Ekonomski učinci morskih luka i njihov utjecaj na regionalno gospodarstvo

Mudronja, Gorana

Doctoral thesis / Disertacija

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Economics and Business / Sveučilište u Rijeci, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:192:622654

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Repository / Repozitorij:

Repository of the University of Rijeka, Faculty of Economics and Business - FECRI Repository

UNIRI DIGITALNA KNJIŽNICA

Image not found or type unknown

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Gorana Mudronja

EKONOMSKI UČINCI MORSKIH LUKA I NJIHOV UTJECAJ NA REGIONALNO GOSPODARSTVO

DOKTORSKI RAD

Rijeka, 2019.

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Gorana Mudronja

EKONOMSKI UČINCI MORSKIH LUKA I NJIHOV UTJECAJ NA REGIONALNO GOSPODARSTVO

DOKTORSKI RAD

Mentor: Prof. dr. sc. Alen Jugović
Komentor: Izv. prof. dr. sc. Dunja Škalamera-Alilović

Rijeka, 2019.

UNIVERSITY OF RIJEKA
FACULTY OF ECONOMICS AND BUSINESS

Gorana Mudronja

ECONOMIC EFFECTS OF SEAPORTS AND THEIR IMPACT ON REGIONAL ECONOMY

DOCTORAL THESIS

Rijeka, 2019.

Mentor rada: Prof. dr. sc. Alen Jugović
Komentor rada: Izv. prof. dr. sc. Dunja Škalamera-Alilović

Doktorski rad obranjen je dana 03.10.2019. na Ekonomskom fakultetu Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. Izv. prof. dr. sc. Ana Perić Hadžić, predsjednica povjerenstva
2. Izv. prof. dr. sc. Helga Pavlić Skender, članica povjerenstva
3. Izv. prof. dr. sc. Zoran Ježić, član povjerenstva

Mojoj mami Branki

ZAHVALA

Prvenstveno se zahvaljujem svojem mentoru prof. dr. sc. Alenu Jugoviću na potpori i korisnim savjetima tijekom pisanja doktorske disertacije ali i na poticaju i povjerenju od prvih dana rada na Pomorskom fakultetu u Rijeci. Zahvaljujem se i svojoj komentorici izv. prof. dr. sc. Dunji Škalamera-Alilović na znanstvenom i stručnom usmjeravanju te nesebičnim riječima podrške tijekom cijeloga procesa.

Posebnu zahvalu upućujem i doc. dr. sc. Vinku Zaninoviću koji je nesebično dijelio svoje znanje o ekonometriji sa mnom te strpljivo odgovarao na svako moje postavljeno pitanje i nedoumicu. Također, zahvaljujem i članovima povjerenstva na kvalitetnim i korisnim smjernicama koje su unaprijedile kvalitetu doktorske disertacije.

Nadalje, zahvaljujem se svojim prijateljima i kolegama koji su bili uz mene za vrijeme pisanja doktorske disertacije i pružili mi smijeh i veselje kada mi je to bilo potrebno.

Zahvaljujem se cijeloj obitelji na podršci, a posebno mami Branki koja mi je najveća podrška kroz cijeli život, pruža mi bezuvjetnu ljubav i vjeruje u mene i kada sama posumnjam u sebe.

Hvala mojem suprugu Luki koji me podržava, pruža mi ljubav, motivira me i veseli se svakom mom uspjehu. Uz njega svaki dan svjedočim kako je život lijep i jednostavan.

SAŽETAK

Morske luke važan su dio regionalnih gospodarstava te svojim poslovanjem stvaraju niz pozitivnih utjecaja na područja unutar kojih se nalaze. Veliki dio svjetske trgovinske razmjene odvija se pomorskim putem što čini morske luke neizbježnim lokacijama globalne trgovine. Morske luke objekti su koji potpomažu u uspostavljanju ravnoteže između ponude i potražnje jer povezuju proizvode koji se proizvode na jednom kraju svijeta s potrošačima koji se nalaze na drugom kraju. One stvaraju direktne i indirektne utjecaje na regionalna gospodarstva, kreirajući nova radna mjesta te stvarajući vrijednost koja doprinosi povećanju bruto domaćeg proizvoda. Morske luke smanjuju troškove prijevoza, povećavaju regionalnu zaposlenost te privlače i stvaraju ostale lučke djelatnosti. Razvoj ekonomije, tehnologije te društva općenito potiče morske luke da unaprjeđuju svoje poslovanje u skladu s promjenama. Inovacije te razvoj i primjena novih tehnologija značajne su za uspješno funkcioniranje luka čime se olakšava poslovanje, smanjuju troškovi te privlače novi korisnici. Ljudski kapital također je važan čimbenik jer je novu tehnologiju prvenstveno potrebno razviti te nakon toga uspješno implementirati i koristiti. Razina obrazovanja djeluje na gospodarski rast jer povećava sposobnost prilagodbe i primjene postojeće tehnologije te se reakcijske sposobnosti regije na nova ulaganja i inovacije mogu povezati s kvalitetnim ljudskim kapitalom.

Temeljni cilj doktorskog rada je istražiti utjecaj morskih luka na regionalni gospodarski rast primjenom endogene teorije rasta temeljene na istraživanju i razvoju. Prema endogenoj teoriji rasta temeljenoj na istraživanju i razvoju, najvažniji pokretači gospodarskog rasta su stvaranje inovacija te ljudski kapital. U istraživanju su se koristili panel podaci 107 lučkih regija Europske unije NUTS 2 klasifikacije, u razdoblju od 2005. do 2015. godine. Pri testiranju modela primijenila se dinamička panel analiza. Rezultati Generalizirane metode momenata i njenog procjenitelja u dva koraka ukazuju da morske luke imaju značajan utjecaj na gospodarski rast lučkih regija Europske unije. Također je dokazana važnost ljudskog kapitala i ulaganja u istraživanje i razvoj za poticanje rasta regionalnih gospodarstava. Prema endogenoj teoriji rasta inovacije i ljudski kapital važni su pokretači gospodarskog rasta budući da se smatra kako će razvoj novih ideja konstantno pridonositi razvoju ekonomije čime će gospodarstva moći zauvijek rasti i povećavati životni standard ljudi. Ljudski kapital sa svojim znanjem može postati glavni čimbenik povećanja konkurentnosti morskih luka ali i regionalnih gospodarstava. Primjena inovacija i novih tehnologija te kvalitetan ljudski kapital značajni su i za uspješno poslovanje morskih luka od kojih se očekuje da budu u toku s novim tehnološkim trendovima

te da pružaju usluge na najučinkovitiji način. Rezultati ekonometrijske analize povezuju gospodarski rast lučkih regija s kombinacijom poslovanja morskih luka, ljudskog kapitala te ulaganja u istraživanje i razvoj. Čimbenici ulaganje u istraživanje i razvoj te ljudski kapital često su podcijenjeni u politikama i strategijama Europske unije, posebice u odnosu na ulaganja u prometnu infrastrukturu. Smjernice za preusmjeravanje sredstava mogle bi ići u korist poticanja inovacija te ulaganja u razvitak ljudskog kapitala.

Ključne riječi: morske luke, regionalna gospodarstva, lučke regije Europske unije, endogena teorija rasta, panel analiza

SUMMARY

Seaports are an important part of regional economies since they create a number of positive impacts on the surrounding areas. Much of the world's trade is taking place by sea, making seaports the inevitable locations of global trade. Seaports are facilities that help balance the supply and demand since they link products produced in one part of the world with consumers at the other part. They create direct and indirect effects on the regional economy by creating new jobs and new value that contributes to the growth of gross domestic product. Seaports reduce transportation costs, increase regional employment and create other port activities. The development of the economy, technology and society generally encourages seaports to pursue their business in accordance with the changes. Innovations and the development and application of new technologies are important for the successful operation of ports, making it easier to operate, reduce costs and attract new users. Human capital is also an important factor because the new technology first needs to be developed and then successfully implemented and utilized. The level of education contributes to economic growth, as it increases the ability to adapt and apply existing technology and helps with the region's responsiveness to new investments and innovation.

The basic objective of this dissertation is to research the impact of seaports on regional economic growth by using endogenous growth theory based on research and development (R&D). According to the endogenous growth theory based on R&D, the most important drivers of economic growth are innovation and human capital. Data used in this research were panel data of the 107 European Union's port regions for NUTS 2 classification in period from 2005 to 2015. Dynamic panel data analysis was applied to model testing. The results of the two-step Generalized Method of Moments indicate that seaports have a significant impact on the economic growth of the port regions in European Union. The relationship between human capital and investment in R&D on the economic growth of regional economies was indicated as well. According to the endogenous growth theory based on R&D, main factors that influence economic growth are innovation and human capital. It is considered that the development of new ideas contributes to constant economic development that leads to increment in the standards of living. Human capital with its knowledge can become a major factor in increasing the competitiveness of seaports but also of regional economies. High-quality human capital is also significant for the successful operation of seaports that are expected to be up to date with new technological trends. The results of the econometric analysis link the economic growth of

the port regions with the combination of seaports business, human capital and investment in R&D. Human capital and investment in R&D are often underestimated in European Union's policies and strategies, especially regards to investment in transport infrastructure. Guidelines for resource redistribution could go in favor to investment in R&D and in human capital development.

Key words: seaports, regional economies, European Union's port regions, endogenous growth theory, panel data analysis

SADRŽAJ

1. UVOD 1

1.1. Problem, predmet i objekt istraživanja 3

1.2. Znanstvena hipoteza i pomoćne hipoteze 5

1.3. Svrha i ciljevi istraživanja 5

1.4. Pregled dosadašnjih istraživanja 6

1.5. Znanstvene metode 16

1.6. Kompozicija rada 17

2. ODREDNICE GOSPODARSKOG RASTA U FUNKCIJI ENDOGENE TEORIJE RASTA TEMELJENE NA ISTRAŽIVANJU I RAZVOJU 19

2.1. Povijesni razvoj i osnovna obilježja endogene teorije rasta 20

2.2. Vrste modela endogene teorije rasta 22

2.3. Važnost razvoja novih ideja za rast gospodarstva 26

2.3.1. Karakteristike područja sklonih inovacijama 28

2.3.2. Analiza ulaganja u istraživanje i razvoj u Europskoj uniji 29

2.4. Važnost ljudskog kapitala za rast gospodarstva 35

2.4.1. Karakteristike ljudskog kapitala kao pokretača gospodarskog rasta 37

2.4.2. Analiza ljudskog kapitala u Europskoj uniji 39

3. OSNOVNE ZNAČAJKE MORSKIH LUKA 44

3.1. Temeljna obilježja i ekonomske odrednice morskih luka i njihov značaj u gospodarstvu 45

3.1.1. Općenito o morskim lukama 45

3.1.2. Lučki korisnici i pružatelji usluga 48

3.1.3. Upravljanje lučkim poslovanjem i kvaliteta pružanja usluga 53

3.1.4 Učinkovitost poslovanja morskih luka i lučka konkurentnost 57

3.2. Morske luke u Europskoj uniji 60

3.2.1. Transeuropska mreža prometnica i njena važnost za razvoj i poslovanje morskih luka 62

3.2.2. Analiza i ocjena stanja morskih luka Europske unije 65

3.3. Suvremeni trendovi u poslovanju morskih luka s posebnim osvrtom na ulaganja u tehnološki napredak 71

3.3.1. Postojeći i budući trendovi u poslovanju morskih luka 72

3.3.2. Inovacije i tehnološki napredak u poslovanju morskih luka 75

3.3.3. Razvojne mogućnosti poslovanja morskih luka u budućnosti 78

3.3.4. Primjer implementacije inovacija i suvremenih tehnologija u poslovanju – luka Rotterdam 81
4. MORSKE LUKE KAO SUBJEKTI RASTA REGIONALNIH GOSPODARSTAVA 85
4.1. Važnost morskih luka za regionalno gospodarstvo 86
4.1.1. Unaprjeđenje regionalne konkurentnosti kao posljedica poslovanja luka 88
4.1.2. Tržište rada u lučkom sektoru 91
4.1.3. Utjecaj globalizacije na morske luke i regionalna gospodarstva 94
4.1.4. Značaj lučke infrastrukture za regionalno gospodarstvo 98
4.1.5. Negativni učinci morskih luka na regionalno gospodarstvo 100
4.2. Multiplikativni učinci morskih luka i njihov utjecaj na gospodarstvo 104
4.3. Primjer multiplikativnih učinaka morskih luka: Europska unija 109
5. MJERENJE EKONOMSKOG UTJECAJA MORSKIH LUKA NA REGIONALNA GOSPODARSTVA 116
5.1. Metodološki okvir modela za mjerenje utjecaja morskih luka na regionalna gospodarstva 117
5.2. Metoda panel analize podataka 117
5.2.1. Vrste panel modela 119
5.2.2. Generalizirana metoda momenata i njen procjenitelj u dva koraka 122
5.3. Testiranje modela 123
5.3.1. Definiranje uzorka istraživanja i opis korištenih podataka 123
5.3.2. Deskriptivna statistička analiza podataka 127
5.3.3. Specifikacija empirijskog modela 129
5.3.4. Rezultati empirijskog modela 131
5.4. Prijedlog smjernica za primjenu modela u donošenju odluka i preporuke za budući rad 137
6. ZAKLJUČAK 140
LITERATURA 152
POPIS TABLICA 166
POPIS GRAFIKONA 167
POPIS SHEMA 168
POPIS ZEMLJOVIDA 169
LONG ABSTRACT 170
PRILOZI 185

1. UVOD

Morske luke važan su sudionik u domaćoj i međunarodnoj trgovini, budući da se veliki dio svjetske trgovinske razmjene odvija pomorskim putem, a morske luke su početna i završna točka svakog prijevoza tereta ili putnika morem. Zajedno sa svojom lučkom regijom i okolinom, luka čini logistički centar koji olakšava funkcioniranje globalnog tržišta. Tradicionalno se morske luke smatraju strateškim gospodarskim dobrom sposobnim povezati globalna i lokalna tržišta koja favoriziraju proces globalizacije. Ujedno su morske luke važan čimbenik regionalnih gospodarstava budući da smanjuju troškove prijevoza, povećavaju regionalnu zaposlenost te privlače i stvaraju ostale lučke djelatnosti. Morske luke stvaraju doprinos svojemu međunarodnom konkurentskom položaju te također međunarodnom konkurentskom položaju regije ili zemlje u kojoj se nalaze. Konkurentski položaj luke ogleda se u količini tereta koji se prevozi dok se konkurentski položaj regije definira kroz pokazatelje zaposlenosti i stvorene vrijednosti.

Proizvodnja i potrošnja mnogih proizvoda nalaze se na različitim stranama svijeta te je uloga morskih luka njihovo povezivanje čime se stvaraju globalni opskrbni lanci. Luke su čvorovi u globalnoj logističkoj mreži te povezuju pomorski prijevoz i regije. Poslovanje u morskim lukama u većini slučajeva obuhvaća međunarodno poslovanje čime se stvara konkurencija među morskim lukama u različitim zemljama. Korisnici, ukoliko nisu zadovoljni s poslovanjem u određenoj luci, vrlo jednostavno mogu svoje poslovanje prebaciti u drugu luku što potiče na dodatnu izvrsnost i poboljšanje kvalitete pružanja usluga morskih luka. Osim povezivanja pomorskog i kopnenog prometa, morske luke mogu razviti i industriju unutar svoga prostora te time smanjiti troškove jer se teret ne mora odvoziti u industrijske komplekse.

Poslovanje luka važno je za društvo općenito budući da doprinosi rastu bruto domaćeg proizvoda gradova i regija u kojima se nalaze te stvara nova radna mjesta. Osim stvaranja direktnih pozitivnih učinaka na gospodarstvo, morske luke istovremeno stvaraju i indirektne i inducirane učinke. Indirektni učinci od poslovanja luke nastaju kada se njihovi inicijalni ostvareni dohodci od rada, poslovne zarade i poreznih prihoda naknadno troše ili djelomično troše u regiji čime ponovno generiraju nova radna mjesta i dodatnu poslovnu zaradu. Inducirani učinci proizlaze iz poboljšanja infrastrukture i kvalitete usluga u prometnom sustavu regije zbog postojanja luke. Sudionici u poslovanju morskih luka raznoliki su te imaju direktne ili indirektne koristi od lučkog poslovanja, no za gospodarstvo općenito je važno da morske luke

stvaraju vrijednost te nova radna mjesta sudionicima u lučkom poslovanju. Poslovanje luke u jednoj regiji također može stvoriti učinke prelijevanja na druge regije čime morske luke dobivaju na većoj važnosti.

Važnost morskih luka za rast regionalnih gospodarstava istraživati će se primjenom endogene teorije rasta temeljene na istraživanju i razvoju. Osnovna značajka teorije endogenog rasta je da trajne promjene u pojedinim varijablama ekonomske politike imaju trajan efekt na dugoročne stope ekonomskog rasta. Postoji široki konsenzus među ekonomistima, koji favoriziraju endogene teorije rasta, da su istraživanje i razvoj te ljudski kapital dvije od najutjecajnijih sila sposobnih za povećanje ekonomske produktivnosti. Teorija zagovara važnost istraživanja i razvoja, inovacija i ljudskog kapitala kao pokretača gospodarskog razvoja. Paul Romer njen je začetnik te je njegov glavni doprinos konstrukcija modela koji ističe presudnu ulogu znanja i ideja u ekonomskom rastu.

Endogena teorija rasta govori da ekonomski rast proizlazi iz unutrašnjosti sustava, bilo da se radi o državi ili o poduzeću. Nadalje, teorija navodi kako ljudska bića posjeduju gotovo beskrajni kapacitet za rekonfiguriranje fizičkih objekata, kreirajući nove načine njihove upotrebe čime mogu potaknuti proizvodnost, stvoriti nove prilike za povećanje profita, i konačno, utjecati na ekonomski rast. Endogena teorija rasta također navodi da će se nastaviti povećavati životni standard ljudi tako što će se konstantno unaprjeđivati znanje kako proizvoditi više i kako proizvoditi bolje sa što manje resursa. Starije teorije zagovaraju akumulaciju kapitala koja vodi ka točki zasićenosti tj. utjecaju zakona opadajućih prinosa, dok endogena teorija rasta smatra kako se ideje konstantno razvijaju te nisu podložne zakonu opadajućih prinosa. U doktorskoj disertaciji primijeniti će se dinamička panel analiza te Generalizirana metoda momenata i njen procjenitelj u dva koraka.

Primjena istraživanja i razvoja, inovacija te upotreba novih tehnologija značajne su za uspješno funkcioniranje luka, jer se od njih očekuje da budu u toku s novim tehnologijama koje olakšavaju njihovo poslovanje, smanjuju troškove te privlače nove klijente. Poslovanje morskih luka dinamično je i sklono promjenama te je potrebno pratiti nove trendove koji se javljaju na tržištu. Više nije dovoljno samo prevoziti teret na najučinkovitiji način već tržište očekuje da luke budu i sofisticirane pri rukovanju podacima. Razna su nova rješenja u poslovanju morskih luka, a samo neki od primjera su sljedeći: primjena 5G mreže, Interneta stvari, *blockchain* tehnologije te dronova.

Ljudski kapital u segmentu inoviranja i korištenja novih rješenja u poslovanju igra važnu ulogu te može postati glavni čimbenik povećanja konkurentnosti. Novu tehnologiju prvenstveno je potrebno razviti te nakon toga implementirati što čini dugotrajan proces koji je moguć jedino uz kvalitetnu i obrazovanu radnu snagu. Razina obrazovanja potiče rast jer povećava sposobnost prilagodbe i primjene postojeće tehnologije ili stvaranje novih tehnologija. Nadalje, sposobnost regije da pretvori ulaganje u inovacije u napredak ovisi o primjeni ljudskih znanja te o nizu socio-ekonomskih uvjeta regije. Društveni uvjeti određuju prihvaćanje novih ideja i tehnologija, odnosno područja bez odgovarajuće društvene sposobnosti apsorpcije novih ideja i mogućnosti njihova pretvaranja u korisno znanje, neće moći iskoristiti prednosti inovacijskih investicija.

S razvojem društva, razvijaju se i ekonomija te tehnologija te mnoge svjetske luke unaprjeđuju svoje poslovanje u skladu s promjenama što je istovremeno i izvor njihovih konkurentskih prednosti. Jedan od primjera dobre prakse je luka Rotterdam koja je najznačajnija luka u Europskoj uniji, ne samo po količini prevezenog tereta, već i po primjeni novih znanja i tehnologija u svome poslovanju. Luka Rotterdam te općenito luke Europske unije poslužiti će kao glavni primjeri u gotovo svim poglavljima doktorske disertacije. Europska unija uključuje integraciju prometne infrastrukture, poreznih zakona i kulture te omogućuje suradnju morskim lukama koje se nalaze u različitim zemljama članicama. Korisnici luka Europske unije većinom su međunarodna poduzeća što morske luke čini važnom karikom u povezivanju cijeloga svijeta.

1.1. Problem, predmet i objekt istraživanja

Morske luke važan su sudionik svjetske trgovinske razmjene te stvaraju direktne učinke na regionalno gospodarstvo u aspektima proizvodnje vrijednosti te stvaranja radnih mjesta. Veliki dio svjetske trgovinske razmjene odvija se pomorskim putem što stavlja luke u centar globalnog trgovinskog poslovanja. Slijedom toga, morske luke moraju konstanto unaprjeđivati svoje poslovanje te pratiti nove trendove na tržištu kako bi mogle što kvalitetnije i bolje pružati usluge svojim korisnicima. Tema utjecaja morskih luka na lokalno i regionalno gospodarstvo obrađivana je od većeg broja autora te je veza u većini slučajeva dokazana, no, samo je nekolicina autora koristila ekonomske teorije kao okvir istraživanja.

U kontekstu navedene problematike istraživanja, definiran je **znanstveni problem istraživanja:** iako je utjecaj morskih luka na lokalno i regionalno gospodarstvo bio predmetom istraživanja autora, oni u većini slučajeva nisu koristili ekonomske teorije kao temelj za

istraživanje. Stoga će se u disertaciji kao teorijska osnova koristiti endogena teorija rasta temeljena na istraživanju i razvoju te će se predložiti model kojim će se moći utvrditi ekonomski utjecaj morskih luka na regionalno gospodarstvo. Nadalje, u centru istraživanja gospodarskog rasta regija najčešće je bila prometna infrastruktura dok su ostali pokretači gospodarskog rasta bili zanemareni. Stoga će se u doktorskoj disertaciji, uz poslovanje morskih luka, posebna pozornost obratiti na ulaganje u istraživanje i razvoj i ljudski kapital kao pokretače regionalnog gospodarstva. Ulaganje u istraživanje i razvoj i ljudski kapital istovremeno su bitni čimbenici i za kvalitetno poslovanje morskih luka. Ukoliko luke žele biti i ostati konkurentne na tržištu moraju pratiti nova tehnološka dostignuća koja im omogućuju brži i jeftiniji prekrcaj tereta te moraju imati kvalitetan ljudski kapital koji će znati koristiti novu tehnologiju.

Iz definiranog problema istraživanja proizlazi **predmet znanstvenog istraživanja:** istražiti, analizirati, utvrditi i na sustavan način izložiti dosadašnje teorijske i znanstvene spoznaje o utjecaju morskih luka na rast gospodarstva; prikazati stanje lučkih regija Europske unije; utvrditi i analizirati relevantne čimbenike odnosa između morskih luka, ulaganja u istraživanje i razvoj i ljudskog kapitala te regionalnog gospodarskog rasta u lučkim regijama Europske unije; definirati i na primjeru lučkih regija Europske unije primijeniti novi model za analizu utjecaja poslovanja morskih luka na rast regionalnih gospodarstava; interpretirati rezultate modela i dati preporuke za njihovu daljnju primjenu.

Znanstveni problem i predmet znanstvenog istraživanja odnose se na sljedeće **objekte znanstvenog istraživanja,** a to su: morske luke i gospodarski rast lučkih regija.

Za razliku od ostalih istraživanja u području lučke ekonomije, ovo istraživanje će razmotriti utjecaj poslovanja morskih luka na regionalni gospodarski rast u aspektu endogene teorije rasta temeljene na istraživanju i razvoju. Odnosno, sagledati će što uz morske luke utječe na regionalni gospodarski rast lučkih regija a u skladu je s načelima endogene teorije rasta.

1.2. Znanstvena hipoteza i pomoćne hipoteze

Sukladno definiranom znanstvenom problemu istraživanja, predmetu znanstvenog istraživanja i objektu znanstvenog istraživanja postavljena je i **temeljna znanstvena hipoteza:**

Znanstveno utemeljenim spoznajama o čimbenicima koji utječu na regionalni gospodarski rast moguće je predložiti novi model procjene utjecaja morskih luka na gospodarstvo pripadajuće regije te omogućiti bolje razumijevanje značaja morskih luka u cjelokupnom gospodarstvu.

Iz glavne hipoteze definiraju se sljedeće **pomoćne hipoteze:**

PH 1. Kvantitativnim metodama moguće je analizirati kako efikasnost poslovanja luka utječe na rast regije.
PH 2. Postoji pozitivna veza između ljudskog kapitala i regionalnog gospodarskog rasta te poslovanja luka.
PH 3. Ulaganje u ljudski kapital i istraživanje i razvoj u većoj mjeri utječu na rast regionalnog gospodarstva nego ulaganje u prometnu infrastrukturu.
PH 4. Trgovinska otvorenost pozitivno utječe na regionalni gospodarski rast lučkih regija.

1.3. Svrha i ciljevi istraživanja

Cilj istraživanja je sumirati i proširiti spoznaje o utjecaju morskih luka na regionalna gospodarstva te istaknuti važnost ostalih čimbenika koji djeluju na regionalno gospodarstvo, a istovremeno su važni i za uspješno poslovanje luka.

