glossary/detail.asp?ID=2791, [pristupljeno: 25. veljače 2021.]
225. OECD (2020_b). *Youth not in employment, education or training (NEET)*. Dostupno na: https://data.oecd.org/youthinac/youth-not-in-employment-education-or-training-neet.htm [pristupljeno: 25. studenog 2020.]
226. Official Journal of the European Union (2003). *DIRECTIVE 2003/88/EC OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL of 4 November 2003 concerning certain aspects of the organisation of working time*. Dostupno na: https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32003L0088&from=EN [pristupljeno: 24. siječnja 2021.]
227. Official Journal of the European Union (2019). *DIRECTIVE (EU) 2019/1152 OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL of 20 June 2019 on transparent and predictable working conditions in the European Union*. Dostupno na: https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32019L1152&from=EN [pristupljeno: 24. siječnja 2021.]
228. Okun, A. M. (1962). Potential GNP: Its Measurement and Significance. Proceedings, Business and Economic Statistics Section of the American Statistical Association, pp. 89–104.

229. Oliskevych, M., Lukianenko, I. (2019). Labor force participation in Eastern European countries: nonlinear modeling. *Journal of Economic Studies*. Vol. 46 No. 6. pp. 1258-1279. doi: 10.1108/JES-07-2018-0235
230. O'Sullivan, M., Lavelle, J., Turner, T., McMahon, J., Murphy, C., Ryan, L., Gunnigle, P. (2021). Employer-led flexibility, working time uncertainty, and trade union responses: The case of academics, teachers and school secretaries in Ireland. *Journal of Industrial Relations*. Volume 63, Issue 1, pp. 49-72. doi: 10.1177/0022185620960198
231. Otoiu, A. (2017). Is the policy-induced Romanian demographic boom affecting the labor market?. *Revista Economica*. Vol. 69 No. 5. pp. 96-106.
232. Owyang, M. T., Sekhposyan, T. (2012). *Okun's Law over the Business Cycle: Was the Great Recession All that Different?*. Federal Reserve Bank of St. Louis Review. vol. 94.
233. Oxoby, R. (2009.) Understanding social inclusion, social cohesion, and social capital. *International Journal of Social Economics*. Vol. 36 No. 12, pp. 1133-1152. doi: 10.1108/03068290910996963.
234. Ozawa, M. N. (2013). *Income Security*. Encyklopedia of social work. National association od social workers press and Oxford University press. Dostupno na: https://doi.org/10.1093/acrefore/9780199975839.013.196 [pristupljeno: 25. siječnja 2021.]
235. Parent-Thirion, A., Fernández-Macías, E., Hurley, J., Vermeylen, G. (2007). *Fourth European Working Conditions Survey*. ISBN 92-897-0974-X. European Foundation for the Improvement of Living and Working Conditions. Dublin.
236. Penava, M. (2011). Utjecaj migracija na Europsko tržište rada. *EKONOMSKA MISAO I PRAKSA DBK*. GOD XX. (2011.) BR. 2. (335-362)
237. Peraro, C. (2017). *The enforcement of posted workers' rights across the European Union*. Freedom, Security & Justice: European Legal Studies. n. 2, pp. 114-130. ISSN 2532-2079
238. Potočnjak, Ž. (2012). *Fleksigurnost u okviru pravne stečevine Europske unije – ograničenja i mogućnosti*. Fleksibilnost i fleksigurnost. Zagreb: Rosip d.o.o.
239. Požega, Ž. (2012). *Menadžment ljudskih resursa – Upravljanje ljudima i znanjem u poduzeću*. Osijek: Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku.
240. Prachowny, M. F. (1993). *Okun's law: Theoretical foundations and revised estimates*. The Review of Economics and Statistics. 75. pp. 331–336.
241. Prpić, K. (ur.) (2005). *Elite znanja u društvu (ne)znanja*. Zagreb: Institut za društvena istraživanja u Zagrebu.

242. Puljiz, V., Bežovan, G., Šućur, Z., Zrinščak, S. (2005). *Socijalna politika: definicije i područja*. Zagreb: Sveučilište u Zagrebu. Pravni fakultet Zagreb. Sveučilišna tiskara d.o.o.