Specifični ciljevi koji se vežu za glavni cilj te za znanstvenu hipotezu i predmet istraživanja su sljedeći:

- Istražiti čimbenike koji u okviru endogene teorije rasta djeluju na rast gospodarstva
- Istražiti važnost stvaranja novih ideja za gospodarski rast
- Istražiti važnost ljudskog kapitala za gospodarski rast
- Utvrditi važnost ulaganja u nove tehnologije u morskim lukama
- Istražiti multiplikativne učinke morskih luka na gospodarstva
- Analizirati stanje lučkih regija Europske unije

1.4. Pregled dosadašnjih istraživanja

Luke služe kao vitalna veza u mnogim opskrbnim lancima i distribucijskim kanalima koji se odnose na međunarodnu trgovinu, čime igraju važnu ulogu u regionalnom razvoju. One se smatraju ekonomskom infrastrukturom te se pretpostavlja da će razvoj luke stvoriti ekonomske koristi (Bottasso *et al.*, 2014). Luka kao gospodarski subjekt od mnogih je autora (Bottasso *et al.*, 2014; Shan, Yu i Lee, 2014; Park i Seo, 2016) opisana kao žarište regionalnog rasta koje potiče razvoj transporta i olakšava napredak međunarodne trgovine. Nadalje, morske luke su ključne za stvaranje novih mogućnosti zapošljavanja kroz učinke povezane s morskim lukama i logističkim aktivnostima (skladištenje, distribucija, funkcija teretnih kontejnera, itd.). Doprinos morskih luka gospodarskom rastu velik je zbog svoje dodane vrijednosti i logističkih aktivnosti koje se odvijaju u blizini morskih luka koje privlače nove industrije i predstavljaju stupove za razvoj ostalih gospodarskih djelatnosti u okolici luke (Jouili, 2016).

Prometna infrastruktura utječe na sveukupni ekonomski rezultat smanjenjem troškova prijevoza (Fujita *et al.*, 1999) i povećanjem dostupnosti (Bottasso *et al.*, 2014), što izravno smanjuje troškove faktora proizvodnje (Gripaios i Gripaios, 1995; Cohen i Monaco, 2008), povećava privatna ulaganja, potiče trgovinu (Bottasso *et al.*, 2014), stvara i posredno povećava produktivnost rada i poboljšava obrazovne ishode (Aschauer, 1989). Luke mogu biti gledane kao poslovni sustavi koji posluju na vrlo kompetitivnom tržištu te posljedično zahtijevaju kontinuirani razvitak kroz inovacije i osposobljavanje ljudskog kapitala kako bi pospješile kvalitetu svojih usluga i povećale uspješnost cjelokupnog lučkog sustava. Literatura vezana za gospodarski učinak transporta na gospodarstvo je mnogobrojna iako se uglavnom bavi učincima cesta i željeznica, a manje se pažnje posvećuje zračnom i pomorskom prometu. Kako bi se jednostavnije sagledao pregled literature vezane uz temu, literatura se grupirala u pet različitih odjeljaka. Prvo će se dati osvrt na literaturu vezanu uz utjecaj lučke infrastrukture na gospodarstvo, zatim će se obraditi literatura vezana uz utjecaj lučkog poslovanja na zaposlenost nakon čega slijedi utjecaj lučkog poslovanja na gradsko gospodarstvo. Zadnja dva odjeljka najbliža su temi doktorske disertacije, a to su utjecaj lučkog poslovanja na regionalno gospodarstvo te radovi koji se temelje na endogenoj teoriji rasta i istraživanju i razvoju.

Utjecaj lučke infrastrukture na gospodarstvo

Stariji radovi zagovarali su pozitivnu vezu između utjecaja prometne infrastrukture na regionalni razvoj, dok noviji radovi tvrde da odnos nije toliko veliki (Crescenzi i Rodríguez-

Pose, 2012). Povećanje ulaganja u prometnu infrastrukturu moglo bi generirati proširenje relevantnih tržišta za lokalne proizvođače i povećanje konkurentskog pritiska. Jača konkurencija mogla bi potaknuti lokalne proizvođače da inoviraju ili smanje troškove kako bi održali ili čak proširili svoju konkurentnu poziciju, uz pozitivne učinke na lokalni ekonomski rast i na razinu zaposlenosti. Nadalje, smanjenje troškova prijevoza povezano s novom prometnom infrastrukturom trebalo bi lokalnim proizvođačima omogućiti kupnju jeftinijih faktora proizvodnje, specijalizirati se u onim sektorima gdje lokalno gospodarstvo ima komparativnu prednost ili pronaći nova tržišta za svoje proizvode. Međutim, ako lokalni proizvođači nisu osobito učinkoviti, izgradnja nove prometne infrastrukture, pogodujući uvozu jeftinijih dobara, mogla bi čak uzrokovati, posebice u kratkom roku, smanjenje lokalnog rasta i zaposlenosti smanjenjem potražnje za lokalnim proizvodima (Bottasso *et al.,* 2013).

Troškovi prijevoza izravno su povezani s postojanjem dobro razvijene i učinkovite mreže prometne infrastrukture čiji čvorovi, kao što su luke, igraju važnu ulogu. Dugo se vremena luke smatralo motorom za rast i razvoj na lokalnoj i agregatnoj razini jer dopuštaju globalizacijskom procesu da u potpunosti generira svoje koristi kroz razvoj trgovine. Štoviše, dodatne aktivnosti koje su povezane s poslovanjem luke povećavaju multiplikativni utjecaj lučke djelatnosti na samu lučku industriju i na aktivnosti vezane uz luke. Najvažniji teorijski doprinos koji podupire ideju da luke pružaju komparativnu prednost gradovima u kojima se nalaze su razvili Fujita i Mori (1996) u svom modelu koji pokazuje kako luka može stvoriti endogeni rast pružajući konkurentnu prednost gospodarskim aktivnostima koje se nalaze oko nje i objašnjavajući pozitivne učinke transportnih čvorova u procesu prostornog ekonomskog rasta.

Ekonomska teorija tradicionalno je podržavala navedene stavove o važnosti transportne infrastrukture, budući da sugeriraju da usluge koje pruža prometna infrastruktura pozitivno utječu na produktivnost industrije na različite načine. Glavni pozitivni utjecaji su smanjenje vremena i troškova prijevoza, što zauzvrat može imati različite implikacije poput veće produktivnosti drugih faktora proizvodnje, nižih troškova proizvodnje, intenzivnije konkurencije, rasta trgovine, poboljšanja podjele rada, boljeg pristupa stranim intermedijarnim dobrima i iskorištavanje ekonomije razmjera (Aschauer, 1989; Bottasso *et al.*, 2014). Nadalje, veća dostupnost i niži troškovi prijevoza pridonose povećanju tržišnog potencijala različitih lokacija (Niebuhr, 2006; Condeço-Melhorado et al., 2011) .

Jouili (2016) u svome radu mjeri utjecaj infrastrukturnih ulaganja u luke na ekonomski rast okruženja u Tunisu kroz period 1987 – 2014. Budući da je u Tunisu uočeno povećanje ulaganja

u luke, postavilo se pitanje koliko su luke imale utjecaja na ekonomski rast u posljednja dva desetljeća. Koristeći Cobb-Douglasovu proizvodnu funkciju zaključeno je kako infrastrukturna ulaganja stimuliraju proces ekonomskog rasta kroz nekoliko transmisijskih kanala. Investicije pozitivno utječu na ponudu budući da za sobom stvaraju povećanu proizvodnju. Nadalje, investicije modificiraju strukturu transportnih troškova, što koristi procesu ekonomskog rasta te također stimuliraju inozemnu trgovinu kao i izravna strana ulaganja. Infrastrukturne investicije u tuniške morske luke imaju elastičnost BDP-a 0,071 što dokazuje pozitivnu vezu infrastrukturnih ulaganja na ekonomski rast. Budući da tuniška država ulaže oko 6% svojih javih ulaganja u razvoj morskih luka, navedeni rezultati su pozitivni te daju smjernice da se ulaganja u lučku infrastrukturu mogu nastaviti.

Song i van Geenhuizen (2014) istraživali su utjecaj infrastrukturnih lučkih investicija na regionalni ekonomski rast u Kini. Ustvrdili su da dobar položaj kineskih luka ukazuje na činjenicu da je Kina uložila znatna sredstva u lučku infrastrukturu, no ono što im je bilo manje poznato je do koje razine navedene investicije djeluju na ekonomski rast okolnih regija. Zaključili su da investicije u lučku infrastrukturu, gustoća prometnica, lučka prelijevanja te međunarodna povezanost imaju pozitivni utjecaj na regionalni ekonomski rast u Kini. Ukoliko se lučka infrastruktura (u regiji Bohai Rim) poveća za 1%, regionalni BDP će se povećati za 0,54%, a ukoliko se proizvodni sektor poveća za 1%, regionalni BDP će se povećati za 3,81%.

Yoo (2006) je istraživao vezu između infrastrukturnih lučkih investicija i ekonomskog rasta u Koreji između 1970 i 2002. godine. Jedno od glavnih pitanja bilo je utvrditi koja varijabla ima prednost tj. je li investiranje u lučku infrastrukturu poticaj za gospodarski rast ili ekonomski rast dovodi do ulaganja u lučku infrastrukturu. Rezultati istraživanja pokazali su da postoji jednosmjerna dugotrajna kauzalnost od ulaganja u lučku infrastrukturu prema ekonomskom rastu bez ikakvog učinka povratne veze. Visoka razina ulaganja u lučku infrastrukturu dovodi do visoke razine realnog BDP-a, iako postoje mnogi drugi čimbenici koji doprinose gospodarskom rastu, a ulaganje u lučku infrastrukturu je samo jedan od čimbenika.

Autori Deng i suradnici (2014) istražili su optimalnu razinu akumulacije transportne infrastrukture koja maksimizira stopu rasta. Istražili su u kojim okolnostima dodatna prometna infrastruktura pozitivno utječe na ekonomski rast u Kini, bazirano na regresijskoj panel analizi koja koristi pragove (eng. *panel threshold regression models*). Većina radova bavi se pronalaskom veze između infrastrukturnih transportnih ulaganja te njihovog utjecaja na gospodarstvo i izračuna elastičnosti prometne strukture, no autore je u ovome radu zanimalo da

li će i daljnja ulaganja imati pozitivne učinke i u kojoj mjeri tj. postoji li prag preko kojega dodatna ulaganja ne vode ka boljoj ekonomskoj efikasnosti. Aplicirali su Barrov model rasta nakon što su ga prilagodili regionalnim faktorima koji utječu na lokalnu ekonomsku aktivnost. Procjena parametara gustoće mreže autocesta pozitivna je i vrlo značajna na razini od 1%, kada se nalazi u rasponu između 0,17 i 0,387. Kada je gustoća cesta ispod 0,17 km/km^2 utvrđen je neznatan pozitivan odnos između akumulacije transportne infrastrukture i ekonomskog rasta. Nakon što gustoća mreže autocesta dosegne drugi prag od 0,387 km/km^2, učinak akumulacije infrastrukture autocesta na ekonomski rast pokazuje padajući trend, s koeficijentom jednakim 0,09. Autori su zaključili kako ulaganje u prometnu infrastrukturu mora biti optimalno jer premalo ulaganje ili čak i preveliko ulaganje ne vode ka poboljšanju gospodarstva.

Nketiah-Amponsah (2009) istražuje alokaciju izdataka koji su vezani za gospodarski rast u Gani u razdoblju 1970-2004. Izdaci za obrazovanje i zdravstvo predstavljaju razvoj ljudskog kapitala, dok izdaci za ceste i vodene putove predstavljaju razvoj infrastrukture. Rezultati pokazuju da izdaci za zdravstvo i infrastrukturu potiču gospodarski rast, dok oni za obrazovanje nisu imali značajan utjecaj u kratkom roku.

Autori Canning i Pedroni (2008) također se bave pitanjem infrastrukture i njenog utjecaja na gospodarski rast te njihovi rezultati pokazuju da iako infrastruktura nastoji uzrokovati dugoročni gospodarski rast, no postoje znatne razlike među zemljama. Njihov model prikazuje kako postoji točka maksimizacije infrastrukture te ako se zemlja nalazi ispod te točke tada povećanje infrastrukture povećava dugoročni rast dok ako se zemlja nalazi iznad te točke povećanje infrastrukture smanjuje dugoročni rast.

Devarajan i suradnici (1996) u svome radu istražuju odnos između kompozicije javnih izdataka i gospodarskog rasta zemalja u razvoju koristeći podatke 43 zemlje u razvoju tokom više od 20 godina. Autori su u istraživanju došli do rezultata da standardni pokretači gospodarskog napretka kao što su kapital, promet i komunikacije, zdravlje i obrazovanje imaju negativan ili beznačajan odnos s gospodarskim rastom što su opravdali teorijskim modelom koji kaže da javni izdaci koji se smatraju produktivnima mogu postati neproduktivni ako se javljaju u prekomjernoj količini. Na primjer, kapitalni rashodi, koji se često smatraju pokretačem razvoja, su prekomjerni u zemljama u razvoju čime su ukazali da vlade zemalja u razvoju pogrešno dodjeljuju javne izdatke u korist kapitalnih sredstava.

Yu i suradnici (2012) istražuju postoji li povezanost između ulaganja u prometnu infrastrukturu i gospodarskog rasta u Kini na nacionalnoj i regionalnoj razini koristeći podatke vremenske serije u razdoblju od 1978-2008 godine. Empirijski nalazi pokazuju da dugoročno, na nacionalnoj razini, postoji jednostrana Grangerova kauzalnost od gospodarskog rasta do prometne infrastrukture; na regionalnoj razini postoji dvosmjerna kauzalnost u bogatoj istočnoj regiji, dok siromašnije središnje i zapadne regije pokazuju jednosmjernu Grangerovu kauzalnost od gospodarskog rasta do prometne infrastrukture. U kratkom roku, ne postoji uzročnost između gospodarskog rasta i ulaganja u infrastrukturu kako na nacionalnoj tako i na regionalnoj razini. Navedeni rezultati upućuju na to da poboljšanje samo prometne infrastrukture nije dovoljno za poticanje gospodarskog rasta u nerazvijenim područjima Kine. Kako bi bolje shvatila ekonomske koristi koje donosi prometna infrastruktura, kineska vlada treba obratiti pozornost na razvoj komplementarnih čimbenika u središnjim i zapadnim regijama.

Općenito, nositelji politike uvijek su smatrali da je prometna infrastruktura, čiji je sastavni dio lučka infrastruktura, ključni čimbenik koji može potaknuti teritorijalnu koheziju, ublažiti gospodarske razlike, pogodovati gospodarskom razvoju i konvergenciji. Na primjer, oko 30% fondova Europske unije za regionalni razvoj (ERDF) i Kohezijskih fondova za razdoblje od 2007. do 2013. godine posvećeno je investicijama u infrastrukturu, a značajan je dio takvog proračuna dodijeljen ulaganjima u prometnu infrastrukturu s ciljem poboljšanja regionalnih potpora i dovršavanja transeuropskih prometnih mreža (TEN-T): ceste, željezničke pruge velikih brzina, luke za otpreme tereta i zračne luke financirane kroz sheme TEN-T-a. Očekivanja su bila da će donijeti velike transformacije širom Europske unije, ne samo uklanjanjem uskih grla i prekida u transportnom sustavu Europske unije, već i u smislu poboljšanja regionalnog BDP-a po stanovniku, promicanja zapošljavanja, olakšavanja mobilnosti i povećanja dostupnosti, što se odražava u kriterijima procjene za ove mjere politike (EspoN, 2009).

Međutim, pozitivni efekti lučkih aktivnosti na lokalna i regionalna gospodarstva smanjili su se, pogotovo tokom posljednjih 40 godina, budući da su se javile promjene na pomorskom tržištu, posebice uvođenje kontejnera i više kapitalno intenzivnih rješenja. Navedeno je smanjilo efekt izravnih zapošljavanja (Musso *et al.*, 2000; Grobar, 2008).

Utjecaj lučke infrastrukture na pripadajuće gospodarstvo istražena je tema te su rezultati raznoliki. Ulaganja u infrastrukturu iziskuju velike novčane iznose te je potrebno vrijeme da se

pozitivni efekti ulaganja počinju ostvarivati. Druga negativna strana je što infrastruktura brzo zastarijeva, odnosno potrebna su kontinuirana ulaganja te je podložna zakonu opadajućih prinosa – sve više i više ulaganja donosi rast gospodarstvu ali po opadajućoj stopi i to dok ne dosegne točku zasićenosti nakon koje dodatna ulaganja u infrastrukturu ne vode gospodarskom rastu. Neka od navedenih istraživanja dokazuju kako infrastruktura nema toliko jaki utjecaj na gospodarstva kako se to u određenim prijašnjim istraživanjima smatralo te ukazuju da postoje drugi utjecaji na koje bi se trebala obratiti pozornost. Stoga samo ulaganje u infrastrukturu nije dovoljno kako bi se lučka regija i lučko gospodarstvo mogli dugoročno razvijati već je potrebno obratiti pozornost i na ostale pokretače regionalnog gospodarskog rasta.

Utjecaj lučkog poslovanja na zaposlenost

Utjecaj lučkog poslovanja za lokalnu i regionalnu zaposlenost je također tema kojom su se bavili određeni autori. Grobar (2008) je istraživala najveće kontejnerske luke Sjedinjenih američkih država i njihov utjecaj na zapošljavanje te je utvrdila da su stope nezaposlenosti i siromaštva znatno veće u lučkim područjima nego u područjima koja nemaju luku. Prisutnost velike kontejnerske luke ne služi kao motor rasta za lokalno područje već za područje koje nema luku. Moguće objašnjenje ovog promatranog trenda je da ukoliko velike kontejnerske luke stvaraju značajne lokalne negativne vanjske utjecaje, to može smanjiti cijenu iznajmljivanja nekretnina u blizini luke, čime privlače kućanstva s niskim prihodima. Rezultati rada također ukazuju na činjenicu da u mnogim lučkim četvrtima ima mnogo poslova, no njihovi stanovnici imaju visoke stope nezaposlenosti i siromaštva. U radu se koristila samo deskriptivna statistika što je ograničavajući čimbenik istraživanja.

Bottasso i suradnici (2013) procijenili su utjecaj lučke djelatnosti na lokalno zapošljavanje na uzorku od 560 lučkih i ne-lučkih regija koje pripadaju 10 zapadnoeuropskih zemalja, promatrane tijekom razdoblja od 2000. do 2006. godine. Uzorak uključuje 116 luka koje pokazuju značajnu heterogenost u svojoj specijalizaciji. Zbog navedenog u obzir su uzete lučke djelatnosti svih glavnih prometnih kategorija: kontejnera, tekućeg tereta, suhog tereta, Ro-Ro prometa, ostalog prometa i putnika. Utvrđeno je da promet luke znatno povećava razinu zapošljavanja u regiji u kojoj se luka nalazi, s manje izraženim učinkom na uslužni sektor u usporedbi s prerađivačkim industrijama. Procijenjeni pokazatelji upućuju na to da, primjerice, u regiji s milijun radnika, povećanje od 1 milijun tona tereta stvara oko 400 do 600 novih radnih mjesta, ovisno o specifikaciji modela. Nasuprot tome, nije pronađena povezanost između broja pomorskih putnika i zapošljavanja.

Povezivanjem lučkog prometa i razine zaposlenosti u regijama bavili su se i Ferrari i suradnici (2010.). U svome radu procijenili su utjecaj poslovanja luka na zaposlenost u proizvodnom sektoru, zaposlenost u uslugama te na ukupnu zaposlenost. Dokazali su pozitivan utjecaj luka na zaposlenost, s elastičnošću koja leži u intervalu od 0,015 – 0,024, a nešto je značajnija u tercijarnom sektoru.

Povezanost morskih luka i zaposlenosti pretpostavlja se sama po sebi budući da su luke izravni poslodavci, no također stvaraju i dodatnu industriju i razvoj poduzeća u okolini koja su povezana s njihovim poslovanjem. Teze i zaključci prethodno navedenih radova poslužiti će za potrebe disertacije budući da je i sama zaposlenost jedan od utjecaja na rast i razvoj regionalnog gospodarstva. Svaka industrija povezuje se s različitim karakteristikama zaposlenih te će se u disertaciji sagledati u kojoj mjeri ljudski kapital utječe na razvoj regionalnog gospodarstva, a samim time i na razvoj poslovanja luka, što u prethodnim radovima autora nije bilo istraženo.

Utjecaj lučkog poslovanja na gradsko gospodarstvo

Utjecajem prometa luka na gradsko gospodarstvo bavili su se Shan i suradnici (2014) te su prikupili podatke makroekonomskih pokazatelja i prometa morskog tereta u 41 lučkom gradu u Kini tijekom godina 2003. do 2010. Autori su ispitivali tri situacije: (1) gospodarski utjecaj lučkih djelatnosti na lokalno područje na kojem u nalazi luka, (2) utjecaj prelijevanja luke na susjedno područje te (3) odnos i interakciju između susjednih luka budući da su mnoge luke bile zabrinute da im susjedne konkurentne luke oduzimaju posao. S godišnjim podacima na gradskoj razini, izvršili su ekonometrijsku analizu kako bi se ispitao utjecaj aktivnosti luka na gospodarski rast gradova. Donijeli su tri važna zaključka: prvo, promet tereta u luci značajno utječe na gospodarski rast grada u kojem se luka nalazi. Drugo, kontejnerski promet tereta većih luka u puno većoj je mjeri povezan s gospodarstvom nego što je to slučaj u manjim lukama. Treće, protuintuitivno, promet tereta konkurentskih morskih luka ima pozitivan utjecaj na gradsko gospodarstvo. Prema analizi, konkurencija susjednih luka može pomoći pri poticanju lokalnog gospodarstva. Navedeno ilustrira koncept poznat kao kooperacija luka, gdje pored čistog tržišnog natjecanja luke u istoj regiji mogu imati koristi od suradnje jedne s drugima, kako bi se povećala ukupna količina tereta u regiji.

Zhao i suradnici (2017) pretpostavili su da prethodno smatrana jaka veza između luka i lučkih gradova u posljednje vrijeme slabi te također istražuju mogućnosti privlačenja investicija. Koristili su podatke 50 najvećih svjetskih kontejnerskih luka. Rezultati pokazuju da, unatoč

pozitivnom odnosu između luka i lučkih gradova, lučki gradovi ne pokazuju značajne prednosti u odnosu na ne-lučke gradove u kontekstu privlačenja izravnih stranih ulaganja *(eng. Foreign Direct Investment – FDI).* Nadalje, konkurentnost lučkog grada ovisi više o urbanim karakteristikama nego o faktorima luke.

Cheung i Yip (2011) obradili su temu povezanosti luke i gospodarstva grada kojemu luka pripada, no s obrnutog aspekta od ostalih autora tj. istraživali su na koji način gospodarstvo utječe na luku i lučku proizvodnju. Lučke gradove smatrali su proizvodnom organizacijom, lučku proizvodnju finalnim proizvodom organizacije (outputom), dok su gradske čimbenike smatrali faktorima proizvodnje (inputima). Rad su temeljili na sedam lučkih gradova u Kini. Razvijen je model ekonomske proizvodnje za proučavanje proizvodnje luka u odnosu na gradske čimbenike koji doprinose lučkim operacijama temeljen na Cobb-Douglasovoj proizvodnoj funkciji. U svome radu identificirali su luku i gradsko sučelje te odgovorili na dva temeljna pitanja: kako luke olakšavaju funkcioniranje grada i kako gradovi podržavaju lučke funkcije. Gradske čimbenike grupirali su u nekoliko skupina: ekonomski čimbenici, demografski čimbenici i infrastrukturni čimbenici te su promatrali kako svaka od navedenih skupima utječe na lučku proizvodnju. Prepoznato je da gradsko gospodarstvo tj. ekonomski čimbenici daju najznačajniji doprinos rastu luke, ali ne postoje dosljedni rezultati o učincima infrastrukture i demografskih čimbenika na lučko poslovanje. Rad nudi statističke dokaze koji podupiru razvoj lučkih gradova i pruža čvrste temelje za gospodarsku politiku razvoja luka.

Povezanost gradskog gospodarstva s lučkim poslovanjem dakako postoji, no utjecaj lučkog poslovanja može biti u mnogome širi od samoga grada, budući da se sve popratne aktivnosti i poslovi ne mogu odvijati u samome gradu. Multiplikativni efekti poslovanja luka u većini slučajeva biti će mnogo širi tj. obuhvaćati će jezgru (općina ili grad), unutrašnji krug, vanjski krug te periferiju (Kesić i Jugović, 2006:166) stoga će se istraživanje u disertaciji bazirati na regionalnom gospodarstvu, a zaključci nekih od autora koji su se bavili povezanošću regionalnog gospodarstva i lučkog poslovanja dani su u nastavku.

Utjecaj lučkog poslovanja na regionalno gospodarstvo

Park i Seo (2016) u svome radu istražuju ekonomske utjecaje morskih luka na regije u Koreji. Koristili su ekonometrijski alat proširenog Solowljevog modela koji se konstruirao na temelju panel podataka za 11 velikih lučkih gradova i njihovih luka te 5 regija koje nemaju luke, tijekom razdoblja od 2000. do 2013. godine. Autori su jedni od rijetkih koji se referiraju na ekonomsku

teoriju prilikom proučavanja povezanosti morskih luka i njihovog utjecaja na gospodarstvo. Dokazali da teretne luke bez dovoljnog prometa tereta ometaju regionalni gospodarski rast (većinom se radi o malim lukama), dok u slučajevima dovoljnog prometa tereta pridonose regionalnom gospodarskom rastu. Nadalje, dokazali su da kontejnerske lučke djelatnosti pozitivno utječu na regionalni gospodarski rast, dok investiranja u luku neizravno dovode do ekonomskog rasta tj. potrebno je investirati u luke koje su uspješne te imaju dovoljan promet tereta, u suprotnome investicije ne vode ka poboljšanju. Također su dali smjernice koje govore da je bolje graditi i razvijati veće luke nego više manjih luka. Procjene ukazuju da povećanje prometa tereta od 1 tone u teretnoj luci teži povećanju ekonomskog rasta u odgovarajućoj regiji za 2,78%. Kada su u pitanju kontejnerske luke, rezultat ukazuju da povećanje od 1% u kontejnerskom teretu rezultira s prosječno 0,07% povećanja gospodarskog rasta u datim regijama. Zaključno, u kontekstu Koreje, utvrđeno je da su kontejnerske i teretne luke (s dovoljnim količinama tereta) važne za jačanje regionalnih gospodarstava.

Bottasso i suradnici (2014) u svome radu analiziraju utjecaj aktivnosti luka na regionalni BDP, s naglaskom na njegove učinke prelijevanja na susjedne regije. U obzir su uzeli europske regije te koristili prostornu panel analizu. Empirijski nalazi ukazuju da luke imaju tendenciju povećanja BDP-a na području gdje se nalaze (izravni učinak) te da postoje velika i pozitivna prelijevanja na BDP obližnjih regija. Procjene izravnog učinka upućuju na to da povećanje prometa luka od 10% u određenoj regiji ima tendenciju povećanja BDP-a u istoj regiji za oko 0,01 - 0,03%. Što se tiče ukupnog učinka, procjene impliciraju da je navedeno povećanje od 10% u razini prometa luka u određenoj regiji povezano s prosječnim porastom BDP-a u svim regijama u rasponu od 0,06 - 0,2%, što zauzvrat podrazumijeva neizravne učinke prelijevanja u rasponu od 0,05 - 0,18%. Rezultati istraživanja također ukazuju na činjenicu da ekonomska ekspanzija u regijama koje nemaju luku također može generirati veću potražnju za lučkim uslugama u lučkim regijama. Nadalje, autori su naveli i smjernice vezane uz model upravljanja morskim lukama gdje učinci lučke djelatnosti na regionalni BDP potvrđuju mogućnost daljnjeg ulaganja u politike razvoja infrastrukture.

Autori koji se bave povezanošću luka s gospodarstvom, bilo da se radi o povezanosti s bruto domaćim proizvodom ili sa zaposlenošću, u većini slučajeva dokazali su kako postoji pozitivna veza između jednih i drugih. Veliki nedostatak većine radova je nepovezivanje istraživanja s ekonomskim teorijama i novim ekonomskim saznanjima. Aspekt ljudskog kapitala, ulaganja u istraživanje i razvoj te ostali socio-ekonomski uvjeti nisu uzeti u obzir prilikom povezivanja i

utvrđivanja utjecaja morskih luka na pripadajuće gospodarstvo. Prema endogenoj teoriji rasta smatra se da znanja i ideje nisu podložni zakonu opadajućih prinosa kao što je to slučaj kod infrastrukture, premda i jedna i druga strana iziskuju velika novčana ulaganja.

Radovi temeljeni na istraživanju i razvoju

Crescenzi i Rodriguez-Pose (2012) u svome radu ispituju do koje razine prometna infrastruktura utječe na regionalni gospodarski rast u Europskoj uniji u razdoblju između 1990. i 2004. godine. Istraživanje se djelomično temelji na endogenoj teoriji rasta. Rezultati Generalizirane metode momenata i njenog procjenitelja u dva koraka ukazuju da je infrastruktura (reprezentirana cestovnom mrežom) relativno loš prediktor gospodarskog rasta te da regionalni gospodarski rast Europske unije rezultira od kombinacije adekvatnog socijalnog filtra, dovoljnog ulaganja u inovacije i razvoj te od regionalne sposobnosti da privlači migrante. Autori su zaključili kako ne postoji jaka povezanost između ulaganja u infrastrukturu i regionalnog gospodarskog rasta te da bi se sredstva trebala preusmjeriti na ulaganje u ljudski kapital i inovacije i razvoj.

Autori Bilbao-Osorio i Rodriguez-Pose (2004) istraživali su utjecaj ulaganja u istraživanje i razvoj na razvoj inovacija te utjecaj inovacija na ekonomski rast. Objasnili su da uz samo ulaganje u istraživanje i razvoj moraju postojati i određeni socio-ekonomski uvjeti kao preduvjeti za uspješnu implementaciju novih ideja. Uvjeti obuhvaćaju relativno visoku zaposlenost stanovništva budući da su nezaposleni manje skloni inoviranju, zatim visoku razinu ljudskog kapitala tj. dobra obrazovna dostignuća te određenu ekonomsku strukturu regije. Ekonomska struktura odnosi se na pretežitu djelatnost kojom se bavi regija, odnosno poljoprivredne regije biti će manje sklone inoviranju u odnosu na regije koje se bave određenim uslužnim i proizvodnim djelatnostima. Rezultati ukazuju na pozitivnu vezu između ulaganja u istraživanje i razvoj i inovacija iako postoji razlika između različitih istraživačkih sektora (privatni, javni i visoko obrazovanje). Točnije, istraživačke aktivnosti privatnog sektora imaju jaču vezu u odnosu na ostale sektore. Veza između inovacija i ekonomskog rasta je postojeća u perifernim regijama, ali ne postoji u regijama koje nisu periferne. Autori su zaključili kako su i ostali čimbenici osim inovacija važni kako bi se razumio proces gospodarskog rasta u regijama Europske unije.

Crescenzi (2005) je u svome radu predložio model koji prikazuje vezu između inovacija i rasta u regijama Europske unije. U teorijskom dijelu autor je postavio hipotezu kako različite inovacijske aktivnosti vode ka različitim ekonomskim učincima. Izračunat je vlastiti inovacijski

indeks koji je uveden u regresijsku analizu. Analiza je pokazala kako inovacijske aktivnosti igraju važnu ulogu u definiranju regionalnog rasta. Također je zaključeno da inovativne aktivnosti u periferijalnim područjima moraju biti poduprte velikim ulaganjima u ljudski kapital kako bi mogle biti produktivne kao one u središnjim područjima.

Endogena teorija rasta služila je kao temelj istraživanja autorima koji su se bavili utjecajem transportne infrastrukture na rast gospodarstava, no utjecaj poslovanja morskih luka primjenom navedene teorije još nije obrađen. Radovi su općenito dokazali važnost ulaganja u istraživanje i razvoj kao pokretača rasta gospodarstva. Uzimajući prethodne spoznaje u obzir, u doktorskoj disertaciji obraditi će se utjecaj poslovanja morskih luka na rast regionalnih gospodarstava primjenom endogene teorije rasta temeljene na istraživanju i razvoju. Prethodna istraživanja autora poslužiti će kao pomoć i smjernice ali i temelj za određenu modifikaciju spoznaja prilikom istraživanja i donošenja zaključaka u doktorskoj disertaciji.

1.5. Znanstvene metode

Prilikom pisanja disertacije te tokom znanstvenog istraživanja koristiti će se različite znanstvene metode pomoću kojih će se istražiti postavljeni problem istraživanja te omogućiti donošenje zaključaka. Metode koje će se koristiti jesu sljedeće: metoda analize i sinteze, metoda deskripcije i eksplanacije, induktivna i deduktivna metoda, metoda generalizacije i specijalizacije, metoda komparacije, metoda klasifikacije, metoda kompilacije, grafička metoda, statistička metoda, povijesna metoda te kvantitativna metoda.

U teorijskom dijelu rada koristiti će se opsežna literatura iz područja ekonomije luka i endogene teorije rasta. Koristiti će se opsežan bibliografski opus koji je vezan uz navedenu problematiku te se sastoji od relevantne domaće i inozemne literature znanstvenog i stručnog usmjerenja. Kroz kvalitativnu i kvantitativnu analizu kritički će se prikazati stanje morskih luka regija Europske unije kao i njihova razina ulaganja u istraživanje i razvoj, ljudski kapital, stanje nezaposlenosti, trgovinsku otvorenost, populaciju te ulaganje u prometnu infrastrukturu. Također će se istražiti važnost čimbenika koji djeluju na gospodarski napredak u okviru endogene teorije rasta.

Prilikom testiranja modela koristiti će se dinamička panel analiza (*eng. Dynamic Panel Data Model*). Upotrijebiti će se Generalizirana metoda momenata i njen procjenitelj u dva koraka (*eng. two-step Generalized Method of Moments (GMM)*) izveden od strane Arellano i Bond

(1991) i modificiran od strane Blundell i Bond (1998). Testirani podaci obuhvaćaju 107 lučkih regija Europske unije u razdoblju od 2005. do 2015. godine.

1.6. Kompozicija rada

Rezultati istraživanja u svrhu dokazivanja temeljne hipoteze te pomoćnih hipoteza biti će prezentirani u šest međusobno povezanih dijelova.

U prvom dijelu ***Uvodu*** definirani su problem, predmet i objekt istraživanja. Definirana je znanstvena hipoteza i pomoćne hipoteze koje se povezuju s glavnom hipotezom, svrha i ciljevi istraživanja te je naveden pregled dosadašnjih istraživanja povezanih s temom disertacije. Navedene su znanstvene metode koje će se koristiti u svrhu dokazivanja hipoteza.

Drugi dio s naslovom ***Odrednice gospodarskog rasta u funkciji endogene teorije rasta temeljene na istraživanju i razvoju*** bavi se objašnjavanjem endogene teorije rasta temeljene na istraživanju i razvoju, koja čini teorijsku podlogu doktorske disertacije. Opisuje se povijesni nastanak endogene teorije rasta te se definiraju njene vrste. Objašnjava se važnost razvoja novih ideja za rast gospodarstva te važnost ljudskog kapitala za rast gospodarstva. Također se analiziraju ulaganja u istraživanje i razvoj, ljudski resursi u znanosti i tehnologiji, udio ljudi s visokim obrazovanjem u ukupnoj populaciji te indeks ljudskog razvoja na primjeru zemalja članica Europske unije.

U trećem dijelu koji nosi naslov ***Osnovne značajke morskih luka*** opisuju se temeljna obilježja morskih luka, definira se tko su lučki korisnici a tko pružatelji usluga, na koji način se upravlja lučkim poslovanjem te se definira lučka konkurentnost. U poglavlju se također analiziraju morske luke Europske unije te objašnjavaju suvremeni postojeći i budući trendovi u poslovanju morskih luka. Analiziraju se inovacije i tehnološki napredak koji se javljaju u poslovanju morskih luka te objašnjavaju razvojne mogućnosti luka u budućnosti. Na kraju poglavlja daje se primjer luke Rotterdam kao najuspješnije luke Europske unije ne samo po prometu tereta nego i po primjeni suvremenih tehnologija u poslovanju.

Morske luke kao subjekti rasta regionalnih gospodarstava naslov je četvrtog dijela doktorske disertacije. Poglavlje se bavi definiranjem i analiziranjem važnosti morskih luka za regionalna gospodarstva u aspektima stvaranja konkurentskih prednosti i radnih mjesta. Analizira se tržište rada u lučkom sektoru te njegovi najzastupljeniji poslovi. Nadalje, analizira se na koji način je

globalizacija imala utjecaj na poslovanje morskih luka i njihova regionalna gospodarstva te se analizira značaj lučke infrastrukture za regionalno gospodarstvo. Također se daje uvid u negativne utjecaje koje morske luke stvaraju na okolinu. Analiziraju se multiplikativni učinci što ih morske luke stvaraju na pripadajuća gospodarstva te se daje primjer europske pomorske industrije kao kreatora multiplikativnih učinaka za europska gospodarstva.

Peti dio s naslovom ***Mjerenje ekonomskog utjecaja morskih luka na regionalna gospodarstva*** bavi se formiranjem i testiranjem modela kojim se mjeri utjecaj poslovanja morskih luka na regionalna gospodarstva u okviru endogene teorije rasta temeljene na istraživanju i razvoju. Opisuje se metodološki okvir postavljenog modela, definira i opisuje metoda panel analize podataka te Generalizirana metoda momenata koja će se koristiti za testiranje modela. Primjenom dinamičke panel analize podataka na uzorku 107 lučkih regija Europske unije ocijenjen je utjecaj poslovanja morskih luka na regionalna gospodarstva u razdoblju od 2005. do 2015. godine. Iznose se rezultati te testiraju pomoćne hipoteze i glavna hipoteza istraživanja. Na kraju poglavlja daje se prijedlog smjernica za primjenu modela u donošenju odluka.

U posljednjem šestom dijelu, ***Zaključku***, sustavno su i koncizno formulirani i prezentirani najvažniji rezultati znanstvenog istraživanja koji su prethodno detaljno opisani u doktorskoj disertaciji te kojima se dokazuje postavljena hipoteza rada.

2. ODREDNICE GOSPODARSKOG RASTA U FUNKCIJI ENDOGENE TEORIJE RASTA TEMELJENE NA ISTRAŽIVANJU I RAZVOJU

Teorija endogenog rasta zagovara da promjene u pojedinim varijablama ekonomske politike trajno utječu na dugoročne stope gospodarskog rasta. Glavni motiv istraživanja dugoročnog rasta jest razaznati zašto su neke zemlje bogatije, a neke siromašnije. Općenito, i vrlo male promjene u dugoročnoj stopi gospodarskog rasta mogu uzrokovati značajne razlike u životnom standardu građana te se želi razaznati što potiče gospodarski rast. Modeli endogenog rasta mogu se svrstati u tri glavne skupine: u jednoj grupi modela endogenog rasta akumulacija kapitala je ključni pokretač gospodarskog rasta (AK modeli) te se smatra da gospodarstva koja žele ostvariti gospodarski rast moraju povećavati količinu svoja fizičkog i ljudskog kapitala. U drugoj grupi modela rast potiču eksternalije te zagovara također akumulaciju kapitala koja vodi ka gospodarskom rastu. Treća grupa modela zastupa stajalište da gospodarski rast potiču tehnološke promjene koje su rezultat ulaganja u istraživanje i razvoj, odnosno rezultat ljudske aktivnosti. Teorija koja će predstavljati temelje doktorske disertacije je endogena teorija rasta zasnovana na istraživanju i razvoju. Noviji modeli rasta impliciraju da nacionalne politike utječu na razinu i efikasnost akumulacije faktora proizvodnje, a time i na ravnotežne stope rasta, dajući veliku ulogu nacionalnim politikama u određivanju dugoročnog ekonomskog rasta. Modeli odbacuju pretpostavke o opadajućim prinosima i konvergenciji, što je temelj neoklasičnih modela te smatraju kako do konvergencije uopće ne mora doći tj. bogate zemlje mogu vječno unaprjeđivati svoj životni standard, dok siromašne zemlje mogu zauvijek ostati slabije razvijene. Pitanje je da li je ekonomski rast rezultat sreće ili promišljenih odluka i odabira različitih politika. Empirijski podaci govore u prilog druge teze tj. da se na gospodarski rast može utjecati izborom optimalnih politika (Mervar, 1999:20).

U sljedećim potpoglavljima dati će se uvid u povijesni razvoj endogene teorije rasta te nabrojati i analizirati vrste endogene teorije rasta. Nadalje, definirati će se važnost razvoja novih ideja i ljudskog kapitala za rast gospodarstva te će se analizirati ulaganja u istraživanje i razvoj i ljudski kapital u Europskoj uniji.

2.1. Povijesni razvoj i osnovna obilježja endogene teorije rasta

Ekonomisti klasične škole bavili su se ekonomskim rastom na način da su analizirali odnos između raspodjele dohotka, akumulacije kapitala i rasta. Prvi model rasta bio je Harrod-Domarov model koji tvrdi da tržište nije dovoljno jako da samostalno osigura rast gospodarstva uz punu zaposlenost. Model pretpostavlja fiksni odnos između kapitala i rada te implicira da se gospodarstvo redovito nalazi izvan svoje putanje rasta (Mervar, 1999:23). Klasični ekonomisti, poput Smitha (1776.), Malthusa (1798.) i Ricarda (1819.), već su implicitno povezali gospodarski rast s inovacijama. U glavnoj struji ove klasične ekonomije, tehnologija se uvijek smatrala egzogenim čimbenikom. Schumpeter (1935., 1939.) je proširio ideju tehnološkog razvoja. Razvio je tvrdnju da se važne inovacije javljaju na početku gospodarskog oporavka i tvrdi je da su, osobito u vrijeme gospodarske krize, poduzeća spremna preuzeti rizike i otvoriti nove kanale za trgovinu. Znanstveni izumi i otkrića pretvaraju se u komercijalne inovacije kroz intuitivnost poduzetnika u procesu koji on naziva kreativnom destrukcijom. Grupiranje inovacija i širenje radikalnih tehnologija uzrokuju duge ekonomske cikluse (Geerlings i Wiegmans, 2018:333).

Ekonomist Robert Solow smatrao je teze klasične škole dvojbenima te je razvio svoj neoklasični model rasta koji se smatra začetkom moderne teorije rasta. U njegovom modelu naglasak je stavljen na moguću supstituciju između kapitala i rada u procesu proizvodnje (Solow, 1956). Solow je definirao da je pri istraživanju dugoročnog ekonomskog rasta potrebno obratiti pozornost na tri elementa: tehnologiju, kapital i rast. Njegov model zagovara da kontinuirani rast kapitalnih investicija samo privremeno povećava stopu rasta, jer se omjer kapitala i rada povećava. Granični proizvod dodatnih jedinica kapitala može se smanjiti zbog opadajućih prinosa te se tako gospodarstvo vraća u stanje dugoročnog rasta, s realnim bruto domaćim proizvodom koji raste istom brzinom kao i rast radne snage. Stanje stabilne ravnoteže gospodarstva postiže se kada proizvodnja, kapital i rad rastu istom brzinom, tako da su output po radniku i kapital po radniku konstantni (Riley, 2019).

Neoklasični ekonomisti vjeruju da povećanje stope rasta zahtijeva povećanje ponude radne snage i višu razinu produktivnosti rada i kapitala. Razlike u stopama rasta su objašnjene razlikama u tehnologiji između zemalja, no tehnologija je u njihovoj teoriji egzogena. Neoklasični model tretira poboljšanja produktivnosti kao egzogenu varijablu, odnosno pretpostavlja se da je produktivnost neovisna o iznosu kapitalnih ulaganja. Također se

pretpostavlja da zemlje koje kreću s niže razine razvijenosti imaju veće stope rasta od onih koje su naprednije tj. čije su stope rasta niže. Stoga teorija govori da siromašnije zemlje mogu sustići bogatije zemlje zbog veće granične stope povrata na uloženi kapital. Teorija predviđa određenu konvergenciju životnog standarda mjerenu prihodima po glavi stanovnika. Međutim, dovodi se u pitanje stupanj dostizanja višeg životnog standarda budući da rastuće ekonomije teško održavaju rast i povećanje dohotka po glavi stanovnika iznad određene razine (Riley, 2019). Ukoliko se gospodarstvo nalazi u stanju stabilne ravnoteže te nema tehnološkog napretka, tada nema porasta dohotka po stanovniku.

Jedna od pretpostavki neoklasičnog modela je da je tehnološki napredak egzogen tj. da na njega djeluju vanjske sile s čime se noviji teorijski doprinosi nisu slagali što je bio poticaj za razvitak modela endogenog rasta. Noviji teoretičari smatrali su kako je napredak u tehnologiji rezultat ljudskog rada te da se na njega može utjecati. Također, neoklasična teorija nije dala preporuke ekonomskoj politici za rješavanje problema sve slabijeg rasta zemalja s visokih dohotkom i stagnacije siromašnih zemalja što je također bio poticaj za kreiranje modela endogenog rasta.

Modeli endogenog rasta zagovaraju da je gospodarski rast rezultat endogenih sila unutar ekonomskog sustava što je u suprotnosti s idejama neoklasične teorije koje su gospodarskom rastu pripisivale snage koje djeluju izvan njega. Nadalje, pretpostavljaju da je tehnološki napredak endogen tj. da je rezultat ljudskog rada te radi toga pojedinci i poduzeća mogu imati monopolsku moć i zarađivati monopolsku rentu. Prva formulacija endogenog modela rasta pripisuje se Romeru (1986.), Lucasu (1988., 1993.) i Scottu (1991.) koji smatraju da nove investicije u kapital dovode do tehnološkog napretka zahvaljujući „učenju putem rada“. Novost je da se pod kapitalom misli na fizički i ljudski kapital koji smanjuje štetne posljedice rastuće količine kapitala po stanovniku te omogućuju da se granična proizvodnost kapitala ne smanjuje (Mervar, 1999:29).

Romer se u svojim daljnjim radovima (1992., 1993.) bavio idejama kao glavnim pokretačima ekonomskog rasta. Također, predložio je da se pojam ideja razlikuje od pojma ljudski kapital jer su ideje puno širi pojam od ljudskog kapitala koji predstavlja tek input u stvaranju novih ideja. Ideje vode prema većem nacionalnom proizvodu koji istovremeno vodi ka većim investicijama i većoj akumulaciji kapitala. Odnosno, ideje povećavaju produktivnost i uzrokuju akumulaciju kapitala. Kako bi se pomoglo zemljama u razvoju potrebno je poticati komunikaciju i razmjenu ideja između zemalja te je, prema Romeru, međunarodna trgovina ključni čimbenik u razmjeni ideja (Mervar, 1999:31). No, u navedenom prijedlogu širenja ideja

postoji dilema: prvenstveno, kako bi se manje razvijene zemlje mogle razvijati potrebno je širiti nove ideje, no s druge strane postavlja se pitanje tko će financirati stvaranje novih ideja. Stvaranje novih ideja zahtijeva mnogo sredstava koja se ulažu u istraživanje i razvoj. Razvoj prve ideje je veoma skup, dok je njeno kopiranje relativno jeftino što ostali akteri mogu učiniti i na taj način raditi na vlastitom napretku a da pritom nisu potrošili mnogo sredstava.

Postoje alati koji omogućavaju ograničavanje širenja novih ideja te su jedni od njih patenti. Patenti omogućavaju privremeni monopol te se imitatorima onemogućuje imitiranje i nadograđivanja postojeće ideje. Prethodno navedena dilema jasno se može očitati kod patenata gdje s jedne strane postoji potreba kreiranja novih ideja te kreatori ideje žele da ona ostane pod njihovim okriljem, dok s druge strane postoji potreba širenja novih ideja za napredak nerazvijenih zemalja. Jedno od rješenja navedene dileme mogu biti subvencije sveučilištima i drugim institucijama za istraživanje i razvoj. Nakon što institucije razviju nove ideje, one su javno dostupne. Suvremena tehnologija, Internet, online edukcije i slično kao i trgovinska otvorenost omogućuju brzo širenje ideja te mogućnost razvoja novih ideja kroz nadogradnju tuđih ideja.

2.2. Vrste modela endogene teorije rasta

Modeli endogenog rasta nastali su u osamdesetim godinama dvadesetog stoljeća te se i dalje unaprjeđuju i mijenjaju stoga formalna podjela modela ne postoji, no mogu se obuhvatiti glavne karakteristike određenih skupina modela.

Radi lakšeg pregleda modeli će se razvrstati u tri skupine prema Mervar (2003.):

1. AK modeli
2. Modeli zasnovani na eksternalijama
3. Modeli zasnovani na istraživanju i razvoju

AK modeli najjednostavniji su modeli gospodarskog rasta te objašnjavaju gospodarski rast isključivo kroz akumulaciju kapitala. Pod kapitalom se misli na fizički i ljudski kapital. U ovom tipu modela smatra se da poduzeća stalo povećavaju količinu kapitala u savršeno konkurentnim tržištima što vodi ka većem ekonomskom rastu. Pretpostavka savršene konkurencije veže za sebe pretpostavku da kapital mora biti plaćen prema svome graničnom proizvodu koji ne smije biti niži od eskontne stope (Mervar, 2003:384). Stoga se određuje donja granica za prinose na

kapital čime se osigurava da investicije ostaju profitabilne te nisu podložne zakonu opadajućih prinosa.

Modeli zasnovani na eksternalijama najbliži su neoklasičnom modelu jer zagovaraju da na gospodarski rast utječu investicije i akumulacija kapitala. Objašnjavaju da nove investicije u kapital dovode do tehnološkog napretka zahvaljujući eksternalijama. Razlika u odnosu na neoklasični model je u tome što se pod kapitalom ne smatra samo fizički kapital već i ljudski kapital. Pretpostavlja se da se ljudski kapital akumulira kroz formalno obrazovanje, učenje na poslu ili učenje kroz rad *(eng. learning by doing)* te je on uzrok rastućim prinosima i stvara mogućnost neograničenog gospodarskog rasta. Pojedini subjekti akumulacijom kapitala pridonose porastu proizvodnosti kapitala drugih subjekata, odnosno tu se može sagledati utjecaj eksternalija. Model pretpostavlja tržište savršene konkurencije te ne postoji monopolska moć koja dovodi do profita. Nadalje, model zagovara da gospodarstva koje više investiraju u fizički i ljudski kapital, rastu brže u dugom roku te se investicijama u fizički i ljudski kapital osigurava da se granična proizvodnost kapitala ne smanjuje. Navedeno znači da bogate zemlje mogu stalno rasti, a siromašne zemlje mogu zauvijek ostati siromašne.