243. Ringold, D., Kasek, L. (2007). *Social Assistance in the New EU Member States - Strengthening Performance and Labor Market Incentives*. World Bank Working paper NO. 117., The International Bank for Reconstruction and Development/The World Bank. ISBN-13: 978-0-8213-7159-6. doi: 10.1596/978-0-8213-7159-6.

244. Rodgers, G. (2007). Labour Market Flexibility and Decent Work. *Economic & Social Affairs*. DESA Working Paper No. 47. 1-9.

245. Sahlberg, P. (2012). *Lekcije iz Finske*. Što svijet može naučiti iz obrazovne promjene u Finskoj. Zagreb: Školska knjiga d.d.

246. Sahnoun, M., Abdennadher, C. (2019). Labor Market Institutions and Performance Economic Within Trial Labor Market Models: Flexibility, Rigidity, and Flexicurity. *The Review of Black Political Economy*. Vol. 46 Issue 2. 99–129 doi: 10.1177/0034644619850179

247. Samuelson, P. A., Nordhaus, W. D. (2011). *Ekonomija*. 19. izdanje. Zagreb: Mate d.o.o.

248. Sawyer, M. (2002). The NAIRU, aggregate demand and investment. *Metroeconomica*. Vol. 53. pp. 66–94. doi: 10.1111/1467-999X.00137

249. Seyfried, W. (2004). *Examining the relationship between employment and economic growth in ten largest states*. Southwestern Economic Review. pp. 1-12.

250. Schmid, G. (2010). *The Future of Employment Relations: Goodbye 'Flexicurity' – Welcome Back Transitional Labour Markets?*. AIAS Working Paper 10-106, University of Amsterdam, Amsterdam.

251. Schmid, G. & Schommann, K. (2003). The Concept of Transitional Labour Markets and Some Policy Conclusions: The State of the Art. TLM.NET Working Paper No. 2003-01. ISSN: 15.72.3380-001. *Wissenschaftszentrum Berlin fur Sozialforschung (Social Science Research Center Berlin) (WZB)*. Berlin, Germany

252. Sellin, B. (2002). *Scenarios and strategies for vocational education and lifelong learning in Europe*. Summary of findings and conclusions of the joint Cedefop/ETF project (1998 - 2002). Cedefop Panorama series; 40. Luxembourg: Office for Official Publications of the European Communities.

253. Silvapulle, P., Moosa, I. A., Silvapulle, M. J. (2004). Asymmetry in Okun's law. *Canadian Journal of Economics/Revue canadienne d'économique*. 37 (2). pp. 353–374.

254. Službeni list Europske unije (2013). *UREDBA (EU) br. 1296/2013 EUROPSKOG PARLAMENTA I VIJEĆA*. Dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32013R1296&qid=1614688977808&from=EN [pristupljeno: 24. siječnja 2021.]
255. Solow, R. M. (1956). *A Contribution to Theory of Economic Growth*. The Quarterly Journal of Economics, 70, No. 1, pp. 65 – 94.
256. Soylu, Ö. B., Çakmak, I., Okur, F. (2018). Economic growth and unemployment issue: Panel data analysis in Eastern European Countries. *Journal of International Studies*. 11(1). pp. 93-107. doi:10.14254/2071-8330.2018/11-1/7
257. Strahinja, D. (2007). *Međunarodna ekonomija*. Teorija i politika. Rijeka: Sveučilište u Rijeci. Ekonomski fakultet Sveučilišta u Rijeci. Futura d.o.o.
258. Stubbs, P., Zrinšćak, S. (2005). *Proširena socijalna Europa?*. Socijalna politika, socijalna uključenost i socijalni dijalog u Hrvatskoj i Europskoj uniji. Zagreb: Institut za javne financije. Zaklada Friedrich Ebert, str. 157 – 180.
259. Szpejna, M., Boudalaoui-Buresi, Z. (2020). *The scope of EU labour law*. European Parliament. Dostupno na: https://www.europarl.europa.eu/RegData/etudes/IDAN/2020/658181/IPOL_IDA(2020)658181_EN.pdf [pristupljeno: 28. siječnja 2021.]
260. Šribar, P. (2005). *Rad kod kuće ili na drugom izdvojenom mjestu rada*. Zagreb: Poslovni savjetnik, br. 7-8/2005.
261. Šundalić, A. (2012). *Između društva rada i društva znanja*. Media, culture and public relations. Vol. 3 No. 2. str. 120-130.
262. Tadin, H. (2012). *Europska unija - unutarnje tržište i porezi*. Zagreb: HITA d.o.o.
263. Tang, B., Bethencourt, C. (2017). *Asymmetric unemployment-output tradeoff in the Eurozone*. MPRA Paper No. 66043. J. Pol. Model. 39 (3). pp. 461–481.
264. Tavares, F., Santos, E., Diogo, A., Ratten, V. (2021). Teleworking in Portuguese communities during the COVID-19 pandemic. *Journal of Enterprising Communities: People and Places in the Global Economy*. Vol. 15 No. 3, pp. 334-349. Dostupno na: https://doi.org/10.1108/JEC-06-2020-0113 [pristupljeno: 28. siječnja 2021.]
265. The Danish Government (2019). *Denmark's National Reform Programme 2019*. Ministry for Economic Affairs and the Interior. Dostupno na: https://ec.europa.eu/info/sites/info/files/2019-european-semester-national-reform-programme-denmark-en.pdf [pristupljeno: 12. ožujka 2021.]