Polazišna ideja modela zasnovanim na eksternalijama potekla je od Arrowa (1962.) i njegove hipoteze o učenju kroz rad odnosno nastanku novih ideja pri korištenju starih. Smatrao je da pojedinci uče iz iskustva drugih te se njihova učinkovitost mjeri proizvedenom količinom. Razlike u akumuliranom znanju mogu objasniti razlike između različitih stopa rasta gospodarstava. Paul Romer vezao se na Arrowov model te je 1986. godine izradio vlastiti model kojem je dodao hipotezu o prelijevanju znanja, odnosno smatrao je da nakon što nastane novo znanje, ono postaje besplatno i svima dostupno. Ulaganje u fizički i ljudski kapital mogu iskoristiti i druga poduzeća, stoga svi zajedno nisu suočeni s opadajućim prinosima na opseg. Najbitnija stavka Romerovog modela jest novo znanje za koje je pretpostavio da je generator eksternalija te je tehnološki napredak poistovjetio upravo s novim znanjem (Mervar, 2003:374).

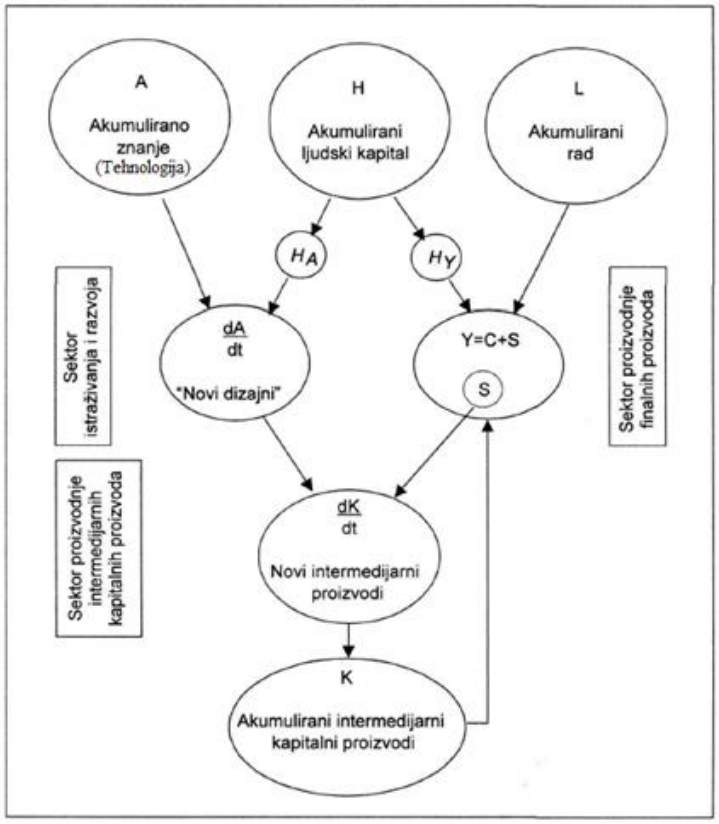
Nedostatak ovakve formulacije modela jest definiranje tehnološkog razvoja koji je tek slučajni rezultat ekonomske aktivnosti poduzeća. U stvarnosti, novo znanje i ideje rezultat su rada i ulaganja pojedinaca te je vrlo mali dio novih otkrića dobiven slučajnim putem. Nadalje, nedostatak modela je također i pretpostavka savršene konkurencije. Navedene nedostatke Romer je otklonio u svojim daljnjim radovima.

Modeli zasnovani na istraživanju i razvoju započeti su Romerovim modelom (1990.) koji se nadograđivao na Schumpeterove (1942.) ideje. Nakon Romera, modele su također razvili Grossman i Helpman (1990. i 1991.) i Aghion i Howitt (1992.). Ovi modeli odvajaju se od pretpostavke savršene konkurencije te uvode mogućnost postojanja monopola. U savršenoj konkurenciji svi sudionici imaju mogućnost korištenja novih znanja i novih inovacija koje je netko drugi razvio te pojedinci nemaju poticaj razvijati inovacije budući da nemaju zarade od njih. Ukoliko postoji mogućnost monopola i monopolske rente, poticaj za inoviranjem je veći.

U modelima zasnovanim na istraživanju i razvoju pretpostavlja se da postoji odvojeni tehnološki sektor koji razvija nove tehnologije te ostali subjekti mogu kupiti njihove izume. Zbog odmaka od savršenog tržišta, proizvođači tehnologija mogu naplaćivati cijenu koja je viša od graničnog troška proizvodnje. Stopa rasta gospodarstva ovisi o količini sredstava koja su namijenjena istraživanju i razvoju te stupnju do kojeg tehnologije mogu biti privatno korištene (Mervar, 2003:379). Romerov model stoga pretpostavlja da gospodarski rast pokreću tehnološke promjene te da se do tehnoloških promjena dolazi promišljenim akcijama pojedinaca, a ne slučajnim događajima na tržištu kako je to bio slučaj u neoklasičnim modelima.

Romerov model iz 1990. godine ima četiri osnovna faktora proizvodnje: fizički kapital, rad, ljudski kapital te tehnologiju. Nadalje, njegov model ima tri sektora: istraživački sektor, sektor proizvodnje intermedijarnih dobara te sektor finalnih dobara. Detaljniji prikaz odnosa u sektorima može se vidjeti na sljedećoj shemi.

Shema 1. Romerov model zasnovan na istraživanju i razvoju



Izvor: Valdés, 1999; Mervar, 2003

Istraživački sektor koristi se ljudskim kapitalom i postojećom razinom akumuliranog znanja tj. tehnologijom kako bi proizveo novo znanje. Sektor proizvodnje intermedijarnih dobara koristi se „novim dizajnima“ stvorenim u istraživačkom sektoru te prije stvorenim proizvodom finalnog sektora koji nije potrošen. Nadalje, sektor finalnih dobara koristi se radom, ljudskim kapitalom i intermedijarnim dobrima da bi proizveo finalna dobra. Ovaj model implicira da stopu dugoročnog ravnotežnog rasta određuje razina akumuliranog ljudskog kapitala, da je pri stabilnoj ravnoteži premalo ljudskog kapitala namijenjeno istraživanju i da integracija gospodarstva u globalno tržište povećava stopu rasta (Valdés, 1999).

U odnosu na modele u kojima se dolazi do novih otkrića i razvoja novih proizvoda, postoje i modeli gdje se pretpostavlja unaprjeđenje proizvoda tj. zamjena starih za nove. Nakon što se stvori novi dizajn proizvoda, poduzeće koje se prvo njime počinje koristiti, zauzeti će dio tržišta. Novi proizvodi kvalitetniji su ili se mogu prodavati po nižoj cijeni što je konkurentska prednost pojedinca te se smatra kako je svaki proizvod moguće unaprijediti beskonačno mnogo puta.

2.3. Važnost razvoja novih ideja za rast gospodarstva

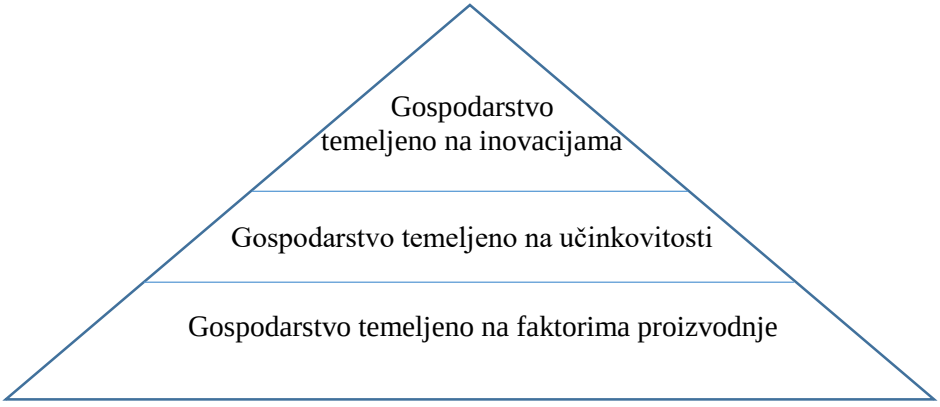
Inovacije se mogu definirati kao razvijanje nove ideje ili novog pristupa te mogu biti dvojake: inovacije procesa i inovacije proizvoda. Inovacije procesa poboljšavaju proizvodne procese što rezultira manjim utroščima prilikom proizvodnje proizvoda. Inovacije proizvoda vezane su uz razvoj novih proizvoda koji zadovoljavaju potrebe kupaca. Kroz proces inovacija resursi dobivaju nova svojstva te inovacije generiraju nove djelatnosti i novu uspostavu vrijednosti. Tim procesom se znanje pretvara u novu vrijednost, a nova vrijednost postaje temeljem konkurentnosti na dinamičnim tržištima (Sundać et al., 2016:123).

Inovacije stvaraju poticaje za dugoročni rast jer stvaraju mogućnosti za poboljšanje produktivnosti. Inovacijom procesa postiže se da je za proizvodnju istog proizvoda potrebno kraće vrijeme ili manje resursa što dovodi do veće efikasnosti i produktivnosti. Nadalje, inovacije omogućuju da se pomakne granica proizvodnih mogućnosti. Ukoliko gospodarstva posluju na granici proizvodnih mogućnosti gdje su svi resursi angažirani, uvođenjem inovacije granica se može pomaknuti te se može proizvoditi više. Nadalje, iz inovacija mogu proizaći određene društvene koristi kao što su pozitivne eksternalije zbog učinka prelijevanja tehnologije koja je nastala inovacijama. Primjenom novih tehnologija može se primjerice djelovati na smanjenje emitiranja štetnih plinova, što se može primijeniti u morskim lukama i njihovom poslovanju kako bi se poboljšala briga za okoliš.

Tehnologija mora biti uvedena na tržište i mora biti prihvaćena od strane potencijalnih korisnika. Klasičan pristup usvajanju tehnologije je model: izum – inovacija – difuzija koji se temelji na radu Schumpetera. Ovaj se model temelji na specifičnoj interpretaciji tehnološkog razvoja, odnosno na identifikaciji triju različitih stupnjeva razvoja tehnologije: izum, inovacija i difuzija. U prvoj fazi izuma razvija se nova ideja ili tehnika te nije nužan uvjet da će tehnologija ikada biti primijenjena ili ostvariti komercijalni uspjeh već je fokus na znanosti i inženjeringu. Druga faza je faza inovacije te je ovdje pozornost usmjerena na uspješno uvođenje tehnologije na tržište. Uvođenje se može odvijati iz komercijalnih razloga, ali može biti i zbog drugih razloga (energetska politika, zakonodavstvo vezano uz okoliš itd.). Posljednja faza modela je faza difuzije gdje se inovacija širi na veliki broj usvojitelja. Ova konceptualna razlika teško se može naći u praksi kao jasan trenutak u vremenu: izum je u mnogim slučajevima definiran kao inovacija, a difuzija u mnogim slučajevima uključuje daljnje inovacije i tako dalje (Geerlings i Wiegmans, 2018:333).

Tehnološke promjene mogu biti velikog obujma, no istodobno proces inovacija može biti diskontirani proces malih poboljšanja te jedan pristup ne isključuje drugi. Geerlings (1998.) smatra da bi kumulativni rezultat malih tehnoloških inovacija mogao biti značajniji nego rezultat iznenadnog velikog tehnološkog napretka. Inovacije nisu automatski superiornije od starih tehnologija već tokom određenog vremena moraju dokazati svoju vrijednost. U procesu učenja uvode se daljnja poboljšanja koja novu tehnologiju čine prikladnom za specifično okruženje u kojem se ona mora koristiti (Geerlings i Wiegmans, 2018:334). Svjetski ekonomski forum *(eng. World Economic Forum WEF)* razlikuje tri faze razvoja gospodarstva, svaka sa sve većim fokusom na inovacijama. Faze razvoja mogu se vidjeti na sljedećoj shemi.

Shema 2. Piramida ekonomskih razvojnih faza



Izvor: Prilagodila autorica prema Van den Bosch *et al.*, 2011, bazirano na Svjetskom ekonomskom forumu *(eng. WEF)* i izvješćima o globalnoj konkurentnosti

Što se zemlja nalazi više na piramidi, to je njena globalna konkurentnost veća tj. zemlje s gospodarstvom koje se temelji na inovacijama smatraju se konkurentnijima od zemalja koje se uglavnom temelje na učinkovitosti ili na faktorima proizvodnje. Nadalje, zemlje se mogu nalaziti i u procesu tranzicije između jedne od tri navedene faze. Navedeno se može primijeniti i na različit stupanj razvijenosti regija tj. što se neka regija nalazi više na piramidi, to je njena konkurentnost veća.

Tehnologija se vrlo brzo unaprjeđuje te postaje temeljni katalizator gospodarskog rasta. Regije s najvišim tehnološkim kapacitetom stvaraju veće gospodarske prednosti povezane s promjenama u metodama proizvodnje i potražnjom na tržištu. Stoga se smatra da će regije koje intenzivno ulažu u razvoj tehnologije rasti brže nego ostale regije, ne samo zbog visokih prinosa vezanih uz tehnologiju, nego i zbog učinaka multiplikatora koje stvaraju inovacijski centri i

njihove asimilacijske sposobnosti na nova tehnološka dostignuća (Rodríguez-Pose, 1999:76). Tehnološko znanje se nakon korištenja ne iscrpljuje već se kumulira jer se temelji na postojećem znanju. Ono također u većini slučajeva uzrokuje prelijevanje iz područja gdje je nastalo na ostala područja.

2.3.1. Karakteristike područja sklonih inovacijama

Ulaganje u istraživanje i razvoj povećava mogućnost postizanja višeg tehnološkog standarda u poduzećima i regijama, što potencijalno omogućuje uvođenje novih proizvoda ili procesa te rezultira višim razinama prihoda i rastom. No, tehnologija se ne može slobodno prenijeti iz jednog okruženja u drugo već mora biti adekvatno usvojena. Tehnološki razvoj je specifičan za određeno vrijeme, određeni sektor i određenu lokaciju (Geerlings i Wiegmans, 2018:334). Razvoj tehnologije u velikoj mjeri ovisi o kulturnim i organizacijskim čimbenicima te se može reći da nisu sva područja sklona inovacijama i da postoje određene karakteristike koje su povoljne za poticanje i prihvaćanje inovacija. Autor Rodríguez-Pose (1999:80) objašnjava kako postoje različiti „društveni filteri“ u različitim regijama koji stvaraju drugačije preduvjete za implementaciju inovacija u gospodarsku aktivnost. Neki od preduvjeta su demografska i obrazovna dostignuća, nezaposlenost i ekonomska struktura područja koje imaju različit, pozitivan ili negativan, utjecaj na razvoj i implementaciju inovacija.

Obrazovna dostignuća povezana su s ljudskim kapitalom te se smatra da je istraživanje i razvoj neprofitabilno za niske razine ljudskog kapitala. Stoga je potrebno uz ulaganje u istraživanje i razvoj imati i kvalitetan ljudski kapital koji će inovaciju prihvatiti i implementirati u stvarnost. Situacija na tržištu rada također može utjecati na inovacijski proces. Niska razina zaposlenosti negativno je povezana sa spremnošću na inoviranje (Rodríguez-Pose, 1999:96). Zaposleno stanovništvo će biti spremnije učiti i uvoditi promjene te prihvaćati nove inovacije od nezaposlenog stanovništva. Nezaposlenost mladog stanovništva predstavlja ozbiljnu društvenu prepreku za asimilaciju inovacija. Ukoliko mladi, dinamičniji i često bolje pripremljeni budući radnici ostaju izvan tržišta rada, često su prisiljeni migrirati, dok radno stanovništvo stari.

Ekonomska struktura regije također je važna za poticanje i implementiranje inovacija. Pretežno poljoprivredne regije imati će manju sklonost inovacijama budući da poljoprivredni sektor u cjelini ne pokazuje tendencije ka inoviranju kao neki drugi sektori. S druge strane, regije koje se bave određenim proizvodnim i uslužnim djelatnostima, sklonije su inoviranju, posebice regije koje se oslanjaju na tehnološki napredne sektore (Bilbao-Osorio i Rodriguez-Pose,

2004:438). Nadalje, čimbenik koji može djelovati na regionalnu sklonost ili nesklonost inovacijama jest mogućnost prelijevanja novih znanja i ideja na susjedne regije. Budući da su znanje i ideje općenito javna dobra te postoje poteškoće u njihovom prisvajanju, određena područja mogu odlučiti ne inovirati te biti slobodni jahači koji besplatno koriste tuđe ideje i nova saznanja.

Društva sklona inovacijama su sposobna transformirati veći dio istraživanja i razvoja u inovacije i gospodarske aktivnosti. Ona su otvorenija prema vanjskim inovacijama te je njihov društveni filtar iznimno propustan za inovacije i promjene. Društveni filtar je čimbenik koji omogućuje glatku transformaciju ne samo novih proizvoda u gospodarsku aktivnost, nego također pogoduje inovacijama procesa jer doprinosi većoj fleksibilnosti proizvodnog procesa. Nadalje, većina područja ima umjereni društveni filtar gdje je sposobnost i spremnost prihvaćanja inovacija nešto manje razvijena te je prijelaz iz istraživanja i razvoja u stvarne inovacije stoga manje brz. U većini područja koja su umjereno sklona inovacijama, ulaganja u istraživanje i razvoj donijet će svoj udio povrata ali on će biti nešto manji od povrata u područjima sklonima inovacijama. Konačno, postoje i društva koja nisu sklona inovacijama te čiji je društveni filtar gotovo nepropustan. Takva društva nemaju kapacitete za pretvaranje inovacija u gospodarsku aktivnost te će ulaganja u istraživanje i razvoj u tim područjima donijeti niže prinose nego ulaganja u područjima sklonim inovacijama (Rodríguez-Pose, 1999:82).

Inovacija je, između ostaloga, kolektivno učenje i društveno ugrađeni proces stoga postoji veza između inovacija i regija u kojima se odvijaju. Iako su regije sa svojim društvenim, kulturnim i institucionalnim područjem presudne za uspješne inovacije; inovacije su zauzvrat ključni izvor konkurentske prednosti za pripadajuće regije.

2.3.2. Analiza ulaganja u istraživanje i razvoj u Europskoj uniji

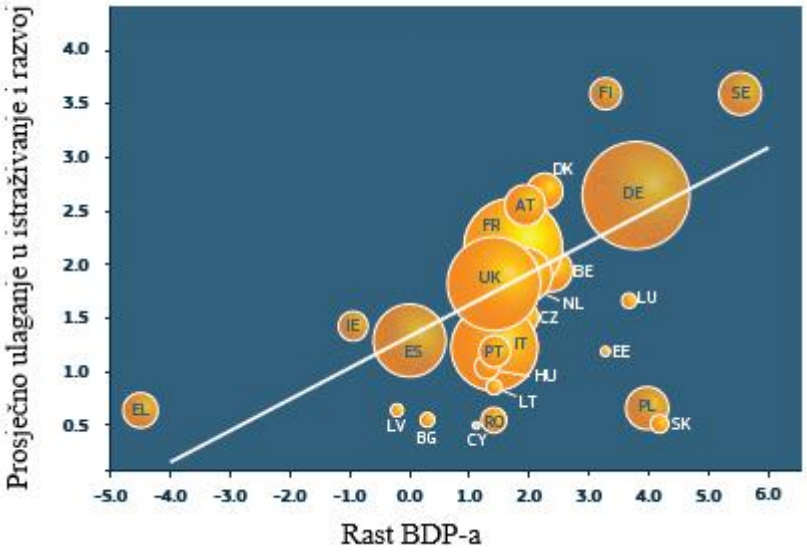
U procesima tehnoloških inovacija uz sama poduzeća, važnu ulogu igra i država. Postoje razne vrste odnosa između poduzeća i države u kojima se potiče ulaganje u istraživanje i razvoj te razvijanje inovacija. Na globalnoj razini postoje značajne razlike u oblicima suradnje između poduzeća i države. U Europskoj uniji ta je suradnja relativno nedovoljno definirana i poticana. Europska tehnološka politika je vrlo diverzificirana te postoji mala koordinacija između tehnoloških politika pojedinih država članica. Europski sustav karakteriziraju nacionalno fragmentirani proizvodni sustavi i standardi te oni većinom prate svoje nacionalne politike.

Uspostavljanje zajedničke tehnološke politike Europske unije teško je dijelom zato što ne postoji jasno definiran zajednički interes. Provedbom programa Obzor 2020 djelomično se otklonio nedostatak te je stvoren poticaj za zajedničku suradnju. Unutar cjelovitog programa postoje brojni nezavisni programi u koje su uključene i luke, pomorska logistika i održivi promet (Geerlings i Wiegmans, 2018:336). Nadalje, kao dio svog programa vezanog za istraživanje i inovacije, Europska komisija je u 2016. godini u sklopu programa Obzor 2020 pokrenula inicijativu pod nazivom „Luka budućnosti" kako bi se potaknule inovacije u lukama (European Commission, 2015).

Europske lučke regije biti će glavni uzorak istraživanja disertacije stoga je potrebno sagledati kako Europska unija i njene zemlje članice percipiraju ulaganje i primjenu istraživanja i razvoja. Europska unija stavlja inovacije u središte svojih strategija za poticanje rasta i stvaranja radnih mjesta te je razvila i posebnu strategiju nazvanu Inovacijska unija (*eng. Innovation Union*). Strategija potiče zemlje članice da ulažu 3% BDP-a u istraživanje i razvoj do 2020. godine. Očekuje se ulaganje od 1% iz javnog sektora te 2% iz privatnog sektora čime se predviđa otvaranje 3,7 milijuna radnih mjesta te viši BDP Europske unije za 800 milijardi eura (European Union, 2019). Europska unija stavlja naglasak na rješavanje izazova vezanih za energiju, hranu, klimatske promjene te sve starije stanovništvo. Ideja je da se s pomoću javnog sektora podupire privatni sektor čime se omogućuje lakši protok ideja na tržište. Potpore uključuju financijska sredstva, javne nabave za inovacije te ubrzanje postavljanja standarda. Europska unija, također želi stvoriti i jedinstveno europsko istraživačko područje koje će podržavati i poticati prekograničnu suradnju, a istraživači će moći raditi bilo gdje u Europi.

Prema informacijama Europske komisije, zemlje koje više ulažu u istraživanje i razvoj brže su se oporavile od svjetske ekonomske krize što se može vidjeti i na sljedećem grafikonu (European Commission, 2013:6).

Grafikon 1. Usporedba BDP-a s prosječnim ulaganjem u istraživanje i razvoj u Europskoj uniji



Izvor: European Commission, 2013:6

Rast bruto domaćeg proizvoda pozitivno je povezan s prosječnim ulaganjem u istraživanje i razvoj te i sama Europska unija smatra kako je potrebno razvijati inovacije koje će dovesti do dugoročnog rasta. Budući da će u istraživanje biti uključeno 107 lučkih regija Europske unije, prikazivanje podataka za svaku regiju zasebno bilo bi preopširno. Stoga će se u nastavku prikazati podaci o ulaganju u istraživanje i razvoj na agregatnoj razini. U sljedećoj tablici mogu se vidjeti podaci o ulaganju u istraživanje i razvoj od 2008. do 2017. godine te cilj koji je Europska komisija postavila za svaku zemlju. Također je izračunat i indeks koji uspoređuje zadnju promatranu godinu s prvom promatranom godinom u tablici.

Tablica 1. Ulaganja u istraživanje i razvoj u zemljama Europske unije (% od BDP-a)

ZEMLJA	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	CILJ	INDEKS 2017./2008.
Belgija	1,92	1,99	2,05	2,16	2,27	2,33	2,39	2,46	2,55	2,58	**3,00**	134,38
Bugarska	0,45	0,49	0,56	0,53	0,60	0,64	0,79	0,96	0,78	0,75	**1,50**	166,67
Češka	1,24	1,29	1,34	1,56	1,78	1,90	1,97	1,93	1,68	1,79	**1,00**	144,35
Danska	2,77	3,06	2,92	2,94	2,98	2,97	2,91	3,06	3,1	3,05	**3,00**	110,11
Njemačka	2,60	2,72	2,71	2,80	2,87	2,82	2,87	2,91	2,92	3,02	**3,00**	116,15
Estonija	1,26	1,40	1,58	2,31	2,12	1,72	1,43	1,47	1,25	1,29	**3,00**	102,38
Irska	1,39	1,61	1,59	1,56	1,56	1,56	1,50	1,19	1,19	1,05	**2,00**	75,54
Grčka	0,66	0,63	0,60	0,67	0,70	0,81	0,83	0,96	0,99	1,13	**1,20**	171,21
Španjolska	1,32	1,35	1,35	1,33	1,29	1,27	1,24	1,22	1,19	1,2	**2,00**	90,91
Francuska	2,06	2,21	2,18	2,19	2,23	2,24	2,23	2,27	2,25	-	**3,00**	-
Hrvatska	0,88	0,84	0,74	0,75	0,75	0,81	0,78	0,84	0,86	0,86	**1,40**	97,73
Italija	1,16	1,22	1,22	1,21	1,27	1,31	1,34	1,34	1,37	1,35	**1,53**	116,38
Cipar	0,39	0,44	0,45	0,46	0,44	0,48	0,51	0,48	0,53	0,56	**0,50**	143,59
Latvija	0,58	0,45	0,61	0,70	0,66	0,61	0,69	0,63	0,44	0,51	**1,50**	87,93
Litva	0,79	0,83	0,78	0,90	0,89	0,95	1,03	1,04	0,84	0,89	**1,90**	112,66
Luksemburg	1,62	1,68	1,50	1,46	1,27	1,30	1,26	1,28	1,30	1,26	**2,30**	77,78
Madžarska	0,98	1,13	1,14	1,19	1,26	1,39	1,35	1,36	1,20	1,35	**1,80**	137,76
Malta	0,53	0,52	0,61	0,67	0,83	0,77	0,71	0,74	0,57	0,54	**2,00**	101,89
Nizozemska	1,62	1,67	1,70	1,88	1,92	1,93	1,98	1,98	2,00	1,99	**2,50**	122,84
Austrija	2,57	2,60	2,73	2,67	2,91	2,95	3,08	3,05	3,13	3,16	**3,76**	122,96
Poljska	0,60	0,66	0,72	0,75	0,88	0,87	0,94	1,00	0,96	1,03	**1,70**	171,67
Portugal	1,45	1,58	1,53	1,46	1,38	1,33	1,29	1,24	1,28	1,33	**2,70**	91,72
Rumunjska	0,55	0,44	0,46	0,5	0,48	0,39	0,38	0,49	0,48	0,50	**2,00**	90,91
Slovenija	1,63	1,82	2,06	2,42	2,57	2,58	2,37	2,2	2,01	1,86	**3,00**	114,11
Slovačka	0,46	0,47	0,62	0,66	0,80	0,82	0,88	1,17	0,79	0,88	**1,20**	191,30
Finska	3,55	3,75	3,73	3,64	3,42	3,29	3,17	2,89	2,74	2,76	**4,00**	77,75
Švedska	3,49	3,45	3,21	3,25	3,28	3,30	3,14	3,26	3,27	3,40	**4,00**	97,42
Ujedinjeno Kraljevstvo	1,62	1,68	1,66	1,66	1,59	1,64	1,66	1,67	1,68	1,66	-	102,47

Izvor: Izradila autorica prema European Commission, 2018c

Iz tablice se može vidjeti da su Švedska, Austrija, Danska i Njemačka zemlje koje ulažu najveći postotak svog bruto domaćeg proizvoda u istraživanje i razvoj. S druge strane, najmanji postotak bruto domaćeg proizvoda u istraživanje i razvoj ulažu Rumunjska, Latvija, Malta i Cipar. U tablici je prikazan i cilj koji je Europska komisija postavila za svaku od svojih zemalja članica te se cilj usporedio sa zadnjom promatranom godinom i na temelju postignuća označio pripadajućom bojom. Zelena označava zemlje koje su dostigle i premašile navedeni cilj, narančasta zemlje koje su relativno blizu ostvarenju cilja dok su crvenom bojom označene zemlje koje nisu blizu ostvarenja cilja. Češka, Danska, Njemačka i Cipar ostvarile su ciljeve Europske komisije te je potrebno naglasiti kako se Danska i Njemačka također nalaze među zemljama koje najviše ulažu u istraživanje i razvoj.