266. Tintić, N. (1972). *Radno i socijalno pravo*, Knjiga prva: Radni odnosi (II), Zagreb: Narodne novine.
267. Torres, R. (2001). *An Analysis of the Social Pilars of Globalization*. Geneva: International Labour Office
268. Učur, M. (2000). *Socijalno pravo*. Zagreb: Pravni fakultet Sveučilišta u Rijeci i Informator.
269. Učur, M. (2005). *Ugovor o radu za obavljanje poslova kod kuće radnika*. Zagreb: Radno pravo, br. 7/2005
270. UNESCO (2019). *Right to education*. Dostupno na: https://en.unesco.org/themes/right-to-education [pristupljeno: 24. siječnja 2021.]
271. Urban, S. M. L ., Velo, D. (2006). Labour Market Flexibility: Need and Outcome. Some Socio-economic Reflections based on the European Experience. European Review, Vol. 14, No. 4, 587–607.
272. Valadkhani, A., Smyth, R. (2015). Switching and asymmetric behaviour of the Okun coefficient in the US: evidence for the 1948–2015 period. *Economic Modelling*, *Elsevier*. vol. 50(C). pp. 281–290.
273. van den Hee, S. M., van Hooft, E. A. J., van Vianen, A. E. M. (2020). A temporal perspective of job search: The relation between personality attributes, motivation, job search behavior, and outcomes. *Journal of Vocational Behavior*. Volume 122, October 2020, 103489. Dostupno na: https://doi.org/10.1016/j.jvb.2020.103489 [pristupljeno: 25. siječnja 2021.]
274. van Vuuren, D. (2013). FLEXIBLE RETIREMENT. *Journal of Economic Surveys*. 28(3), pp. 573–593. doi:10.1111/joes.12042
275. Voudouris, I. (2004). The use of flexible employment arrangements: some new evidence from Greek firms. *The International Journal of Human Resource Management*. Volume 15, 2004 - Issue 1. pp. 131-146. Dostupno na: https://doi.org/10.1080/0958519032000157384 [pristupljeno: 26. siječnja 2021.]
276. Vukorepa, I. (2018). *Migracije i pravo na rad u Europskoj uniji*. Zbornik PFZ, 68, (1), str. 85 - 120.
277. Walker, A., Wigfield, A. (2004). *The social inclusion component of social quality*. European Network on Indicators of Social Quality (ENIQ) & European Foundation on Social Quality. Dostupno na: https://www.socialquality.org/wp-content/uploads/import/2014/10/Social-Inclusion-febr-2004.pdf [pristupljeno: 23. studenog 2020.]

278. Wang, W., Heyes, J. (2017). Flexibility, labour retention and productivity in the EU. *The International Journal of Human Resource Management*. doi: 10.1080/09585192.2016.1277370. Dostupno na: http://dx.doi.org/10.1080/09585192.2016.1277370 [pristupljeno: 20. ožujka 2021.]

279. Westerheide, N., Kauermann, G. (2012). Flexible Modelling of Duration of Unemployment Using Functional Hazard Models and Penalized Splines: A Case Study Comparing Germany and the UK. *Studies in Nonlinear Dynamics & Econometrics*. Volume 16, Issue 1. Article 5. doi: 10.1515/1558-3708.1914

280. Wirtz, A., Nachreiner, F., Rolfes, K. (2011). *Working on Sundays–Effects on Safety, Health, and Work-life Balance*. Chronobiology International, 28(4), pp. 361–370. doi:10.3109/07420528.2011.565896

281. Wojčák, E., Baráth, M. (2017_a). Differences of Application Part-time in EU Countries, Pros and Cons. *Management and Economics in Manufacturing*. (Proceedings of scientific papers) Zvolen: Technická univerzita vo Zvolene. ISBN 978-80-228-2993-9. pp. 74-81

282. Wojčák, E., Baráth, M. (2017_b). National Culture and Application of Telework in Europe. *European Journal of Business Science and Technology*. Vol. 3 Issue (1) pp. 65–74. ISSN 2336-6494. doi: http://dx.doi.org/10.11118/ejobsat.v3i1.79

283. Zelenika, R., Sundać, D., Pupavac, D. (2002). *Intelektualni kapital – kreator inkluzivnog svjetskog gospodarstva*, Znanje – temeljni ekonomski resurs, Rijeka: Sveučilište u Rijeci, Ekonomski fakultet Rijeka.

284. Zimmermann, K. F. (2009). *Labor Mobility and the Integration of European Labor Markets*. Institute for the Study of Labor. Discussion Paper No. 3999, pp. 1 - 22.

285. Zweig, M. (2015). Complicating the labor market as a social institution. *Review of Radical Political Economics*. Vol. 47 No. 4. pp. 572-578.

POPIS TABLICA

Tablica 1. Analitički prikaz prethodnih istraživanja povezanih s predmetnom problematikom u disertaciji……..……..14
Tablica 2. Ukupan broj zaposlenih u Europskoj uniji, broj zaposlenih žena te stopa zaposlenosti od 2008. do 2018. (stanovništvo u dobi od 20 do 64 godine)..... 34
Tablica 3. Inicijative Europske unije koje ističu ključnu ulogu obrazovanja, mladih i kulture u izgradnji europskog obrazovnog prostora 38
Tablica 4. Broj imigranata u zemljama članicama Europske unije u razdoblju od 2008. do 2018. godine..... 48
Tablica 5. Europski stup socijalnih prava i njegovih 20 načela..... 53
Tablica 6. Proračun ESF-a izražen u eurima po zemljama EU-a od 2014. godine do 2020. godine..... 58
Tablica 7. Sistematizirani pregled novih oblika rada u digitalnoj ekonomiji EU-a..... 63
Tablica 8. BDP po stanovniku od 2008. do 2018. godine po državama članicama EU-a……67
Tablica 9. Stopa zaposlenosti osoba s niskim stupnjem obrazovanja (20 - 64 godine) u zemljama EU-a od 2008. do 2018. godine..... 85
Tablica 10. Stopa zaposlenosti osoba s srednjim stupnjem obrazovanja (20 - 64 godine) u zemljama EU od 2008. do 2018. godine..... 87
Tablica 11. Stopa zaposlenosti osoba s visokim stupnjem obrazovanja (20 - 64 godine) u zemljama EU od 2008. do 2018. godine..... 88
Tablica 12. Mlade osobe od 15. do 24. godine koje nisu zaposlene niti su u obrazovnom procesu ili osposobljavanju, na razini EU-27 od 2008. do 2018. godine 94
Tablica 13. Dugotrajna nezaposlenost prema spolu kao postotak aktivnog stanovništva na razini Europske unije u razdoblju od 2008. do 2018. godine 105
Tablica 14. Ukupni izdaci za socijalnu zaštitu na razini EU-a u razdoblju od 2008. do 2018. godine..... 112
Tablica 15. Samozaposlene osobe na razini Europske unije u razdoblju od 2008. do 2018. godine..... 125
Tablica 16. Privremeno zaposlene osobe na razini Europske unije u razdoblju od 2008. do 2018. godine..... 129