Zadnji stupac u tablici uspoređuje zadnju promatranu 2017. godinu s prvom promatranom godinom 2008. te su izračunati indeksi povećanja ili smanjenja ulaganja u istraživanje i razvoj. Slovačka bilježi najveće povećanje ulaganja u istraživanje i razvoj tokom deset promatranih godina od 91,30%. Znatna povećanja ulaganja u istraživanje i razvoj također imaju i Poljska (71,67%), Grčka (71,21%) te Bugarska (66,67%). Najveće smanjenje ulaganja u istraživanje i razvoj tokom promatranih deset godina imaju Irska (24,46%), Finska (22,25%) te Luksemburg (22,22%).

Ulaganje u istraživanje i razvoj potrebno je povezati i s ljudskim resursima koji rade u tom sektoru, stoga su u nastavku dane informacije o ljudskim resursima koji su zaposleni u znanosti i tehnologiji u zemljama Europske unije. Razdoblje promatranja je isto kao i kod ulaganja u istraživanje i razvoj tj. desetogodišnje razdoblje od 2008. do 2017. godine.

Tablica 2. Ljudski resursi u znanosti i tehnologiji u zemljama Europske unije (% aktivnog stanovništva)

ZEMLJA	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	INDEKS 2017/2008
Belgija	47,00	48,20	49,30	49,60	50,30	49,60	51,10	50,50	51,10	54,30	115,53
Bugarska	31,40	31,80	32,10	32,70	32,80	34,00	35,40	36,30	36,80	36,50	116,24
Češka	37,10	37,90	37,80	35,90	36,60	37,20	38,10	38,10	38,70	39,60	106,74
Danska	49,40	50,00	51,00	51,50	52,90	53,50	54,00	54,50	54,80	56,40	114,17
Njemačka	44,00	44,90	45,70	44,80	46,40	46,80	47,00	47,70	48,40	48,70	110,68
Estonija	44,40	45,90	45,20	47,30	49,20	48,90	48,90	49,30	49,10	50,30	113,29
Irska	44,50	46,20	47,50	50,30	51,90	52,80	53,10	54,20	54,90	56,60	127,19
Grčka	31,90	32,00	32,50	33,70	34,30	35,10	35,40	36,10	37,40	38,50	120,69
Španjolska	38,90	38,80	39,60	40,10	40,40	41,20	42,20	42,70	43,40	44,30	113,88
Francuska	42,60	43,50	43,80	47,40	48,10	48,90	49,10	49,90	50,50	50,80	119,25
Hrvatska	29,00	30,30	31,60	29,80	31,50	34,50	35,10	36,20	37,40	38,20	131,72
Italija	35,40	34,40	34,00	34,60	34,70	34,80	35,00	35,50	35,70	36,30	102,54
Cipar	43,70	43,00	44,00	47,10	48,50	47,90	48,80	49,30	50,60	50,90	116,48
Latvija	39,40	38,70	38,00	38,20	40,10	41,20	40,70	42,40	43,30	44,40	112,69
Litva	42,30	41,70	42,70	43,60	43,90	45,60	46,50	48,20	49,10	49,40	116,78
Luksemburg	45,50	55,50	56,20	57,30	58,90	61,10	64,50	58,80	59,60	57,60	126,59
Madžarska	33,30	33,30	33,00	34,60	35,60	36,00	36,30	36,70	36,30	36,50	109,61
Malta	32,20	32,70	32,60	35,30	37,60	39,00	39,50	40,20	40,30	42,80	132,92
Nizozemska	49,00	49,60	50,90	51,80	52,10	52,70	52,80	53,60	54,60	55,30	112,86
Austrija	37,70	38,90	39,10	40,40	41,70	43,00	48,30	48,60	49,10	50,10	132,89
Poljska	33,40	34,90	35,90	36,60	37,70	39,00	40,40	41,60	42,80	44,00	131,74
Portugal	23,00	23,50	23,90	26,90	28,70	30,00	33,00	34,80	36,20	36,40	158,26
Rumunjska	23,80	24,10	24,00	25,40	25,50	25,10	25,60	27,00	27,60	27,70	116,39
Slovenija	40,10	40,60	40,80	42,40	42,80	43,50	43,70	45,10	46,50	47,80	119,20
Slovačka	32,00	32,00	33,50	33,90	32,50	32,50	32,90	33,50	34,20	35,20	110,00
Finska	49,80	50,40	51,40	52,60	53,60	54,60	55,60	56,50	56,90	57,70	115,86
Švedska	49,30	49,70	50,30	51,70	52,60	53,80	55,10	56,20	57,90	58,60	118,86
Ujedinjeno Kraljevstvo	43,70	44,60	46,30	52,40	53,30	54,10	54,60	55,50	56,90	57,10	130,66

Izvor: Izradila autorica prema European Commission, 2018d

U zadnjoj promatranoj 2017. godini, najviše ljudskih resursa u znanosti i tehnologiji bilo je zaposleno u Švedskoj (58,60%), Luksemburgu (57,60%) te Ujedinjenom Kraljevstvu (57,10%). Najmanje zaposlenih u znanosti i tehnologiji bilo je u Rumunjskoj (27,70%), Italiji (36,30%) te Portugalu (36,40%). Ukoliko se sagleda indeks koji uspoređuje zadnju promatranu 2017. godinu s prvom promatranom 2008. godinom, može se vidjeti da se najveće povećanje od 58,26% desilo upravo u Portugalu koji spada pod zemlje Europske unije koje imaju najmanje zaposlenih u znanosti i tehnologiji. Iz navedenog se može zaključiti kako Portugal radi na povećanju zaposlenosti u tehnološkom i znanstvenom sektoru.

Niti jedna zemlja nema smanjenje zaposlenosti u znanosti i tehnologiji tokom promatranih 10 godina, no nešto manje promjene uočene su kod Italije (2,54%), Češke (6,74%) te Madžarske (9,61%). Navedene zemlje također imaju rast zaposlenih u znanstvenom i tehnološkom sektoru, no u odnosu na ostale promatrane zemlje on je manji. Ukoliko se usporede podaci o ulaganjima u istraživanje i razvoj te ljudskim resursima koji su zaposleni u tom sektoru, može se vidjeti kako zemlje koje najviše ulažu u istraživanje i razvoj također imaju i relativno visok postotak zaposlenih u navedenom sektoru (Danska, Njemačka, Austrija i Švedska). Rumunjska uvelike negativno odskače od ostalih zemalja Europske unije kako u ulaganju u istraživanje i razvoj tako i u zaposlenosti u znanosti i tehnologiji (27,70% u 2017. godini).

Pretvaranje inovacija u ekonomski rast nije jednostavan proces budući da se u otvorenim gospodarstvima događaju značajna prelijevanja i mobilnost inovacija. Područja koja su sposobna brzo se prilagoditi na inovaciju koja je proizvedena na nekom drugom području, mogu imati značajne koristi s vrlo malim ili gotovo nikakvim troškom. Navedeno može smanjiti utjecaj ulaganja istraživanja i razvoja određene regije na vlastiti gospodarski rast (Rodríguez-Pose, 1999:89). No, pretpostavlja se da pozitivni efekti ulaganja u istraživanje i razvoj ipak premašuju negativne što će se i testirati kasnije u istraživanju.

2.4. Važnost ljudskog kapitala za rast gospodarstva

Literatura koja se bavi gospodarskim rastom u sklopu endogene teorije rasta smatra ljudski kapital, uz razvoj novih ideja, primarnim izvorom gospodarskog rasta (Lucas Jr., 1988; Bronzini i Piselli, 2009). Tvrdi se da razina obrazovanja potiče rast jer povećava sposobnost prilagodbe i primjene postojeće tehnologije ili stvaranje nove tehnologije. Teorijske analize naglasile su stratešku komplementarnost između ljudskog kapitala i aktivnosti istraživanja i razvoja. Smatra se da su ulaganje u istraživanje i razvoj i ljudski kapital međuovisni i

komplementarni te zajednički određuju ravnotežu rasta. Istraživanje provedeno od autora Karaman Aksentijević i Ježić (2009) također potvrđuje da kvalitetni ljudski resursi osiguravaju tehnološki napredak te da razvoj, primjena i širenje novih tehnoloških dostignuća izravno utječu na gospodarski rast zemlje.

Osnova ljudskog kapitala leži u teorijama Theodora Schultza koji je dokazao da je društvena stopa povrata ulaganja u ljudski kapital u američkom gospodarstvu veća od one temeljene na fizičkom kapitalu, kao što su nova postrojenja i strojevi. Rezultati Shultzovih istraživanja pokazuju da ulaganja u ljude povećavaju bogatstvo gospodarstva stoga on smatra kako manje razvijene zemlje mogu napredovati upravo ulaganjem u obrazovanje (Schultz, 1961). Navedenu teoriju nadogradio je Gary Becker objašnjavajući da bi se troškovi za obrazovanje, obuku i medicinsku skrb mogli smatrati ulaganjem u ljudski kapital. Nadalje, smatrao je kako se ljudi ne mogu odvojiti od svojih znanja, vještina, zdravlja ili vrijednosti na način na koji se mogu odvojiti od svoje financijske i fizičke imovine (Becker, 1962). Stoga obrazovanje i vještine ljudi doprinose kvalitetnom ljudskom kapitalu. U ovome segmentu važna je kvaliteta radne snage, a ne kvantiteta, odnosno važne su vještine kojima radnik može doprinijeti većoj produktivnosti u poslovanju.

Tehnički napredak stavlja pred svaku zajednicu potrebu da svoje snage usmjerava u pravcu razvoja znanosti, tehnike i tehnologije u svrhu povećanja proizvodnosti rada što posljedično dovodi do povećanja proizvodnje dobara i usluga, a time i do poboljšanja životnog standarda. Budući da je čovjek, kao jedan od ključnih čimbenika proizvodnje, povezan s tehnologijom, prirodno je da se promjene u tehnologiji odražavaju i na ljudske resurse i njihove kvalifikacije. Unaprjeđenje tehnologije zahtijeva ljude sve veće stručnosti koji se efikasno mogu prilagođavati tehničkim promjenama u procesu rada (Sundać et al., 2016:113).

Prema autoru Dubravčić (2007:41) postoje dva načina na koji ljudski kapital djeluje na rast gospodarstva. Prvi način je stvaranje vlastitih inovacija u kojima je potrebna visoka razina ljudskog kapitala, dok je drugi prihvaćanje i implementacija već stvorenih inovacija. Pretpostavka je da ako postoji regija koja prednjači u inovacijama i novoj tehnologiji, druge regije će je brzo dostići ukoliko raspolažu s dovoljnom razinom ljudskog kapitala koji je sposoban implementirati već stvorene inovacije.

U nastavku će se opisati na koji način se stvara ljudski kapital tj. koje su njegove karakteristike koje omogućuju rast gospodarstva te će se analizirati ljudski kapital u zemljama Europske unije.

2.4.1. Karakteristike ljudskog kapitala kao pokretača gospodarskog rasta

Ljudski kapital je vrijednost koja je uložena u ljude, prvenstveno putem obrazovanja, a radi stvaranja znanja, vještina i radnih sposobnosti (Karaman Aksentijević *et al.*, 2012:7). Fokus gospodarstava se mijenja s klasičnih resursa na jedinstvene resurse koji mogu stvoriti nove vrijednosti, a istovremeno ih je vrlo teško imitirati i multiplicirati. Stoga se pažnja pomiče sa samog proizvoda ili usluge na resurse koji su potrebni za njihovo stvaranje pri čemu znanje dobiva status strateškog gospodarskog resursa (Sundać *et al.*, 2016:135).

Bitne karakteristike znanja kao resursa su sljedeće (Morroni, 2006):

- Neisključivost – znanje je teško privatizirati i kontrolirati zbog efekta prelijevanja
- Nesuparništvo – ukoliko pojedinac koristi neko znanje, to ne umanjuje mogućnost korištenja istoga ostalima
- Kumulativnost – znanje se nadograđuje, iz intelektualnih inputa stvaraju se nove ideje i novo znanje

Prelijevanje znanja može biti namjerno i u tom se slučaju smatra transferom znanja te može biti nenamjerno što čini pozitivnu eksternaliju. Efekt prelijevanja znanja dovodi do društvene koristi povrata ulaganja u obrazovanje i istraživanje i razvoj. Nastavno, znanje je nesuparničko dobro jer se može koristiti među raznim akterima istodobno te ukoliko jedna osoba koristi određeno znanje, to ne umanjuje mogućnost korištenja istog od druge osobe (Sundać *et al.*, 2016:138). Važna karakteristika znanja je i kumulativnost kod koje se znanje tokom godina nadograđuje i razvija. Novostvorene ideje i znanja mogu se nadograđivati i razvijati što se može vidjeti iz konstantnog razvoja tehnologije u svijetu.

Ljudski kapital se ne može kupiti za osobnu upotrebu, odnosno učenik mora surađivati u „ugradnji“ znanja učenjem. Nove vještine koje čovjek želi savladati daju pozitivne učinke na okolinu samo ukoliko je čovjek voljan sudjelovati i raditi na njihovoj upotrebi. Nadalje, potrebno je obratiti pozornost i na pojam amortizacije ljudskog kapitala koja ovisi o životnom ciklusu čovjeka. Bržu amortizaciju moraju imati ona znanja koja su stečena u kasnijoj životnoj dobi u odnosu na znanja stečena u ranijoj životnoj dobi za koje postoji duži period primjene. Za razliku od fizičkog kapitala, ljudski kapital gubi na vrijednosti kada se ne koristi tj. ukoliko dolazi do nezaposlenosti, ljudski kapital ostaje samo neiskorišteni potencijal. Stoga je ljudski kapital potrebno iskorištavati ne samo zbog znanja koje je stečeno procesom učenja već i zbog

činjenice da se ljudski kapital također dodatno stvara učenjem kroz rad (*eng. learning by doing*) (Dubravčić, 2007:33).

Regije koje su inovacijski i tehnološki razvijenije izvoziti će proizvode koji su tehnološki intenzivniji. Kao što je prethodno spomenuto razvijenije regije imaju potrebu za obrazovanijim stanovništvom tj. boljim ljudskim kapitalom stoga je česta pojava migracija visokoobrazovanih ljudi prema visoko razvijenim područjima. Ljudski kapital se može jeftinije proizvesti u manje razvijenim područjima te nakon toga migrirati u razvijenija područja gdje mogu primijeniti svoja znanja (Dubravčić, 2007:44). Utjecaj migracija visokoobrazovanih osoba tj. odljeva mozgova (*eng. brain drain*) može biti dvojak ovisno o području. Ukoliko ljudski kapital emigrira iz područja stanovanja u razvijenije regije, tada je to gubitak za područje iz kojega se seli, a istovremeno dobitak za područje u koje se seli koje će gotovo bez ulaganja dobiti obrazovani kadar. No, s druge strane ukoliko nerazvijenija područja imitiraju inovacije razvijenijih tada se može zaključiti da su migracije korisne, kako za pojedinca tako i za područja imigracije i emigracije.

Pod ljudskim kapitalom smatraju se ukupne psihofizičke sposobnosti ljudi koje se mogu upotrijebiti za ostvarenje poslovnih ciljeva i posljedično za napredak gospodarstva (Bahtijarević Šiber, 1999). Ljudski kapital može se povećavati tijekom čitavog životnog vijeka ulaganjem u znanje, vještine i kompetencije, odnosno primjenom cjeloživotnog obrazovanja, stoga je za razvoj kvalitetnog ljudskog kapitala potrebno omogućiti ljudima kvalitetne životne uvjete u kojima će moći razviti i ostvariti svoje potencijale.

U posljednje vrijeme sve se češće spominje termin digitalno gospodarstvo koji je često zastupljen i u poslovanju morskih luka. Prijelaz na digitalno gospodarstvo zahtijeva specifična znanja i vještine tj. da bi razvojni inženjeri luke mogli adekvatno razviti novu tehnologiju i primijeniti je, potrebno je imati kvalitetan kadar koji će novu tehnologiju prihvatiti, implementirati je i koristiti. Zaposlenici u naprednim lukama koje se sve više okreću digitalizaciji, kao što je npr. luka Rotterdam, moraju razumjeti ulogu podataka, razumjeti informacijske tehnologije te biti sposobni upravljati pametnim digitalnim aplikacijama. Temeljne kompetencije koje se u tim slučajevima traže su znanost o podacima, modeliranje podataka, sastavljanje budućih prognoza te analiza podataka što sve zahtijeva visokoobrazovani kadar (Pannekoek, 2019:5).

2.4.2. Analiza ljudskog kapitala u Europskoj uniji

Ljudski kapital je ključan za povećanje produktivnosti i gospodarski rast te se gradi kroz obrazovni sustav, koji se u zemljama Europske unije uglavnom financira javnim novcem. Ulaganje u obrazovanje je javna investicija od koje se očekuju prilično visoki prinosi koji se materijaliziraju tijekom dugog razdoblja. Akumulacija ljudskog kapitala smatra se ključnim pokretačem rasta gospodarstva, produktivnosti, inovacijskih aktivnosti i otpornosti u vrijeme krize. Nadalje, obrazovanje je također djelotvorno u borbi protiv siromaštva i prilikom poravnanja raspodjele dohotka (European Commission, 2017a:1).

Obrazovanje se obično isplati, kako za pojedinca tako i za društvo u cjelini. Na individualnoj razini, osposobljavanje i stjecanje vještina čini ljude produktivnijima što se pretvara u povećanje plaća. Na makro razini, dobro obrazovana radna snaga pridonosi gospodarskom rastu i rastu produktivnosti te unaprjeđuje inovativni kapacitet društva koji zajedno vode ka povećanju životnog standarda cjelokupne populacije (European Commission, 2017a:5).

U endogenoj teoriji rasta temeljenoj na istraživanju i razvoju važnost se pridaje inovacijama te ljudskom kapitalu. Pretpostavka je da je za aktivnosti inovacija i njihovo prihvaćanje i implementiranje potrebno visoko obrazovanje stoga se u nastavku analizira udio visokoobrazovanih osoba u ukupnoj populaciji u zemljama Europske unije kroz desetogodišnje razdoblje (od 2008. do 2017. godine). Također se izračunao indeks koji uspoređuje zadnju promatranu 2017. godinu s prvom promatranom 2008. godinom. Europska unija potiče visoko obrazovanje, no sve zemlje članice ne daju jednake rezultate budući da odgovornost za institucije visokog obrazovanja leži u samim zemljama.

Tablica 3. Udio ljudi s visokim obrazovanjem u ukupnoj populaciji (%)

ZEMLJA	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	INDEKS 2017./2008.
Belgija	32,30	33,40	35,00	34,60	35,30	35,50	36,90	36,90	37,50	40,30	124,77
Bugarska	22,80	23,00	23,30	23,60	24,00	25,60	27,00	27,50	27,70	27,80	121,93
Češka	14,50	15,50	16,80	18,20	19,30	20,50	21,50	22,20	23,00	23,90	164,83
Danska	31,40	32,40	33,30	33,70	34,80	35,40	36,10	37,10	38,00	39,10	124,52
Njemačka	25,40	26,40	26,70	27,70	28,20	28,60	27,10	27,60	28,30	28,60	112,60
Estonija	34,20	36,10	35,50	36,90	37,60	37,40	37,75	38,10	38,90	39,70	116,08
Irska	35,90	37,10	38,70	39,20	40,80	42,60	43,30	44,50	45,10	46,50	129,53
Grčka	22,80	22,90	24,00	25,40	26,10	27,40	28,10	29,10	30,20	31,00	135,96
Španjolska	29,50	30,00	31,00	31,90	32,60	33,70	34,70	35,10	35,70	36,40	123,39
Francuska	27,10	28,40	28,90	29,70	30,70	32,10	33,20	34,10	34,60	35,20	129,89
Hrvatska	16,20	17,20	18,60	18,00	18,50	19,80	21,30	22,70	23,00	23,70	146,30
Italija	14,30	14,50	14,80	15,00	15,80	16,40	16,90	17,60	17,70	18,70	130,77
Cipar	34,50	34,10	35,70	37,70	39,30	39,30	40,30	40,50	41,90	42,50	123,19
Latvija	24,80	25,80	26,90	27,70	29,20	31,00	30,20	31,60	33,40	33,90	136,69
Litva	30,20	30,80	32,40	33,50	34,10	35,20	36,70	38,70	39,70	40,30	133,44
Luksemburg	27,70	34,80	35,50	37,00	39,10	40,70	45,90	41,10	42,60	39,90	144,04
Madžarska	19,30	19,80	20,00	21,00	22,10	22,60	23,40	24,20	23,70	24,10	124,87
Malta	13,30	13,90	14,90	16,20	17,80	19,60	21,20	21,60	22,10	23,90	179,70
Nizozemska	30,20	30,80	32,00	32,10	33,00	33,90	34,40	35,30	36,00	37,20	123,18
Austrija	17,90	18,90	19,10	19,20	19,80	20,60	29,90	30,60	31,40	32,40	181,01
Poljska	19,60	21,20	22,50	23,30	24,50	25,80	27,00	27,70	28,70	29,90	152,55
Portugal	14,20	14,60	15,50	17,20	18,50	19,30	21,70	22,90	23,90	24,00	169,01
Rumunjska	12,80	13,20	13,60	14,60	15,30	15,60	15,90	17,20	17,40	17,60	137,50
Slovenija	22,60	23,30	23,70	25,10	26,40	27,90	28,60	30,20	30,70	32,50	143,81
Slovačka	14,80	15,80	17,30	18,60	19,00	19,90	20,40	21,10	22,00	23,10	156,08
Finska	36,60	37,30	38,10	39,30	39,70	40,50	41,80	42,70	43,10	43,70	119,40
Švedska	32,00	33,10	33,90	34,80	35,70	37,00	38,70	39,80	41,10	41,90	130,94
Ujedinjeno Kraljevstvo	32,00	33,40	35,10	36,90	38,60	39,60	40,60	41,60	42,40	42,80	133,75

Izvor: Izradila autorica prema European Commission, 2018k

Godine 2017. najveći udio ljudi s visokim obrazovanjem u ukupnoj populaciji imala je Irska (46,50%), dok je najmanji udio imala Rumunjska (17,60%). Najveće povećanje udjela visokoobrazovnih ljudi u 2017. godini u odnosu na 2008. godinu imao je Portugal i to za 69,01%. Sve zemlje članice Europske unije imale su povećanje udjela visokoobrazovanih u zadnjoj promatranoj godini u odnosu na prvu, a najmanje povećanje imala je Njemačka. Njemačka je u 2017. godini imala 28,60% visokoobrazovanih ljudi u ukupnoj populaciji što nije veliki postotak ukoliko se uspoređuje s nekim od ostalih zemalja članica, a istovremeno je visoko na ljestvici ulaganja u istraživanje i razvoj.

Europska unija svojim politikama nastoji poticati visoko obrazovanje ljudi iako je odgovornost za organizaciju i provedbu visokog obrazovanja na samim državama članicama. No, Europska unija svojim aktivnostima nastoji pridonijeti dodatnoj međunarodnoj dimenziji studiranja. Programi kao što su Erasmus + i Obzor 2020. podržavaju i potiču međunarodne razmjene studenata, akademskog osoblja i istraživača kao i suradnju između visokoškolskih ustanova. Cilj je da se stvore nove mogućnosti u visokom obrazovanju gdje će ljudi učiti jedni od drugih izvan granica svoje zemlje te raditi na zajedničkim projektima i promicati inovacije (European Commission, 2013). Navedenim aktivnostima pospješuje se formiranje ljudskog kapitala kao i njegov konstantan razvoj.