Tablica 17. Zaposlenost s nepunim radnim vremenom kao postotak od ukupne zaposlenosti na razini Europske unije u razdoblju od 2008. do 2018. godine 134
Tablica 18. Zaposlene osobe koje rade nedjeljom kao postotak od ukupne zaposlenosti na razini Europske unije u razdoblju od 2008. do 2018. godine 137
Tablica 19. Popis varijabli – detaljna kodifikacija 149
Tablica 20. BDP po stanovniku prikazan prema državama i godinama 151
Tablica 21. Stopa zaposlenosti u EU-u od 2008. do 2018. godine 153
Tablica 22. Stopa nezaposlenosti u zemljama EU-a od 2008. do 2018. godine 154
Tablica 23. Opis varijabli analiziranih u hipotezi H2. 155
Tablica 24. Opis varijabli analiziranih u hipotezi $H3_1$ 156
Tablica 25. Opis varijabli analiziranih u hipotezi $H3_2$ 157
Tablica 26. Ukupan broj ispitanika u uzorku prema razredima, odnosno starosnim grupama i državama EU 158
Tablica 27. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Austriju 160
Tablica 28. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Belgiju 161
Tablica 29. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Bugarsku 162
Tablica 30. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Cipar 163
Tablica 31. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Češku 164
Tablica 32. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Dansku 165
Tablica 33. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Estoniju 166

Tablica 34. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Finsku 167
Tablica 35. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Francusku 168
Tablica 36. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Grčku 168
Tablica 37. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Hrvatsku 169
Tablica 38. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Irsku 170
Tablica 39. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Italiju 171
Tablica 40. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Latviju 172
Tablica 41. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Litvu 173
Tablica 42. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Luksemburg……174
Tablica 43. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Mađarsku 175
Tablica 44. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Maltu 176

Tablica 45. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Nizozemsku 177
Tablica 46. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Njemačku 177
Tablica 47. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Poljsku 178
Tablica 48. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Portugal 179
Tablica 49. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Rumunjsku 180
Tablica 50. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Slovačku 181
Tablica 51. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Sloveniju 182
Tablica 52. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Španjolsku 183
Tablica 53. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Švedsku 184
Tablica 54. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za Ujedinjeno Kraljevstvo 185
Tablica 55. Ukupni rezultati empirijskog istraživanja po državama i hipotezi H1..... 186
Tablica 56. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Austriju 187

Tablica 57. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Belgiju 189
Tablica 58. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Bugarsku 190
Tablica 59. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Cipar 191
Tablica 60. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Češku 192
Tablica 61. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Dansku 193
Tablica 62. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Estoniju 194
Tablica 63. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Finsku 196
Tablica 64. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Francusku 197
Tablica 65. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Grčku 198
Tablica 66. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Hrvatsku 199
Tablica 67. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Irsku 200

Tablica 68. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Italiju 201
Tablica 69. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Latviju 203
Tablica 70. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Litvu 204
Tablica 71. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Luksemburg 205
Tablica 72. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Mađarsku 206
Tablica 73. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Maltu 207
Tablica 74. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Nizozemsku 209
Tablica 75. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Njemačku 210
Tablica 76. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Poljsku 211
Tablica 77. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Portugal 212
Tablica 78. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Rumunjsku 213

Tablica 79. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Slovačku 215
Tablica 80. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Sloveniju 216
Tablica 81. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Španjolsku..... 217
Tablica 82. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Švedsku..... 218
Tablica 83. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za Ujedinjeno Kraljevstvo 219
Tablica 84. Ukupni rezultati empirijskog istraživanja po državama i hipotezi H1.1.….220
Tablica 85. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Austriju..... 222
Tablica 86. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Belgiju 223
Tablica 87. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Bugarsku 223
Tablica 88. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Cipar 224
Tablica 89. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Češku..... 225
Tablica 90. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Dansku..... 226

Tablica 91. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Estoniju 227
Tablica 92. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Finsku 228
Tablica 93. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Francusku 228
Tablica 94. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Grčku 229
Tablica 95. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Hrvatsku 230
Tablica 96. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Irsku..... 231
Tablica 97. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Italiju 232
Tablica 98. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Latviju 233
Tablica 99. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Litvu 233
Tablica 100. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Luksemburg..... 234
Tablica 101. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Mađarsku..... 235

Tablica 102. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Maltu 236
Tablica 103. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Nizozemsku 236
Tablica 104. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Njemačku 237
Tablica 105. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Poljsku 238
Tablica 106. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Portugal 239
Tablica 107. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Rumunjsku 240
Tablica 108. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Slovačku 240
Tablica 109. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Sloveniju 241
Tablica 110. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Španjolsku 242
Tablica 111. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Švedsku 243
Tablica 112. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za Ujedinjeno Kraljevstvo 244
Tablica 113. Ukupni rezultati empirijskog istraživanja po državama i hipotezi H1.2. 244

Tablica 114. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Austriju 246
Tablica 115. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Belgiju 247
Tablica 116. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Bugarsku 249
Tablica 117. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Cipar 251
Tablica 118. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Češku 252
Tablica 119. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Dansku 254
Tablica 120. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Estoniju 255
Tablica 121. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Finsku 257
Tablica 122. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Francusku 258
Tablica 123. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Grčku 260
Tablica 124. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Hrvatsku 261
Tablica 125. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Irsku 263
Tablica 126. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Italiju 265
Tablica 127. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Latviju 266
Tablica 128. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Litvu 268
Tablica 129. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Luksemburg 269
Tablica 130. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Mađarsku 271

Tablica 131. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Maltu 272
Tablica 132. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Nizozemsku 274
Tablica 133. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Njemačku..... 275
Tablica 134. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Poljsku 277
Tablica 135. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Portugal 278
Tablica 136. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Rumunjsku..... 280
Tablica 137. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Slovačku 282
Tablica 138. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Sloveniju..... 283
Tablica 139. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Španjolsku 285
Tablica 140. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Švedsku 286
Tablica 141. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za Ujedinjeno Kraljevstvo..... 288
Tablica 142. Ukupni rezultati empirijskog istraživanja po državama i hipotezi H2. .. 289
Tablica 143. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Austriju 290
Tablica 144. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Belgiju..... 291
Tablica 145. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Bugarsku 291
Tablica 146. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Cipar..... 292
Tablica 147. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Češku 293

Tablica 148. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Dansku 293
Tablica 149. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Estoniju……...294
Tablica 150. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Finsku..... 294
Tablica 151. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Francusku..... 295
Tablica 152. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Grčku 296
Tablica 153. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Hrvatsku..... 296
Tablica 154. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Irsku 297
Tablica 155. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Italiju..... 298
Tablica 156. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Latviju..... 298
Tablica 157. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Litvu..... 299
Tablica 158. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Luksemburg 300
Tablica 159. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Mađarsku 300
Tablica 160. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Maltu..... 301
Tablica 161. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Nizozemsku 301
Tablica 162. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Njemačku..... 302
Tablica 163. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Poljsku 303
Tablica 164. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Portugal..... 303

Tablica 165. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Rumunjsku 304
Tablica 166. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Slovačku..... 305
Tablica 167. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Sloveniju 305
Tablica 168. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Španjolsku..... 306
Tablica 169. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Švedsku 307
Tablica 170. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za Ujedinjeno Kraljevstvo 307
Tablica 171. Ukupni rezultati empirijskog istraživanja po državama i hipotezi $H3_1$ .. 308
Tablica 172. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Austriju ... 309
Tablica 173. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Belgiju..... 310
Tablica 174. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Bugarsku . 310
Tablica 175. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Cipar..... 311
Tablica 176. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Češku..... 312
Tablica 177. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Dansku 312
Tablica 178. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Estoniju ... 313
Tablica 179. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Finsku..... 314
Tablica 180. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Francusku 315
Tablica 181. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Grčku 315

Tablica 182. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Hrvatsku.. 316
Tablica 183. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Irsku 317
Tablica 184. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Italiju..... 317
Tablica 185. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Latviju..... 318
Tablica 186. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Litvu..... 319
Tablica 187. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Luksemburg……320
Tablica 188. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Mađarsku 320
Tablica 189. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Maltu…….321
Tablica 190. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Nizozemsku……322
Tablica 191. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Njemačku 322
Tablica 192. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Poljsku 323
Tablica 193. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Portugal... 324
Tablica 194. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Rumunjsku…….325
Tablica 195. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Slovačku….325
Tablica 196. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Sloveniju . 326

Tablica 197. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Španjolsku…….327

Tablica 198. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Švedsku... 328

Tablica 199. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za Ujedinjeno Kraljevstvo 328