Ljudski kapital može se sagledati iz više perspektiva te je jedna od njih i indeks ljudskog razvoja (*eng. Human Development Index – HDI*) koji izrađuje Program Ujedinjenih nacija za razvoj. Indeks je stvoren kako bi se naglasila važnost ljudi i njihovih sposobnosti kao glavnog kriterija za procjenu razvoja zemalja. Također se može upotrijebiti za propitivanje nacionalnih politika, postavljajući pitanje kako dvije zemlje s istom razinom bruto nacionalnog dohotka po glavi stanovnika mogu završiti s različitim ishodima ljudskog razvoja. Indeks ljudskog razvoja je zbirna mjera prosječnog postignuća u ključnim dimenzijama ljudskog razvoja: dug i zdrav život, obrazovanost i pristojni životni standard te je on geometrijska sredina normaliziranih indeksa za svaku od tri dimenzije (United Nations Development Programme, 2018).

U nastavku se nalazi tablica koja obuhvaća indeks ljudskog razvoja u zemljama Europske unije te rang svake zemlje članice u odnosu na ostale zemlje svijeta. Navedeni podaci mogu se pronaći isključivo na razini zemalja te za njih nema podataka na regionalnim razinama. Iz toga razloga podaci nisu korišteni u kasnijem istraživanju tj. testiranju modela, no sagledati će se i analizirati u ovome potpoglavlju. Podaci se promatraju u razdoblju od 2008. do 2017. godine te je izračunat je i verižni indeks koji stavlja u omjer zadnju i prvu promatranu godinu.

Tablica 4. Indeks ljudskog razvoja u zemljama Europske unije od 2008. do 2017. godine

RANG	ZEMLJA	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	INDEKS 2017/2008
4	Irska	0,91	0,91	0,91	0,90	0,90	0,91	0,92	0,93	0,93	0,94	103,30
5	Njemačka	0,92	0,92	0,92	0,93	0,93	0,93	0,93	0,93	0,93	0,94	102,07
7	Švedska	0,90	0,90	0,91	0,91	0,91	0,91	0,92	0,93	0,93	0,93	103,55
10	Nizozemska	0,91	0,91	0,91	0,92	0,92	0,92	0,92	0,93	0,93	0,93	102,76
11	Danska	0,91	0,91	0,91	0,92	0,92	0,93	0,93	0,93	0,93	0,93	102,20
14	Ujedinjeno Kraljevstvo	0,90	0,90	0,91	0,90	0,90	0,92	0,92	0,92	0,92	0,92	102,90
15	Finska	0,90	0,90	0,90	0,91	0,91	0,91	0,91	0,92	0,92	0,92	101,77
17	Belgija	0,90	0,90	0,90	0,90	0,91	0,91	0,91	0,91	0,92	0,92	101,89
20	Austrija	0,88	0,89	0,90	0,90	0,90	0,90	0,90	0,90	0,91	0,91	102,71
21	Luksemburg	0,89	0,88	0,89	0,89	0,89	0,89	0,90	0,90	0,90	0,90	101,57
24	Francuska	0,88	0,88	0,88	0,88	0,89	0,89	0,89	0,90	0,90	0,90	102,62
25	Slovenija	0,88	0,88	0,88	0,88	0,88	0,89	0,89	0,89	0,89	0,90	102,05
26	Španjolska	0,86	0,86	0,87	0,87	0,87	0,88	0,88	0,89	0,89	0,89	104,09
27	Češka	0,85	0,86	0,86	0,87	0,87	0,87	0,88	0,88	0,89	0,89	103,98
28	Italija	0,87	0,87	0,87	0,88	0,87	0,88	0,87	0,88	0,88	0,88	101,38
29	Malta	0,83	0,83	0,84	0,84	0,85	0,86	0,86	0,87	0,88	0,88	105,91
30	Estonija	0,84	0,84	0,85	0,85	0,86	0,86	0,86	0,87	0,87	0,87	103,57
31	Grčka	0,86	0,86	0,86	0,85	0,85	0,86	0,86	0,87	0,87	0,87	101,52
32	Cipar	0,85	0,86	0,85	0,85	0,85	0,85	0,86	0,86	0,87	0,87	102,00
33	Poljska	0,82	0,83	0,84	0,84	0,84	0,85	0,84	0,86	0,86	0,87	104,98
35	Litva	0,83	0,82	0,82	0,83	0,83	0,84	0,85	0,85	0,86	0,86	103,25
38	Slovačka	0,82	0,82	0,83	0,84	0,84	0,84	0,85	0,85	0,85	0,86	104,01
41	Latvija	0,82	0,82	0,82	0,82	0,82	0,83	0,84	0,84	0,84	0,85	103,17
41	Portugal	0,81	0,82	0,82	0,83	0,83	0,84	0,84	0,84	0,85	0,85	104,05
45	Madžarska	0,82	0,82	0,82	0,83	0,83	0,84	0,83	0,83	0,84	0,84	102,44
46	Hrvatska	0,80	0,80	0,81	0,82	0,82	0,82	0,82	0,83	0,83	0,83	103,49
51	Bugarska	0,77	0,77	0,78	0,78	0,79	0,79	0,80	0,81	0,81	0,81	105,45
52	Rumunjska	0,80	0,80	0,80	0,80	0,80	0,80	0,80	0,81	0,81	0,81	102,01

Izvor: Izradila autorica prema United Nations Development Programme, 2018

Prethodna tablica rangira zemlje članice Europske unije po njihovoj razvijenosti ljudskog kapitala. Najrazvijenija zemlja u ovom segmentu je Irska koja se na svjetskoj ljestvici nalazi na 4. mjestu od ukupno 189 promatranih zemalja. Njemačka se također nalazi vrlo visoko na ljestvici tj. na 5. mjestu te je potrebno istaknuti kako je Njemačka također među zemljama Europske unije koja uvelike ulaže u istraživanje i razvoj, stoga je vrlo dobar primjer poticanja razvoja ljudskog kapitala te stvaranja novih inovacija. Zemlja članica Europske unije koja se nalazi na zadnjem mjestu je Rumunjska i zauzima 52. mjesto na ljestvici. Rumunjska se također nalazi među zemljama članicama koje najmanje ulažu u istraživanje i razvoj stoga se već i u ovom teorijskom dijelu može ukazati na važnost povezivanja kvalitetnog ljudskog kapitala s ulaganjima u istraživanje i razvoj.

Endogena teorija rasta zagovara da endogene sile unutar ekonomskog sustava potiču gospodarski rast te je prva teorija koja pretpostavlja da je tehnološki napredak endogen. U fokusu doktorske disertacije je endogena teorija rasta temeljena na istraživanju i razvoju. Teorija ističe važnost obrazovanja i ulaganja u istraživanje i razvoj kao pokretača gospodarskog rasta. No, čak i unutar Europske unije koja svojim strategijama potiče obrazovanje i istraživanje i razvoj, zemlje članice imaju različite rezultate na navedenim poljima. Analizom statističkih podataka o ulaganju u istraživanje i razvoj, ljudskim resursima u znanosti i tehnologiji te obrazovnim dostignućima i ljudskom kapitalu može se doći do zaključka kako zemlje članice Europske unije koje se nalaze visoko na ljestvici po jednom od pokazatelja se većinom nalaze visoko na ljestvici i po ostalim pokazateljima. Isto vrijedi i obrnuto, zemlje koje ulažu manje u istraživanje i razvoj većinom imaju i manje razvijen ljudski kapital. Razina obrazovanja povećava sposobnost stvaranja nove tehnologije i primjene postojeće te se smatra kako su ulaganje u istraživanje i razvoj i ljudski kapital međuovisni te zajedno djeluju na povećanje gospodarskog rasta.

3. OSNOVNE ZNAČAJKE MORSKIH LUKA

Morske luke početna su i završna točka prijevoza tereta ili putnika morem. Prijevoz morem ima dvije najznačajnije prednosti, a one su sljedeće: može primiti velike količine tereta i relativno je jeftin te se iz tih razloga većina svjetske trgovine odvija pomorskim putem. Luke povezuju globalna i lokalna tržišta te se smatraju logističkim centrima u koje je uključena i pripadajuća regija. Teretne luke zastupljenije su od putničkih te će na njima u ovome poglavlju ali i cijeloj doktorskoj disertaciji biti naglasak. Budući da se društvo razvija a s njime i ekonomije i tehnologija, mnoge svjetske luke unaprjeđuju svoje poslovanje u skladu s promjenama što je jedan od izvora lučkih konkurentskih prednosti. Također, luke osim povezivanja pomorskog i kopnenog prometa imaju mogućnost razvoja industrije unutar svojega prostora što im smanjuje troškove jer teret ne moraju odvoziti u industrijske komplekse. Razni su sudionici u poslovanju luke koji direktno i indirektno imaju koristi od njenog poslovanja, no za gospodarstvo je važno da luka stvara vrijednost te radna mjesta.

Europska unija uključuje integraciju prometne infrastrukture te omogućuje suradnju luka koje se nalaze u različitim zemljama članicama. Mnogobrojne luke nalaze se unutar granica Europske unije te se većina robe koja se uvozi u Europu ili izvozi iz Europe odvija pomorskim putem. Nadalje, većina korisnika luka Europske unije su međunarodna poduzeća čime luke utječu na globalizaciju i njen su bitan čimbenik. Transeuropska mreža prometnica koja je u nastajanju svakako će doprinijeti boljem poslovanju luka te većoj učinkovitosti budući da će međunarodni teret lakše dolaziti u Europu te se također lakše distribuirati unutar Europe. Najbolja europska luka s najvećim prometom tereta jest Rotterdam. Luka Rotterdam prednjači i u korištenju suvremene tehnologije koja u posljednje vrijeme postaje pokazateljem uspjeha poslovanja. Općenito, luke koje koriste bolju tehnologiju i nove načine poslovanja uspješnije su od ostalih.

U sljedećim potpoglavljima dati će se osvrt na temeljna obilježja morskih luka i utvrditi njihov značaj u gospodarstvu, zatim će se analizirati morske luke u Europskoj uniji te će se definirati i analizirati suvremeni trendovi poslovanja u morskim lukama s posebnim naglaskom na tehnološki napredak.

3.1. Temeljna obilježja i ekonomske odrednice morskih luka i njihov značaj u gospodarstvu

Većina svjetskog blagostanja u nekom svom segmentu ima vezu s pomorskim putem i aktivnostima vezanim uz pomorstvo. Morske luke su mjesta gdje se odvija trgovina, logistika ali i sama proizvodnja te su u zadnjih nekoliko desetljeća doživjele golemi rast i razvoj. Mnoge morske luke imale su koristi od povećane međunarodne trgovine te se njihov rast također može povezati s procesom globalizacije. Integracija svjetskog tržišta, gospodarski rast i više razine prihoda dovele do toga da je promet postao vrlo značajna gospodarska aktivnost iz čega slijedi da je efikasan prometni sustav važna predispozicija za razvoj luke te prednost u lokalnoj, regionalnoj i međunarodnoj mobilnosti.

Luke igraju važnu ulogu u modernom društvu te doprinose rastu bruto domaćeg proizvoda gradova i regija u kojima se nalaze. Za mnoge proizvode, proizvodnja i potrošnja su raspršene diljem svijeta te je uloga luke povezivanje proizvodnje i potrošnje i uspostavljanje globalnih lanaca opskrbe. Luke mogu biti smatrane čvorovima u globalnoj logističkoj mreži gdje se susreću pomorski prijevoz i zaleđe. Pristupačnost luke je važan pokazatelj ekonomskog učinka. No, luke također stvaraju i negativne efekte kao što su emisije plinova i buka čime se stvara potreba za održivim razvojem morskih luka i poslova povezanih s lukama što zahtijeva promjenu koja se može postići ulaganjem u tehnološke promjene i inovacije, optimiziranjem i kvalitetnim planiranjem (Geerlings *et al.*, 2018:1).

3.1.1. Općenito o morskim lukama

Morske luke su mjesta na kojima se odvija prijenos tereta i putnika do i od plovnih putova i obale. Primarno, luke služe kao mjesta prijevoza u prometnom lancu, ali također i kao lokacije na kojima se može odvijati industrija i logističke aktivnosti. Svaka funkcija ima različita poduzeća koja pružaju usluge, različitu konkurentnost te različite načine mjerenja učinaka. Prema vrstama, luke mogu biti teretne te se u tom slučaju koriste samo za prijevoz tereta, zatim putničke u kojima se odvija samo prijevoz putnika ili kombinacija teretne i putničke luke u kojima se odvija transfer tereta i putnika (Talley, 2009:1).

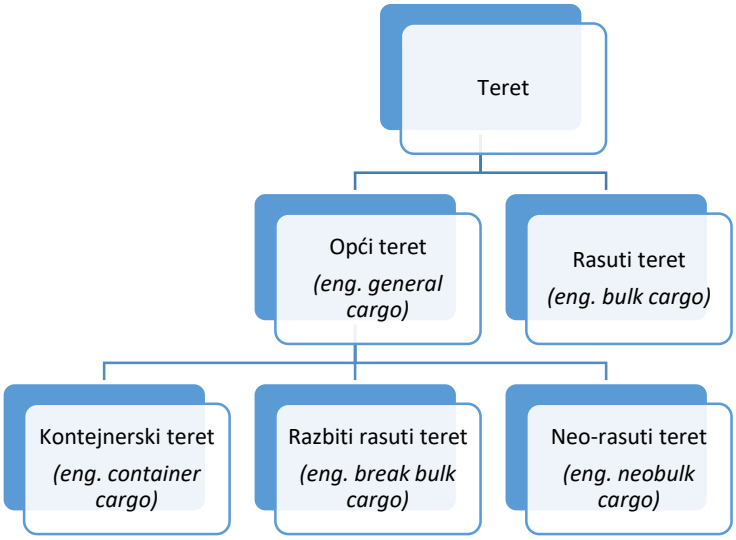
Iz ekonomske perspektive, morske luke su složeni, dinamički i stohastički sustavi cjelokupnog gospodarskog sustava pomorske države ili regije s odgovarajućim kapacitetima (lučkom infrastrukturom, suprastrukturom i ljudskim kapitalom), u kojemu se sučeljavaju gotovo sve

grane prometa i koji omogućava proizvodnju lučkih usluga te obavljanje mnogobrojnih logističkih usluga, a lociran je uz more, u kojemu se povezuju funkcije poslovi i interesi svih aktivnih sudionika prometnog sustava u jedinstveni racionalni integralni proces (Zelenika i Pavlić Skender, 2007:68; Jugović, 2012:17)

U većini slučajeva luke su teretne te one u većoj mjeri pridonose gospodarskom rastu nego putničke luke. Putnici na brodovima za kružna putovanja imaju gotovo sve usluge na samome brodu i relativno malo sredstava troše u destinaciji što nema veliki efekt na rast gospodarstva. Također, putnici u linijskom pomorsko putničkom prometu također ne troše značajnija sredstva prilikom prijevoza ili u početnoj i završnoj destinaciji. Autori Bottasso i suradnici (2013.) su u svome istraživanju dokazali kako broj putnika nema statistički značajan učinak na regionalno gospodarstvo tj. na zapošljavanje koje im je služilo na pokazatelj rasta gospodarstva. Veći utjecaj na gospodarski rast imaju teretne luke te će istraživanje u disertaciji prvenstveno biti orijentirano na njih.

Teret u teretnim lukama uključuje opće i rasute terete. Opći teret čini roba raznih veličina i težina koja se isporučuje kao zapakirani teret i smatra se kontejnerskim teretom ili razbitim rasutim teretom. Nadalje, opći teret također čini roba jednake veličine i težine koja se isporučuje kao nepakirani teret i smatra se neo-rasutim teretom. Kontejnerski teret je opći teret pohranjen u standardiziranim kontejnerima, veličine 20 ili 40 stopa. TEU *(eng. twenty-foot equivalent unit)* je mjera za kontejnerski teret 20 stopne jedinice kontejnera dok je FEU *(eng. fourty-foot equivalent unit)* mjera za kontejnerski teret 40 stopne jedinice kontejnera. Razbiti rasuti teret je opći teret koji se pakira na paletama ili na ovjesama od žice ili užadi za podizanje na i izvan broda. Primjeri neo-rasutih tereta uključuju automobile, čelik i drvo. Rasuti tereti (suhi i tekući) su tereti koji nisu zapakirani niti jednake veličine i težine. Primjeri suhog tereta uključuju ugljen i žitarice, dok su sirove nafte i naftni derivati primjeri tekućeg rasutog tereta (Talley, 2009:1). Navedena podjela tereta može se vidjeti na sljedećem shematskom prikazu.

Shema 3. Podjela tereta u teretnim lukama



Izvor: Izradila autorica prema Talley, 2009:1

Morska luka je između ostalog i ekonomska cjelina koja pruža usluge prijevoza za razliku od same proizvodnje proizvoda. Usluga prijevoza se često naziva prometom tereta, tj. promatra se broj kontejnera ili tone prevezenog tereta te broj putnika koji su prošli kroz luku. U luci se koriste resursi kao što su rad, mobilni kapital (npr. dizalice) i infrastruktura (npr. pristaništa) pri prijevozu tereta i putnika do i od plovila. Ukoliko luka nastoji biti tehnički učinkovita, nastojat će maksimalno povećati svoj promet tereta koristeći što veći kapacitet postojećih resursa (Talley, 2009:1).

Luka može imati dva organizacijska tipa, u prvome je lučka uprava odgovorna za održavanje luke te lučke infrastrukture dok privatna poduzeća (koncesionari) ulažu u imovinu te pružaju gospodarske usluge. Cilj lučke uprave nije ostvarenje dobiti već ona brine o gradnji, održavanju, upravljanju, zaštiti i unaprjeđenju pomorskog dobra (Kesić i Jugović, 2006:129). S druge strane luka može biti u privatnom vlasništvu jednog ili više poduzeća kojima je cilj ostvarenje što boljeg financijskog rezultata. Većina svjetskih luka pripada prvom organizacijskom tipu (van der Lugt, 2018:56).

Postoje tri glavna razloga zbog kojih morske luke posluju, a oni su sljedeći: budući da postoji potreba za razmjenom dobara, luke čine čvorove u prometnim lancima gdje se spajaju različiti tipovi prijevoza. Drugi razlog postojanja luka jest prometna potražnja koja je prostorno rasprostranjena tj. proizvodnja i potrošnja dobara ne odvijaju se na istim lokacijama. Općenito,

niti jedna zemlja nije samodovoljna već proizvodi određene proizvode dok neke druge uvozi. Luke podupiru međunarodnu razmjenu te je potražnja za lučkim uslugama izvedena iz potražnje za prometnim uslugama, a istovremeno potražnja za prometnim uslugama ovisi o međunarodnim trgovinskim tokovima. Promjene u međunarodnim trgovinskim tokovima imaju veliki utjecaj na poslovanje luka. Treći razlog postojanja luka je taj da luka može osigurati privremeno skladištenje tereta. Privremeno skladištenje može pomoći da se prebrode razlike između različitih načina prijevoza, odnosno količina tereta koja se preveze brodom u određenim slučajevima ne može se odmah prevesti kopnenim putem jer je kapacitet kopnenih vozila manji, stoga se teret skladišti (Nijdam i van der Horst, 2018:11).

Pod utjecajem razvoja ekonomije, društva i tehnologije, mnoge su svjetske luke izmijenile i unaprijedile svoju ulogu. Osim što luke povezuju pomorski i kopneni promet, u njima se također razvijaju industrijski kompleksi i industrija općenito. Nadalje, luke pružaju različite logističke usluge koje stvaraju nova poduzeća u okolini. Na primjer, poduzeća koja su vezana uz funkcioniranje kontejnerskih terminala mogu se pojaviti u luci te u kombinaciji s poslovima skladištenja, mogu teretu koji je došao u luku dodati vrijednost. Aktivnosti vezane uz dodavanje vrijednosti obuhvaćaju pakiranje, raspakiravanje, punjenje, označavanje, vaganje, paletiranje i slično. Budući da se kontejneri mogu vrlo lako prevesti različitim načinima kopnenog prijevoza, područja u zaleđu luke se razvijaju kao logistički centri. Stoga, skladištenje i ostale aktivnosti koje dodaju vrijednost mogu biti relativno udaljene od luke tj. mogu se nalaziti unutar lučke regije (Nijdam i van der Horst, 2018:15).

3.1.2. Lučki korisnici i pružatelji usluga

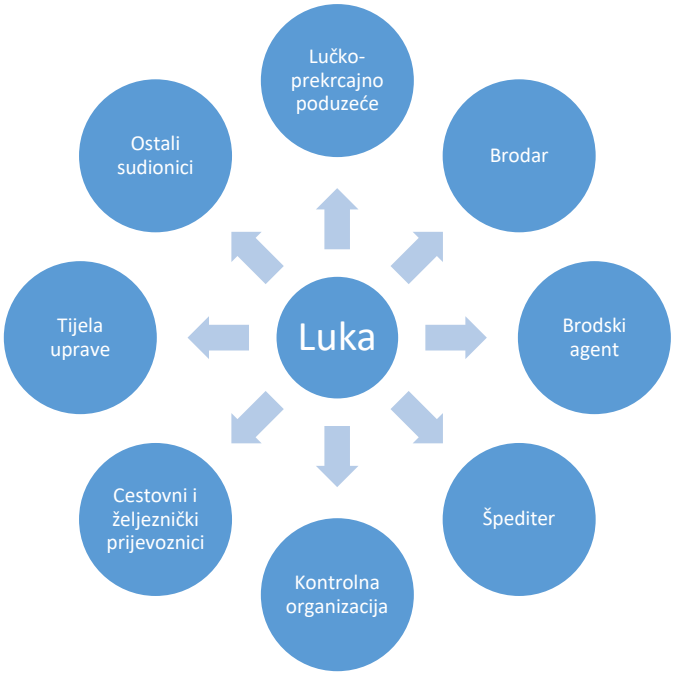
Korisnici luke su sudionici koji koriste luku kao dio procesa prebacivanja tereta i putnika od određenog početnog mjesta do odredišnog mjesta. Kako bi se dogodio prijevoz, dva sudionika moraju biti suglasna; prvi su prijevoznici (npr. brodske linije, željeznice, trajekti) koji moraju biti spremni za prijevoz tereta i putnika, dok su drugi brodari i putnici koji moraju biti spremni pružiti teret i sebe kao putnike, prijevoznicima koji će ih prevoziti. Ako neka od stranaka nije suglasna, neće se dogoditi prijevoz. Dakle, korisnici luke su prijevoznici, brodari i putnici koji koriste luke u stvaranju prijevoza tereta i putnika. Lučki pružatelji usluga su sudionici koji pružaju usluge korisnicima luke.

Primarni pružatelj usluga luke je lučki operator koji upravlja lukom ili jednim (ili više) svojih brodskih terminala. Lučki operator može biti: (1) lučka uprava koja upravlja svojim

terminalom, (2) privatni operator koji ugovara s lučkom upravom upravljanje svojim terminalom, (3) brodarska linija koja djeluje kao lučki operator. Lučki operator upravlja prometom tereta i korištenjem prostora i opreme pristaništa terminala. Ostali pružatelji usluga uključuju, na primjer, brodske agente, špeditere, logistička poduzeća, brokere, pilote brodova i brodska poduzeća za vuču. (Talley, 2009:13 i 26).

Navedeni sudionici pripadaju gospodarskim subjektima u lučkom poslovanju te će u nastavku biti detaljnije objašnjeni zajedno s nekima od nespomenutih sudionika lučkog poslovanja. Oni se većinom nalaze na prostorima u blizini luke te svojim poslovnim aktivnostima i zapošljavanjem osoblja stvaraju pozitivne ekonomske efekte za lučki grad i regiju. Sljedeća shema prikazuje glavne sudionike u lučkom poslovanju.

Shema 4. Sudionici u lučkom poslovanju



Izvor: Izradila autorica prema Kesić, 2003:88-91

Lučko-prekrcajna poduzeća nosilac su lučkih djelatnosti za koja su registrirana i koje su njihova osnovna djelatnost. Dio lučko-prekrcajnih poduzeća čine lučki slagači (stivadori) te lučki skladištari čija je glavna zadaća obavljanje poslova ukrcaja i iskrcaja tereta na brod ili s broda, odnosno djelatnosti skladištenja robe u lučka skladišta. Nadalje, nosilac plovidbe morem je brodar budući da je on korisnik i naručitelj lučkih usluga, dok su stivador, brodski agent i špediter njegovi pomoćnici u luci. Zastupnik samog brodara je brodski agent koji u njegovo

ime i za njegov račun obavlja lučke poslove u određenoj luci koje brodar iz svog sjedišta ne može obavljati. Osnovni poslovi brodskog agenta su prihvaćanje broda, posredovanje kod lučkih vlasti, kontaktiranje krcatelja, stivadora ili primaoca tereta te obračunavanje troškova. Nadalje, gospodarski subjekt koji otprema teret u svoje ime i za tuđi račun naziva se špediter. Njegovi najvažniji poslovi obuhvaćaju izbor prijevoznog puta, otpremu tereta, brigu o preuzimanju i predaji tereta, brigu o ukrcaju i iskrcaju tereta, utvrđivanje stanja tereta, brigu o skladištenju i čuvanju tereta, disponiranje određenih rukovanja teretom u lučkim skladištima te osiguranje tereta u prijevozu. Kontrolna organizacija također je jedna od gospodarskih subjekta u lučkom poslovanju te je njena uloga da na temelju ugovora koji sklapa s komitentom, utvrdi odgovaraju li količina, kvaliteta i druga svojstva robe uvjetima ugovora sklopljenim između kupca i prodavaoca tereta. Važni sudionici u lučkom procesu su i željeznički i cestovni prijevoznici koji robu kopnenim putem otpremaju do primaoca ili dopremaju robu do luke. Posebice je važno da rad kopnenih i željezničkih prijevoznika bude usklađen s radom luke kako bi roba mogla u pravo vrijeme otići u dopremu ili otpremu te kako bi se izbjegla stajanja i prazni hodovi u poslovanju (Kesić, 2003:90).

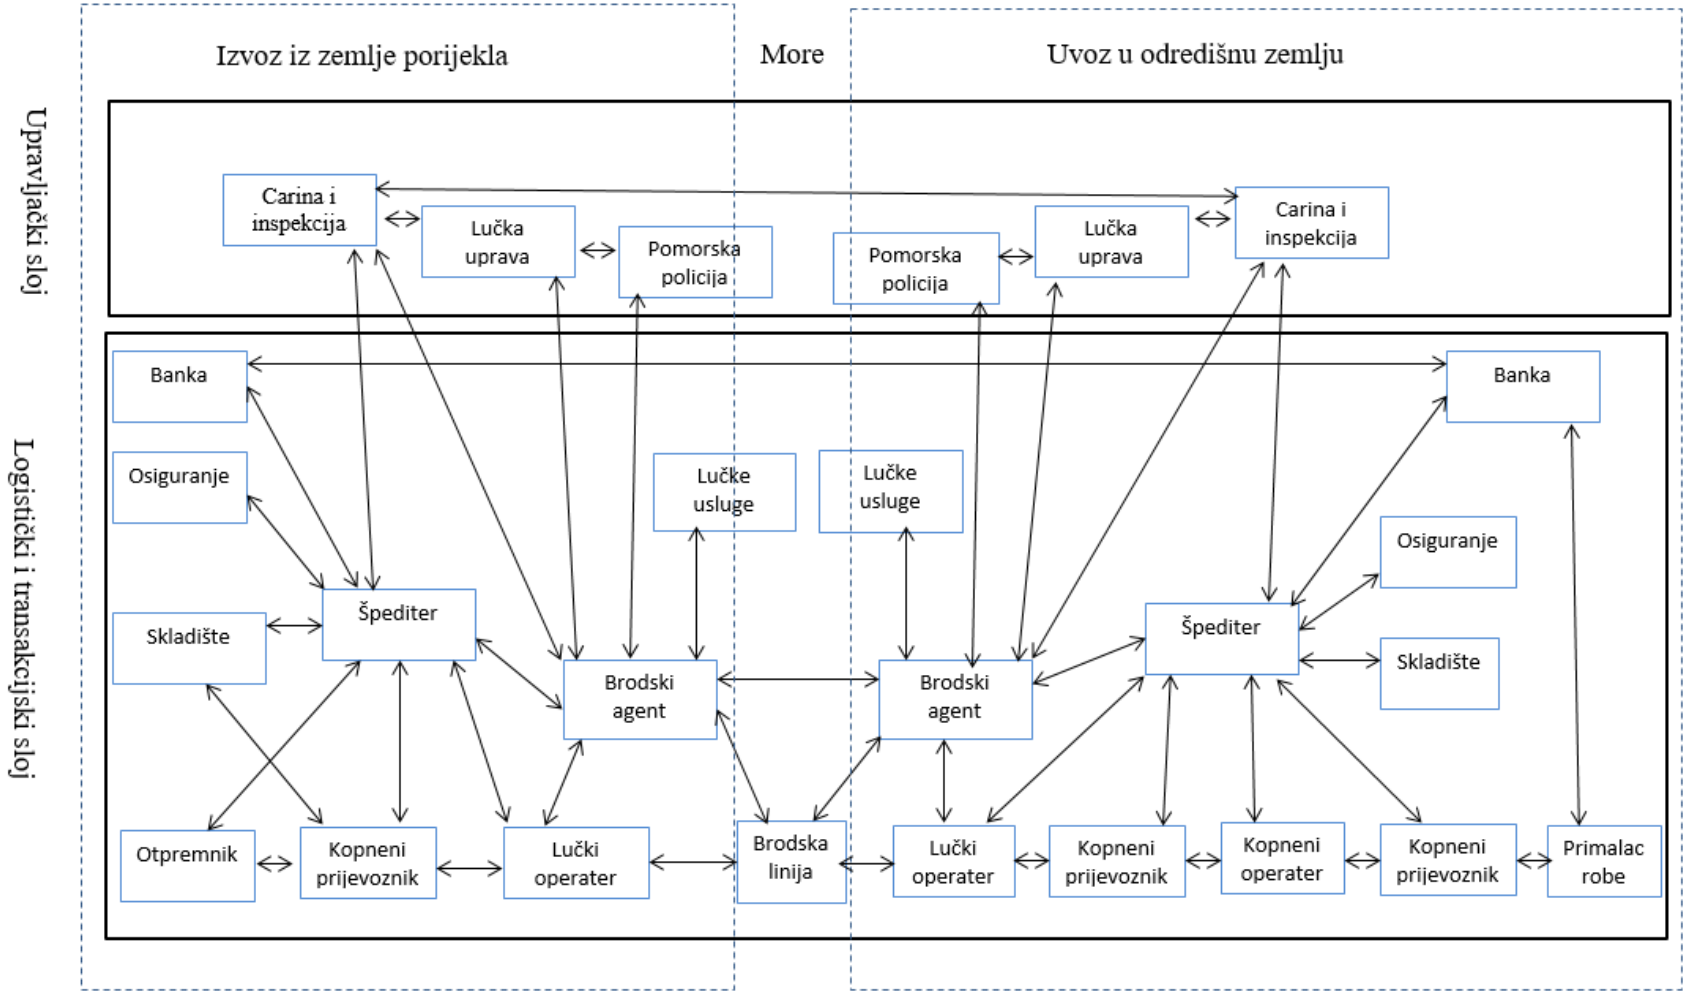
Kao sudionici u lučkom poslovanju, osim gospodarskih subjekata, javljaju se i tijela uprave koja obavljaju administrativno-upravne poslove u luci te čuvaju opće interese luke i osiguravaju sigurnost plovidbe. Lučka kapetanija je predstavnik upravne vlasti u luci i obavlja poslove održavanja sigurnosti plovidbe, pilotažu, izdavanje potrebne dokumentacije pri dolasku i odlasku brodova iz luke te vodi statistiku prometa tereta i putnika. Nadalje, tijelima uprave pripadaju i carinske uprave koje vrše nadzor nad prometom roba u uvozu, izvozu ili tranzitu u skladu s carinskim zakonima, propisima i aktima nacionalnog zakonodavstva. Sanitarni inspektorat, fitosanitetska stanica i veterinarska stanica obavljaju poslove sprječavanja unošenja bolesti, štetočina i nametnika u luku. Budući da se luka otvorena za međunarodni promet smatra graničnim prijelazom, kontrolu nad prometom i zadržavanjem putnika na graničnom prijelazu provode pogranična tijela. Inspekcijske službe nadgledaju da li je rad u lukama u skladu s međunarodnim i nacionalnim propisima te da li se primjenjuju tehničke i zaštitne mjere prilikom dolaska broda u luku i obavljanja ostalih poslova u luci (Kesić, 2003:89).

Lučke uprave koje upravljaju vlastitim kontejnerskim terminalima više nisu toliko učestale. Sve češće lučke uprave imaju ulogu koncesioniranja lučkog područja privatnim lučkim operatorima. Postoji niz globalnih privatnih lučkih operatora na kontejnerskim terminalima. Prema Llyod's

List u 2018. godini najveći svjetski lučki operatori na kontejnerskim terminalima bili su Hutchison Port Holdings s 84 600 000 TEU jedinica, PSA International s 81 000 000 TEU jedinica, DP World s 71 400 000 TEU jedinica te Cosco Shipping Ports s 56 706 600 TEU jedinica (Cosco Shipping Ports Limited, 2019:4; DP World, 2019; Hutchison Ports, 2019; Lloyd's List, 2019; PSA International, 2019).

Lučka tijela uprave stvaraju određene pozitivne ekonomske efekte prvenstveno kroz primarno zapošljavanje. Međutim, veći ekonomski utjecaj imaju gospodarski subjekti u lučkom poslovanju te će na njima, kao stvarateljima poslovnih aktivnosti i multiplikativnih efekata u regiji, biti veći naglasak. Interakcije lučkih korisnika i pružatelja usluga mogu varirati, a sljedeća shema prikazuje jednu od varijacija interakcija.

Shema 5. Interakcija lučkih korisnika i pružatelja usluga



Izvor: Prilagodila autorica prema Zuidwijk, 2018:30

Shema pruža sveobuhvatan pregled interakcija lučkih korisnika i pružatelja usluga koje ne moraju isključivo ići tim redom. Interakcije uključuju mrežu organizacija. Logistički sloj uključuje brodare (pošiljatelje i primatelje), kopnene i pomorske prijevoznike te operatere terminala. U transakcijskom sloju nalaze se špediteri i brodski agenti koji nisu uključeni samo u određivanje smjera logističkog lanca, već su uključeni i u pružanje lučkih usluga. Banke i osiguravajuća društva te ostale poslovne usluge, kao što su pravne usluge i trgovci robom, također su uključene u transakcijski sloj. Upravljačkom sloju pripadaju lučka uprava, policija, te inspekcijska tijela i carine. Kako bi se sve operacije odvijale nesmetano, lučki korisnici i pružatelji usluga moraju kvalitetno i pravodobno obavljati svoje poslove kako ne bi došlo do nepotrebnih zastoja čime se smanjuje efikasnost poslovanja morskih luka.

3.1.3. Upravljanje lučkim poslovanjem i kvaliteta pružanja usluga

Operativna opcija je sredstvo kojim operator luke može definirati kvalitetu svoje lučke usluge. Operativne opcije koje prijevoznici koriste za razlikovanje usluga uključuju brzinu kretanja, učestalost usluge, pouzdanost usluge, prostornu dostupnost, osjetljivost tereta na gubitak ili oštećenje te osjetljivost putnika na ozljede. Operator luke ima slične operativne mogućnosti pomoću kojih se razlikuje kvaliteta usluge.

Operativne opcije operatora luke koje su analogne brzini kretanja prijevoznika predstavljaju usluge ukrcaja i iskrcaja tereta brodova. Brzina ukrcaja tereta mjeri se kao količina tereta (npr. tona ili TEU-a) koji se na brod ukrca u jednom satu, dok je brzina iskrcaja količina tereta iskrcanog u jednom satu. Nadalje, operativna opcija koja je slična učestalosti usluge prijevoznika je vrijeme okretanja u luci, točnije razlika između vremena polaska i dolaska broda. Operativne opcije lučkih operatora koje su analogne pouzdanosti usluge prijevoznika su pouzdanost lučkog kanala i pouzdanost sidrišta. Prvo se može mjeriti kao postotak vremena tokom kojeg je kanal luke otvoren za plovidbu, a potonje kao postotak vremena tokom kojeg je sidrište otvoreno za privez brodova. Sličnost s prostornom dostupnošću ima dostupnost kanala i pristupačnost veza u luci koji se mogu mjeriti kao postotak vremena u kojemu kanala ili vez odgovaraju potrebnim dimenzijama širine i dubine. Što su ti postoci veći, to je veća kvaliteta usluge koju pruža operator luke. Operativne opcije koje su analogne osjetljivosti tereta na gubitak ili oštećenje su vjerojatnost gubitka lučkih tereta i vjerojatnost oštećenja tereta robe. Što su ove vjerojatnosti niže, to je veća kvaliteta usluge koju pruža operator luke (Talley, 2009:95).

Operator luke može nastojati poboljšati kvalitetu svoje usluge, npr. povećanjem broja usluga ukrcaja i iskrcaja. No, kako bi se na tržištu mogla ponuditi povećana usluga, potrebno je angažirati i veću količinu resursa, npr. uposliti veći broj brodskih dizalica ili dizalica za slaganje i uklanjanje kontejnera u skladištima. Pozitivan odnos između minimalne količine angažiranih resursa od strane lučkog operatora i razine operativnih opcija te tereta koji osiguravaju brodari i putnika koji koriste luku, naziva se resursna funkcija lučkog operatora te je njena formulacija sljedeća (Talley, 2009:96):

Minimum lučkih resursa = f (operativna opcija, količina tereta, broj putnika)

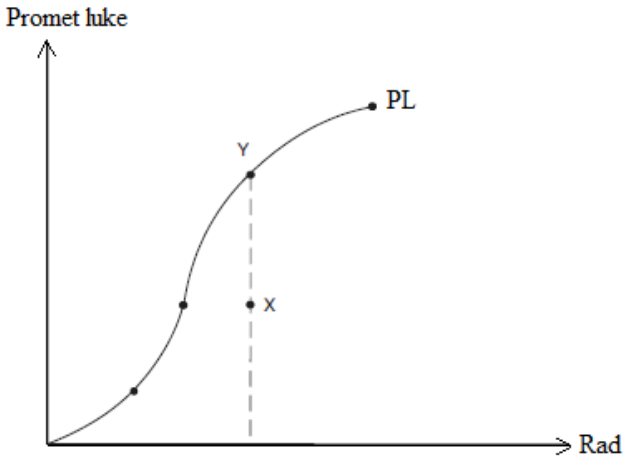
Razine operativnih opcija se mogu kontrolirati, odnosno lučki operator može odlučiti koju razinu kvalitete usluga želi imati te može poduzeti odgovarajuće mjere za njihovo postignuće. S druge strane, teret kojim će se rukovati i putnici koji će posjetiti luku ne mogu se kontrolirati tj. lučki operator ne može prisiliti prijevoznike i putnike da koriste njegovu luku. Zastoj u luci također se djelomično može kontrolirati, a nastaje kada korisnici luka (prijevoznici i putnici) međusobno ometaju korištenje lučkih resursa, čime se povećava njihovo vrijeme boravka u luci. Zagušenje luke može biti nenamjerno ili namjerno. Nenamjerna smetnja događa se u uobičajenom korištenju lučkih resursa, npr. kada vezivanje broda kasni zbog odvezivanja drugog broda. Namjerni zastoji mogu proizaći iz određenog davanja prioriteta, npr. kada operator luke prednost daje jednom lučkom korisniku nad drugim. Još jedan uzrok nastajanja zastoja u luci može biti i nedovoljno lučkih resursa kao što su dizalice ili radna snaga koji dovoljno brzo ne mogu ukrcati i iskrcati teret ili putnike u luci (Talley, 2009:96). Zastoji u luci mogu povećavati troškove u luci i općenito smanjiti privlačnost luke kao mjesta koje prijevoznici i putnici žele odabrati za svoje poslovanje, stoga sama luka mora obratiti pozornost na svoju produktivnost i nesmetano poslovanje.

Luka je tehnički učinkovita kada se ostvaruje maksimalan promet tereta ili putnika koji se može ostvariti s obzirom na razine resursa koje koristi operator luke. Funkcionalni odnos između maksimalnog prometa i razine resursa koje koristi lučki operator je ekonomska funkcija proizvodnje luke (Talley, 2009:96):

Maksimalan promet luke = f (lučki resursi)

Promet luke može se odnositi na broj kontejnera ili tone tereta, dok se pod lučke resurse podrazumijevaju rad, nepokretni kapital (npr. skladišta i zgrade), mobilni kapital (npr. dizalice i vozila) i prometnice (npr. lučke ceste i željeznice). Ukoliko luka postigne maksimalni promet u korištenju određenih razina resursa, tada se može smatrati tehnički učinkovitom. Pojednostavljena ekonomska funkcija proizvodnje luke koja u obzir uzima samo jedan resurs odnosno rad te lučki promet prikazana je na sljedećem grafikonu.

Grafikon 2. Proizvodna funkcija luke



Izvor: Prilagodila autorica prema Talley, 2009:97

Proizvodna funkcija luke koja u odnos uzima lučki rad i promet luke prikazana je kao krivulja PL na grafikonu. Svaka točka na krivulji PL tehnički je učinkovita, odnosno nalazi se na granici proizvodnih mogućnosti gdje se resursi upotrebljavaju učinkovito i u potpunosti. Ukoliko se točka nalazi ispod krivulje, luka posluje tehnički neučinkovito s obzirom na odgovarajuću količinu rada. Primjerice, u točki X, luka posluje neučinkovito, jer rad u toj točki osigurava manje prometa tereta od onoga za koji je sposoban (točka Y). Promet tereta iznad krivulje PL nije moguć jer luka nema dovoljno resursa za njegovo provođenje.

Maksimalan promet tereta koji luka može fizički podnijeti pod određenim uvjetima naziva se ukupni kapacitet luke. Autori Chadwin, Pope i Talley (1990:35) klasificirali su kapacitet luke kao:

1) Dizajnirani kapacitet
2) Preferirani kapacitet
3) Praktični kapacitet

Dizajnirani kapacitet luke je kapacitet kod kojeg je prisutna maksimalna stopa iskorištenosti. Na primjer, dizajnirani kapacitet skladišnog prostora kontejnerske luke je maksimalni broj kontejnera koji se mogu fizički pohraniti u skladište. Preferirani kapacitet luke je kapacitet kod kojeg je prisutna stopa iskoristivosti iznad koje se ne mogu ostvariti određeni zahtjevi tj. stopa iskoristivosti iznad koje dolazi do zagušenja luke. Praktični kapacitet luke je kapacitet kod kojeg je maksimalna stopa iskoristivosti pod realnim radnim uvjetima. Na primjer, praktični kapacitet kontejnerske dizalice definiran je maksimalnim brojem kontejnera koje dizalica može ukrcati i iskrcati s broda po satu pod realnim radnim uvjetima.

Luka kao i svaki drugi poslovni subjekt ima određene troškove kojima nastoji adekvatno upravljati. Operator luke je troškovno učinkovit kada je promet luke osiguran uz najmanje troškove s obzirom na cijene resursa koje plaća. Ekonomska funkcija troškova luke predstavlja odnos između minimalnih troškova luke koji će nastati u upravljanju određenom razinom prometa tereta, odnosno (Talley, 2009:97):

Minimalan lučki troškovi = f (promet luke)

Pod lučkim troškovima smatraju se troškovi koje su lučki operatori podmirili prilikom korištenja resursa, npr. plaće isplaćene radnicima, troškovi goriva za vozila i sl. Ukoliko luka osigurava promet po minimalnom trošku, tada se smatra da luka posluje ekonomično. Nadalje, kako bi luka mogla poslovati ekonomično, ona mora biti tehnički učinkovita. Ukoliko luka nije tehnički učinkovita, može to promijeniti ako omogući dodatni promet tereta s istom količinom resursa te će se u tom slučaju prosječni trošak po jedinici tereta smanjiti. Alternativno, ako je luka tehnički neučinkovita, može značiti da je njena cijena neučinkovita te treba razmisliti o promjeni cijena usluga.

Kako bi luka uspješno poslovala mora težiti tome da što bolje iskoristi svoje resurse te da pruža što kvalitetnije usluge sa što manje zastoja i gubitaka te uz što niže troškove. Luka kao i svaki drugi poslovni subjekt teži da uz što manje troškova ostvari što bolji poslovni rezultat. Ukoliko

luka posluje učinkovito ona postaje atraktivna destinacija za razne lučke korisnike što povećava promet u luci i poboljšava financijski rezultat, a time utječe i na gospodarski rast regije.

3.1.4 Učinkovitost poslovanja morskih luka i lučka konkurentnost

Luka, osobito u konkurentskom okruženju, ne bavi se samo tehničkim i troškovnim učinkom, već i učinkovitošću pružanja prometnih usluga. Učinkovitost prikazuje koliko efikasno luka koristi svoje raspoložive resurse. Gospodarski operativni ciljevi luke mogu se klasificirati kao ciljevi efektivnosti ili ciljevi efikasnosti. Na primjer, operativni ciljevi učinkovitosti luke uključuju tehničku učinkovitost čiji je cilj maksimizacija prometa s određenom količinom korištenih resursa (funkcija proizvodnje) i troškovnu učinkovitost čiji je cilj minimiziranje troškova u pružanju određene razine prometne usluge (troškovna funkcija) (Talley, 2009:136). Luke ocjenjuju svoju učinkovitost uspoređujući stvarno ostvareni promet tereta i predviđeni optimalni promet tereta. Također se mogu koristiti i drugi pokazatelji učinkovitosti kako bi se procijenilo lučko poslovanje. Ukoliko je gospodarski cilj luka povećanje profita, lučki menadžment može odabrati pokazatelje koji prikazuju maksimizaciju zarade luka.

Operativni ciljevi luke razlikovati će se ovisno o tome da li su luke privatne ili državne. Ako je luka u privatnom vlasništvu, njezin poslovni cilj u većini slučajeva će biti povećanje profita ili maksimiziranje prometa uz minimalne troškove. Ukoliko je luka u državnom vlasništvu, njezin cilj može biti povećanje prometa uz nulti operativni manjak. Da bi luka bila efektivna, mora biti i efikasna, odnosno potrebno je da posluje ekonomično, što zauzvrat zahtijeva da mora biti i tehnički učinkovita. Na primjer, ako luka ima za cilj maksimiziranje profita, a istovremeno je troškovno neučinkovita, može ostvariti veću dobit za istu razinu pruženih usluga tako što može smanjiti troškove i postati troškovno učinkovita (Talley, 2009:136-137). Nadalje, postoji mogućnost da će troškovno neučinkovite luke morati povećati svoje cijene kako bi pokrile troškove i ostvarile točku pokrića, čime se s aspekta cjenovne konkurentnosti stavljaju u nepovoljan položaj. Kada su luke tehnički neučinkovite, brodovi se dulje zadržavaju u lukama te brodari moraju uvesti više brodova na određenoj ruti kako bi ostvarili svoje dogovoreno poslovanje. Također, ukoliko teret duže ostaje u lukama, brodari moraju povećati zalihe, što rezultira višim troškovima zaliha. Nedjelotvorne luke stvaraju manju dobit, što rezultira manjim sredstvima za financiranje lučkih investicija (Marlow i Paixão Casaca, 2003). Dakle, ekonomska učinkovitost luke može se ocijeniti s gledišta tehničke učinkovitosti, troškovne učinkovitosti i efektivnosti uspoređujući svoj stvarne učinke s tehnički učinkovitim optimalnim učincima, troškovno učinkovitim optimalnim učincima i optimalnom efektivnošću.

Mjerenje učinka luke djelomično je zahtijevan posao budući da se radi o više povezanih djelatnosti, a ne samo o pomorskoj prijevoznoj djelatnosti. Promet tereta u tonama najčešća je mjera lučkih učinaka te omogućuje da se uspoređuje konkurencija između različitih luka. Ukupan promet tereta do određene mjere opisuje poslovanje luke, no budući da svaka vrsta tereta ima različite načine rukovanja i povezana je s različitim industrijama, promet tereta ne može dati u potpunosti precizan rezultat poslovanja morskih luka. Glavna prednosti ove metode je što se usporedbom prometa tereta različitih luka može definirati i pratiti konkurentska pozicija svake od njih (Nijdam i van der Horst, 2018:16). Ukoliko se luka sagledava kao lokacija, odnosno mjesto za razvoj industrije ili logističkih aktivnosti, promet tereta mjeren u tonama više nije u potpunosti dobra i precizna mjera. Pokazatelj koji najbolje opisuje ekonomske aktivnosti luke je dodana vrijednost te socio-ekonomski ciljevi najčešće vezani uz zaposlenost u luci. Navedena dva pokazatelja su povezana jer su plaće radnicima dio dodane vrijednosti tj. dodana vrijednost sastoji se od plaća radnicima, profita i deprecijacije. Što se tiče zaposlenosti, veliki broj direktno zaposlenih radnika radi blizu lučkog bazena, no znatan broj ljudi također je zaposlen i u lučkim aktivnostima u prostoru koji okružuje lučki bazen (Nijdam i van der Horst, 2018:18). Treći način mjerenja učinaka u lukama jesu privatne investicije. Ukoliko se uočava trend povećanja ulaganja u kapitalna sredstva, to reflektira razvoj budućih lučkih mogućnosti. Opadajuće investicije mogu biti pokazatelj da je portfelj aktivnosti u luci manje prikladan za budućnost.

Razni stručnjaci pokušali su razviti dodatne pokazatelje za mjerenje učinaka u morskim lukama te su ideje ekonomske, društvene i okolišne prirode. Ukoliko se učinak luke sagledava iz društvenog aspekta, mogu se promatrati mjere vezane uz zaposlenosti, obrazovanje i društvenu uključenost lučkih poduzeća. Povećanje razine obrazovanja u lučkoj industriji pokazatelj je rastuće automatizacije i tehnoloških napredaka kao i istraživanja i razvoja. Inovacije su također važne za ekonomski napredak. Lokacije na kojima se češće odvijaju i implementiraju inovacije, imaju bolju perspektivu te mogu povećati produktivnost što posljedično povećava konkurentski položaj ili stvara novu industriju u luci. Mjera za inovativnost može biti povećana razina produktivnosti, broj patenata vezanih uz lučko poslovanje ili broj novih proizvoda i usluga (Nijdam i van der Horst, 2018:21).

Konkurencija luka može se promatrati između različitih luka te se može promatrati i konkurencija unutar određenih luka, odnosno konkurentnost unutar lučkih terminala. Lučka konkurentnost može se procijeniti u smislu rasta, tržišnog udjela i diversifikacije količine

prometa (Talley, 2009:136). Prilikom sagledavanja konkurentnosti između luka, većinom se uspoređuju različite luke te utvrđuje njihov konkurentski položaj. No, iako je zanimljivo uspoređivati različite luke, njihove učinke i uspješnost poslovanja, postoji mogućnost da takve usporedbe mogu biti pogrešne. Različite luke rade u različitim ekonomskim, socijalnim i fiskalnim okruženjima, stoga, ukoliko se uspoređuju luke, potrebno je koristiti luke koje imaju slične karakteristike. Na konkurentnost između luka utječu sljedeći čimbenici: (1) lučki učinak, (2) pristupačnost i lokacija, (3) lučka tradicija, (4) državne subvencije i (5) preferencije lučkih korisnika (Fleming i Baird, 1999).