Tablica 200. Ukupni rezultati empirijskog istraživanja po državama i hipotezi $H3_2$ .. 329

Tablica 201. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *bruto domaći proizvod po stanovniku* s kriterijskom varijablom *fleksibilnost tržišta radne snage* za sve promatrane zemlje……...330

Tablica 202. Rezultati linearne i nelinearne regresijske analize povezanosti prediktorskih varijabli *udio privremeno zaposlenih osoba, udio zaposlenih osoba na nepuno radno vrijeme* te kriterijske varijable *stopa zaposlenosti* za sve promatrane zemlje……331

Tablica 203. Rezultati linearne korelacijske i nelinearne regresijske analize povezanosti prediktorske varijable *ukupan broj osoba koje imaju fleksibilni oblik radnog odnosa* s kriterijskom varijablom *stopa nezaposlenosti* za sve promatrane zemlje……...332

Tablica 204. Rezultati testa značajnosti razlika između proporcija P^1_1, P^1_2 i P^1_3 i testa značajnosti razlika između proporcija P^2_1, P^2_2 i P^2_3 za sve promatrane zemlje……..333

Tablica 205. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *dobna struktura radnika* za sve promatrane zemlje……335

Tablica 206. Rezultati χ^2-testa ispitivanja povezanosti nominalnih varijabli *vremensko trajanje nezaposlenosti* i *motivacija radnika za traženjem novog posla* za sve promatrane zemlje…….335

Tablica 207. Ukupni rezultati empirijskog istraživanja po državama i hipotezama koje su istraživanjem potvrđene, parcijalno potvrđene ili odbačene 336

POPIS SLIKA

Slika 1. Ciljevi, prioriteti i instrumenti redefinirane Socijalne agende 52
Slika 2. 11 tematskih ciljeva kohezijske politike 56
Slika 3. Intervencije politika tržišta rada 83
Slika 4. Socijalna kohezija i socijalna uključenost 92
Slika 5. Struktura strategije Europa 2020. 120
Slika 6. „Zlatni trokut“ danskog tržišta rada 146
Slika 7. Prediktivni model utjecaja fleksibilnosti tržišta rada na gospodarski razvoj zemalja EU-a 345

POPIS GRAFIKONA

Grafikon 1. Indeks digitalne ekonomije i društva prema područjima u 2018. godini za zemlje članice Europske unije 62
Grafikon 2. Javni izdaci za aktivne politike tržišta rada u 2018. godina za odabrane zemlje 81
Grafikon 3. Stopa zaposlenosti osoba (20 - 64 godine) s niskim, srednjim i visokim stupnjem obrazovanja u zemljama EU-a u 2018. godini 90
Grafikon 4. Jaz u zaposlenosti osoba s invaliditetom prema spolu, dobi i obrazovanju u Europskoj uniji u 2011. i 2016. godini. 93

POPIS KRATICA I SIMBOLA

Kratice

ALMPs – aktivne politike tržišta rada (engl. *active labour market policies*)

AT - Austrija

BDP - bruto domaći proizvod (engl. *gross domestic product – GDP*)

BE - Belgija

BG - Bugarska

CEDEFOP – Europski centar za razvoj strukovnog obrazovanja

CFSP - Zajednička vanjska i sigurnosna politika (engl. *Common foreign and security policy*)

CY - Cipar

CZ - Češka

DE - Njemačka

DESI – Indeks digitalne ekonomije i društva

DG EMPL - Generalna uprava za zapošljavanje, socijalna pitanja i uključivanje (engl. *Directorate-General for Employment, Social Affairs and Inclusion*)

DK - Danska

EAAL - Europski program za obrazovanje odraslih (engl. *European agenda for adult learning*)

EaSI - Program Europske unije za zapošljavanje i socijalne inovacije (engl. *European Union Programme for Employment and Social Innovation*)

ECE – Europski centar stručnosti (engl. *European centre of expertise*)

ECSR - Europski odbor za socijalna prava (engl. *European Committee of Social Rights*)

EE - Estonija

EEA – Europski gospodarski prostor (engl. *European Economic Area*)

EGP – Europski gospodarski prostor

EK – Europska komisija

EL - Grčka

ELA – Europsko nadzorno tijelo za rad

EMU – Ekonomska i monetarna unija

EP – Europski parlament

EPL - zakonodavstvo u području zaštite zaposlenja (engl. *employment protection legislation*)

ERDF - Europski fond za regionalni razvoj (engl. *European Regional Development Fund*)

ES - Španjolska

ESB – Europska središnja banka

ESDP - Europska sigurnosna i obrambena politika (engl. *European security and defence policy*)

ESF - Europski socijalni fond (engl. *European Social Fund*)

ESM – Europski socijalni model

ESP – Europski sud pravde

ETF - Europska zaklada za osposobljavanje

EU – Europska unija

EU-LFS - Anketa o radnoj snazi Europske unije (engl. *European Union Labour Force Survey*)

EU-OSHA – Europska agencija za sigurnost i zdravlje na radu

EUROFOUND – Europska zaklada za poboljšanje životnih i radnih uvjeta

EV - Europsko vijeće

EWG – Radna skupina za zapošljavanje (engl. *Employment working group*)

FI - Finska

FR – Francuska

G7 - Skupina G7 (svjetski ekonomski vrh) (engl. *The Group of Seven*)

G20 – Skupina od dvadeset ministara financija i guvernera središnjih banaka (engl. *Group of Twenty Finance Ministers and Central Bank Governors*)

HR - Hrvatska

HU - Mađarska

ICN - Međunarodna mreža tržišnog natjecanja (engl. *International Competition Network*)

IE – Irska

ILO – Međunarodna organizacija rada (engl. *International Labour Organization*)

IT - Italija

itd. – i tako dalje

LLL – Cjeloživotno učenje

LLP – Program za cjeloživotno učenje

LMP - politike tržišta rada (engl. *labour market policies*)

LMS - segmentacija tržišta rada (engl. *Labour market segmentation*)

LT - Litva

LU - Luksemburg

LV – Latvija

M_e - medijan

MSP – mala i srednja poduzeća

MT - Malta

NEET - mlade osobe od 15 do 24 godine koje nisu zaposlene niti su u obrazovnom procesu ili osposobljavanju

NL - Nizozemska

OECD - Organizacija za ekonomsku suradnju i razvoj (engl. *Organisation for Economic Co-operation and Development*)

OMC – otvorena metoda koordinacije (engl. *Open methods of coordination*)

PES – javne službe za zapošljavanje (engl. *public employment services*)

PIFC - javna unutarnja financijska kontrola (engl. *Public internal financial control*)

PL - Poljska

PT - Portugal

RO - Rumunjska

SDG4 – cilj održivog razvoja br. 4 (engl. *Sustainable Development Goal 4*)

SE - Švedska

SGP - Pakt o stabilnosti i rastu (engl. *Stability and Growth Pact*)

SI - Slovenija

SK - Slovačka

TFEU - Ugovor o funkcioniranju Europske unije (engl. *Treaty on the Functioning of the European Union*)

tzv. - takozvani

UEU - Ugovor o Europskoj uniji

UFEU - Ugovor o funkcioniranju Europske unije

UK - Ujedinjeno Kraljevstvo

UN – Ujedinjeni narodi (engl. *United Nations*)

UNESCO – Organizacija Ujedinjenih naroda za obrazovanje, znanost i kulturu (engl. *United Nations Educational, Scientific and Cultural Organization*)

Simboli

$\bar{x}$ - prosjek

< - manje od

$\sum$ - zbroj

% - postotak

Idium, obrt za lektoriranje i kreativno pisanje
OIB: 85980978249
vl. Nikolina Pinčić
Marina Getaldića 4
23000 Zadar

POTVRDA O LEKTURI

Ivona Blažević Dević

UTJECAJ FLEKSIBILNOSTI RADNE SNAGE NA GOSPODARSKI RAZVOJ ZEMALJA EU-a

Doktorski rad je lektoriran prema pravilima hrvatskoga jezika.

U Zadru 23. siječnja 2023.

Nikolina Pinčić, mag. educ. philol. croat.

IDIUM obrt za lektoriranje i kreativno pisanje
vl. Nikolina Pinčić
Marina Getaldića 4, Zadar
OIB: 85980978249

WWW.IDIUM-SADRZAJ.COM
email: idiumlektoriranje@gmail.com, telefon: 099 766 7493