Konkurentnost luke veća je ukoliko ima dobre mogućnosti pristupa moru i kopnu. Kada se luka nalazi blizu otvorenog mora, vrijeme prijevoza broda biti će kraće, a troškovi pilotaže i tegljenja biti će manji što povećava njenu konkurentsku poziciju. Nadalje, ukoliko luka ima izravnu povezanost s autocestama, željeznicom i sustavima unutarnje plovidbe, vrijeme kopnenog prijevoza tereta biti će kraće. Konkurentnost luka također je poboljšana ako se nalaze u blizini centara potrošnje i proizvodnje tj. u blizini velikih gradova s mnogobrojnom populacijom koja tvori velika potrošačka tržišta. Državne subvencije luci mogu utjecati na njen konkurentski položaj. Naime, luka koja prima subvencije države može smanjiti svoje cijene te tako poboljšati svoj položaj na tržištu. Državne subvencije uključuju isplatu novčanih subvencija i druge vrste pomoći koje mogu uključivati smanjenja poreza, povoljne zajmove, izgradnju lučke infrastrukture i korištenje rezultata državno financiranih istraživačkih i razvojnih programa koji pogoduju luci (Talley, 2009:140).

Pod konkurentnošću unutar luka smatra se konkurentnost unutar lučkih terminala te postoji niz pogodnosti od njihovog natjecanja. Konkurentnost unutar luka sprječava monopolističko određivanje cijena što rezultira nižim cijenama koje određuju pojedini operatori terminala, za razliku od slučaja kada konkurencija ne postoji. Nadalje, konkurencija potiče specijalizaciju i kreiranje inovacija unutar luke te stvaranje raznolikosti. Konkurenti unutar iste luke se natječu u istom okruženju tj. suočavaju se s istim regulacijama, tržištem rada i dobavljačima te se u takvim uvjetima češće javlja specijalizacija budući da se operatori moraju na neki način razlikovati od izravne konkurencije (de Langen i Pallis, 2006).

3.2. Morske luke u Europskoj uniji

Europske luke su vitalni prolazi koji povezuju svoje prometne koridore s ostatkom svijeta. Neke od najuspješnijih luka nalaze se u Europi te prema podacima Europske komisije 74% robe koja ulazi ili izlazi iz Europe odvija se pomorskim putem. Luke imaju važnu ulogu u podupiranju razmjene robe na unutarnjem tržištu ali također i ulogu povezivanja perifernih i otočnih područja s kopnom Europe. One čine čvorišta iz kojih se mogu organizirati multimodalni logistički tokovi transeuropskih mreža, koristeći pomorski prijevoz, željeznicu i unutarnje plovne putove kako bi se smanjilo zagušenje na cestama te smanjila potrošnja energije. Nadalje, namjena luke nije samo za kretanje tereta, već luke predstavljaju i energetske čvorove za konvencionalne i obnovljive izvore energije. Europska unija zahtijeva dobro razvijene luke koje zadovoljavaju međunarodne standarde u svim svojim lučkim regijama. Svake se godine više od 3 milijuna tona tereta ukrcava i iskrcava u morskim lukama Europske unije (European Commission, 2015).

Europa je jedna od najgušćih svjetskih lučkih područja, no njene luke su se povijesno razvijale na različite načine. U prvim desetljećima europske integracije dominantan je bio stav da bi se luke, za razliku od ostalih industrija, mogle razvijati bez da budu podložne nadnacionalnoj politici koja bi postavila zajednička pravila. Uspostavljanje jedinstvenog europskog tržišta koje je obuhvaćalo ekonomsku i političku integraciju rezultiralo je time da su europske luke počele bolje međusobno surađivati.

Bolja suradnja luka počela se intenzivirati i zbog drugih čimbenika kao što su globalizacija, kontejnerizacija, logistika, tehnološki napredak te integracija pomorske trgovine u opskrbne lance. Nacionalne ekonomije su bile primorane stvoriti nove lučke politike koje će pratiti novonastale uvjete. No, istovremeno počelo se razmišljati i o zajedničkim pravilima Europske unije te je kreirana ideja o zajedničkoj Europskoj lučkoj politici *(eng. European Port Policy – EPP)*. Zajednička lučka politika Europske unije razvijala se od ranih devedesetih godina dvadesetog stoljeća te se tražila optimalna dugoročna strategija. Također, sudionici poslovanja u lukama tražili su mogućnost utjecaja u procesu stvaranja politike Europske unije (Pallis i Verhoeven, 2009:99). Europska komisija je tokom svih godina u kojima se razvijala politika imala dva glavna cilja: (1) osiguranje dosljedne primjene općih pravila ugovora, osobito u pogledu tržišnog natjecanja i temeljnih sloboda unutarnjeg tržišta te (2) postizanje

uravnoteženog razvoja europskih luka. Oba cilja proizlaze iz temeljnih načela Ugovora o Europskoj uniji (Verhoeven, 2008).

Europska unija je tokom godina napredovala u ekonomskom i društvenom smislu te su se usporedno s time usklađivali i okvirni uvjeti unutar kojih se razvijao svaki industrijski sektor, s ekonomskim, političkim i kulturnim posljedicama. Asimetrična ekonomska integracija kroz stvaranje jedinstvenog europskog tržišta 1992. godine bila je katalizator. Kako bi se poboljšala sloboda kretanja roba, usluga i kapitala, razdvojile su se tarifne i ne-tarifne barijere, uz međusobno priznavanje tehničkih, trgovinskih i drugih standarda što je rezultiralo izravnim smanjenjem troškova. Koraci prema usklađivanju poreznih sustava smanjili su transakcijske troškove. Lisabonska strategija[1] iz 2000. godine i monetarna integracija, stvorili su integracijske procese koji su omogućili poduzećima prostorno širenje. Istodobno, ekonomska integracija povezana je s ekspanzijom intra-industrijske trgovine: jedinstveno europsko tržište pridonosi prijevozu intermedijarnih proizvoda putem složenih multimodalnih opskrbnih lanaca. Nadalje, politička integracija Europske unije dodala je dodatnu mogućnost suradnje te je stvorila preduvjete da Europska komisija krene prema razvoju političkih smjernica u području lučke politike i pomorskog prometa. Važnu ulogu u europskoj integraciji ima i kulturni učinak, odnosno s povećanjem mobilnosti tereta, povećava se i razmjena ideja između zemalja članica Europske unije (Pallis i Verhoeven, 2009:101).

U ranim 1990-ima Europska komisija razvila je zajedničku prometnu politiku čiji je cilj bio razvijanje koherentne europske infrastrukturne mreže putem koncepta transeuropskih prometnih mreža (TEN-T) i postizanje održive mobilnosti. Prva publikacija vezana za morske luke usvojena od strane Komisije bila je Zeleno poglavlje o morskim lukama i pomorskoj infrastrukturi koje se fokusiralo na tri glavne teme: (1) financiranje i naplata luka, (2) pristup tržištu za lučke usluge i (3) integracija luka u TEN-T. Prije same analize morskih luka sagledati će se transeuropska mreža prometnica te utvrditi njena važnost u razvoju morskih luka Europske unije.

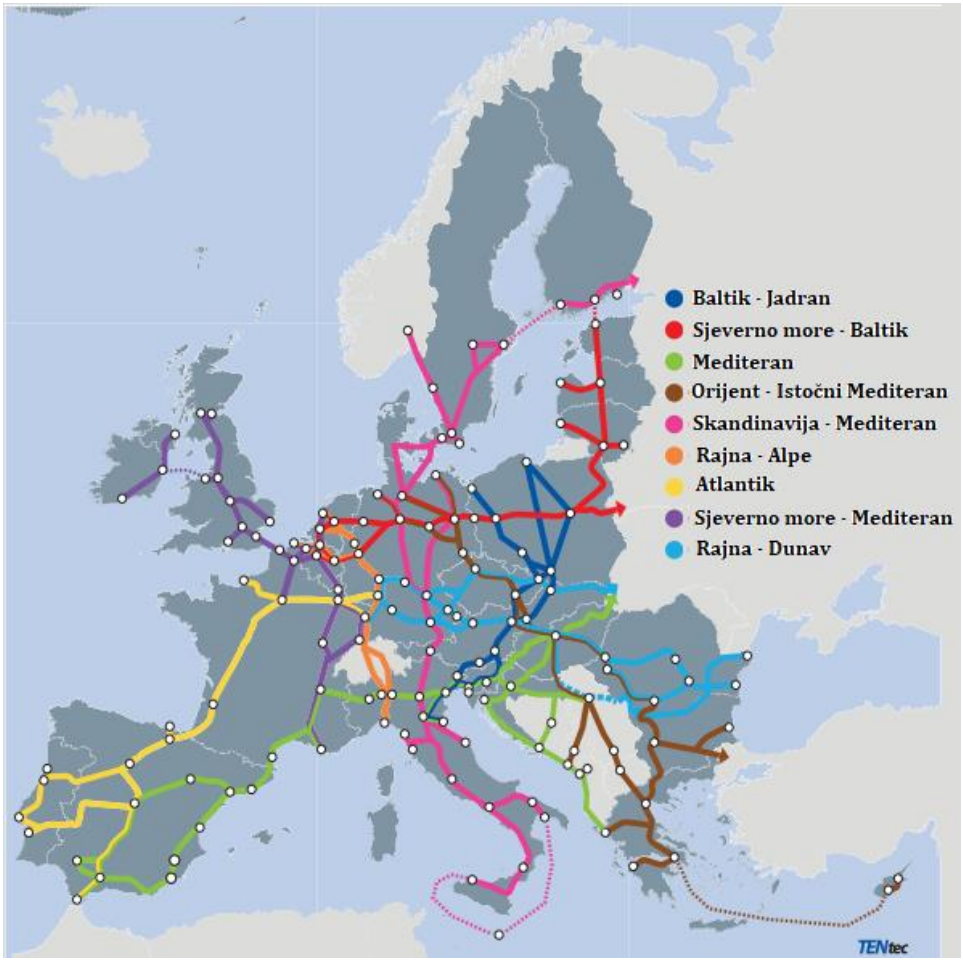
[1] Lisabonska strategija je program koji je povezivao kratkoročne političke inicijative te srednjoročne i dugoročne gospodarske reforme prema kojima je Europska unija do 2010. godine trebala postati najkonkurentnije i najdinamičnije gospodarstvo svijeta. Zasnivala se na (1) ekonomskom segmentu kojim se priprema tranzicija prema konkurentnome, dinamičnom i na znanju zasnovanom gospodarstvu, (2) socijalnom segmentu koji je usmjeren na modernizaciju europskoga socijalnog modela te (3) ekološkom segmentu koji upozorava na činjenicu da gospodarski rast treba uskladiti s razumnom upotrebom prirodnih resursa.

3.2.1. Transeuropska mreža prometnica i njena važnost za razvoj i poslovanje morskih luka

Početkom 1990-ih godina Europska unija je odlučila uspostaviti infrastrukturnu politiku čija je svrha podržavanje učinkovitog razvoj prometa, energetike i telekomunikacija. U 2009. godini politika se ponovno razmotrila što je dovelo do novog zakonodavnog okvira koji je stupio na snagu u siječnju 2014. godine pod nazivom Smjernice Europske unije za razvoj transeuropske prometne mreže. U okviru Instrumenta za povezivanje Europe (*eng. Connecting Europe Facility - CEF*), za promet je na raspolaganje stavljeno 22,4 milijarde eura za razdoblje od 2014. do 2020. kako bi se sufinanciralo Transeuropsku mrežu prometnica (*eng. Trans – European Network – Transport, TEN-T*). Razvoj integrirane europske prometne mreže potiče suradnju između lučkih zajednica te je cilj suradnja prometnih sustava putem povezivanja različitih načina rada. Također podržava širenje uz primjenu modela koji imaju najniže energetske zahtjeve i najmanje moguće negativne učinke na okoliš.

Putem svog investicijskog plana za Europu, Europska unija traži nove i inovativne načine financiranja infrastrukturnih razvoja, uz financiranje iz javnih financijskih institucija, privatnog sektora ili Europskih fondova za strateška ulaganja (EFSU). Program TEN-T sastoji se od stotina projekata: njihov krajnji cilj je osigurati međusobnu povezanost i interoperabilnost prometne mreže Europske unije. U srži je devet multimodalnih prometnih koridora koji su rasprostranjeni diljem Europe i koji bi trebali biti dovršeni do 2030. godine (Eurostat, 2018:153). Cilj TEN-T ali i svake zasebne luke trebao bi biti pojednostavljenje svih procesa u luci tako da se sastoje od aktivnosti koje ili stvaraju vrijednost ili potiču stvaranje vrijednosti. Na globalnoj razini, dovršenje TEN-T imati će pozitivan utjecaj na poslovanje jer će teret lakše dolaziti i transportirati se po Europi. Prometni koridori prikazani su na sljedećem zemljovidu.

Zemljovid 1. Prometni koridori Transeuropske mreže prometnica (TEN-T)



Izvor: Eurostat, 2018:153

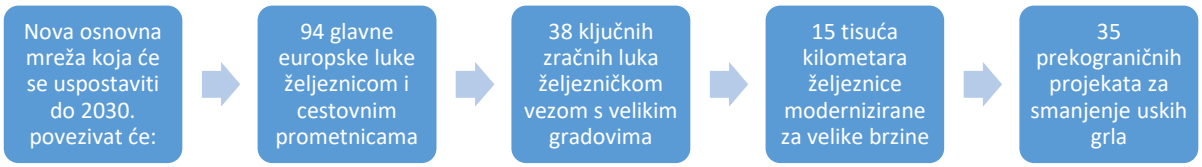
Kao što se može vidjeti iz slike, dovršenjem Transeuropske mreže prometnica, Europa bi trebala imati bolji cestovni i željeznički promet. No, i morske luke imati će pozitivne efekte jer će uključivanje luka u TEN-T osigurati bolju vezu između mora i kopna. Pozitivna strana uključivanja luka u TEN-T je i unaprjeđenje lučkih operacija što se može vidjeti iz broja brodova u lukama, godišnje količine tereta, veličine lučkog zaleđa, vremena boravka broda u luci i vremena prijevoza tereta (Casaca i Marlow, 2007:317). Za brodare je posebno bitan ovaj posljednji aspekt, odnosno vrijeme prijevoza tereta iz jedne destinacije u drugu. Brodarima je važno da je vrijeme prijevoza tereta što kraće kako bi im i troškovi prijevoza bili što manji. Samo ulaganje u infrastrukturu nije dovoljno već je potrebno da luke ulažu i u informacijske tehnologije u tri različita smjera. Prvo je potrebno unaprijediti informacijsku tehnologiju u luci, drugo između luke i korisnika koji posluju s lukom ili u luci i treće između luke i zaleđa.

Navedeno doprinosi standardizaciji lučkih procesa te smanjenju birokratizacije što posljedično olakšava i ubrzava poslovni proces.

Transeuropska mreža prometnica ima utjecaj i na nacionalne vlade koje moraju razviti nacionalnu prometnu politiku koja ispunjava ciljeve transeuropske prometne politike. Prvenstveno je naglasak na pristupačnosti željeznica i cesta koje povezuju luku s lokalnom mrežom prometnica koja dalje povezuje luku s nacionalnom mrežom prometnica. Potrebno je napraviti promjene na operativnoj razini željeznica kako bi teretni vlakovi imali isti prioritet kao i putnički. Ukoliko teretni vlakovi mogu putovati samo u određeno doba dana npr. samo noću, tada je teret u određenom razdoblju u stanju mirovanja čime se ne stvara vrijednost duž opskrbnog lanca. S obzirom na spomenuto, brodari preferiraju unimodalni pristup na štetu multimodalnog ili intermodalnog pristupa (Casaca i Marlow, 2007:318). Ceste koje se nalaze u blizini morskih luka važne su za multimodalne i intermodalne prijevozne lance te one potiču konkurenciju unutar luke koja se tiče korištenja i raspoloživosti poslovnih prostora. Navedeno potiče luke na ubrzanje promjena u fizičkim i informacijskim tokovima kako bi se skratilo vrijeme prijevoza robe kroz luku (Casaca i Marlow, 2007:319).

Sljedeća shema prikazuje ciljeve koji se namjeravaju ostvariti ulaganjem u TEN-T te se može vidjeti kako su morske luke velikim dijelom uključene u razvojne planove.

Shema 6. Rezultati ulaganja u Transeuropsku mrežu prometnica (TEN-T)



Izvor: Izradila autorica prema Ministarstvo mora prometa i infrastrukture, 2019

Europska unija u velikoj mjeri ulaže u infrastrukturu i njeno unaprjeđenje koje će svakako doprinijeti boljoj povezanosti cijele Europe. No, budući da se veliki novčani iznosi izdvajaju za infrastrukturu postavlja se pitanje u kojoj mjeri je ulaganje u infrastrukturu isplativo. Navedeno pitanje istražili su autori Crescenzi i Rodriguez-Pose (2012.) te su došli do zaključka kako je infrastruktura relativno loš prediktor gospodarskog rasta. Autori su između ostalog istražili utjecaj ulaganja u istraživanje i razvoj te ljudskog kapitala koji su se pokazali boljim

pokretačima gospodarskog rasta te smatraju kako bi se dio novčanih sredstava trebao preusmjeriti u njihovom smjeru. No, jedno ne smije isključivati drugo, potrebna su ulaganja i u infrastrukturu i u istraživanje i razvoj te ljudski kapital, ali je istodobno potrebno sagledati u kojoj mjeri je potrebno ulagati u koju stavku. U ovoj doktorskoj disertaciji istražiti će se utjecaj ulaganja u istraživanje i razvoj i ljudski kapital zajedno s poslovanjem morskih luka te utvrditi njihova važnost za rast regionalnog gospodarstva. U istraživanje će se također uključiti i prometna infrastruktura te će se ispitati njena uloga u rastu regionalnog gospodarstva lučkih regija Europske unije.

3.2.2. Analiza i ocjena stanja morskih luka Europske unije

Europska integracija koja uključuje integraciju prometne infrastrukture, poreznih zakona i kulture, omogućuje suradnju između luka u različitim zemljama. Većina korisnika europskih luka su međunarodna poduzeća koja posluju s europskim lukama u mnogim segmentima (de Langen i Nijdam, 2009:163). Na ravnopravnost luka Europske unije utječu politike financijskih tijekova sredstava između tijela javne vlasti, javnih službi, operatora i korisnika, kao i načini naplaćivanja u lukama. Dvije glavne prepreke politikama predstavljaju mnoštvo institucionalnih struktura i poteškoće u prepoznavanju mjera u kojoj postojeće prakse utječu na lučku konkurenciju. Mnoge države članice interveniraju kako bi osigurale ili olakšale restrukturiranje luke putem financijske pomoći koja se javlja u nekoliko oblika poput: nadoknada operativnih gubitaka, davanje zajmova po povlaštenim uvjetima, neoporezivanje dobiti, davanje zakupa zemljišta po povlaštenim uvjetima i besplatno pružanjem administrativnih i tehničkih usluga (Pallis i Verhoeven, 2009:108).

Konkurencija za morski prostor i kumulativni učinak ljudskih aktivnosti na morski ekosustav zahtijevaju zajednički pristup širokom rasponu političkih područja koja utječu na pomorska pitanja. U listopadu 2007. Europska komisija je usvojila Plavi dokument kojim se pokreće Integrirana pomorska politika Europske unije čiji su ciljevi maksimiziranje održivog korištenja oceana i mora, jačanje znanja i inovacija u pomorstvu, osiguravanje razvoja i održivog rasta u lučkim regijama te jačanje europskog pomorskog vodstva. Politika naglašava važnost obalnih regija te ima za cilj razvijanje pomorskih strategija (Eurostat, 2012:192).

Prema podacima Eurostatovog regionalnog ljetopisa iz 2017. godine, više od dvije trećine pomorskog tereta koji se prevozio u 20 najvećih luka Europske unije stiglo je ili je bilo namijenjeno za zemlje koje nisu članice Europske unije čime se dokazuje važnost morskih luka

za povezivanje s ostatkom svijeta (Eurostat, 2017:207). U sljedećoj tablici analizirati će se promet tereta u Europskoj uniji u desetogodišnjem razdoblju, točnije od 2008. godine do 2017. godine. Izračunat je također i verižni indeks koji uspoređuje zadnju promatranu 2017. godinu s prvom promatranom 2008. godinom. Indeks će služiti za analizu povećanja ili smanjenja prometa tereta tokom godina. Budući da lučkih regija Europske unije ima više od 100, teško bi bilo obuhvatiti sve podatke jednom tablicom, stoga se promet tereta na sljedećoj tablici prikazuje na razini država dok se na slici u nastavku prikazuje promet tereta na regionalnoj razini u jednoj godini (2016.).

Tablica 5. Promet tereta u morskim lukama u zemljama Europske unije (u tisućama tona)

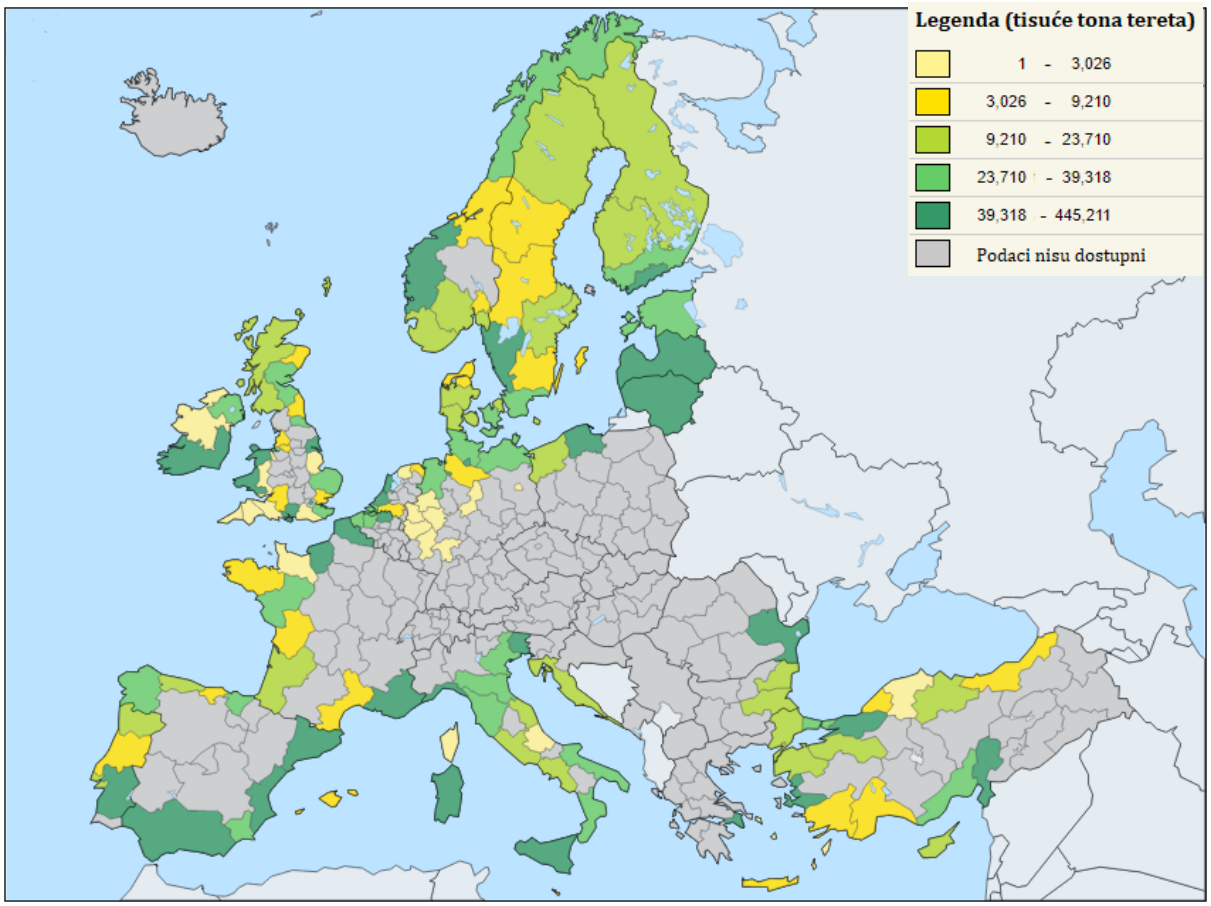
ZEMLJA	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	INDEX 2017/2008
Belgija	243 819	203 368	228 228	232 789	223 987	228 130	237 852	241 459	253 543	257 865	105,76
Bugarska	26 576	21 893	22 946	25 185	26 012	28 841	27 235	27 166	28 685	30 953	116,47
Danska	106 096	90 636	87 068	92 613	87 827	88 406	92 244	95 098	95 830	94 558	89,12
Njemačka	320 636	262 863	275 953	296 037	298 758	297 281	303 742	295 918	297 137	299 189	93,31
Estonija	36 191	38 505	46 026	48 479	43 519	42 908	43 578	34 965	33 596	34 801	96,16
Irska	51 081	41 829	45 071	45 078	47 649	46 722	47 483	50 666	50 758	53 351	104,44
Grčka	152 498	135 430	129 059	135 314	153 317	160 986	168 501	167 036	175 100	181 261	118,86
Španjolska	416 104	363 536	377 095	403 834	419 865	397 462	427 672	447 048	451 255	485 805	116,75
Francuska	351 976	315 562	316 137	322 254	303 269	303 031	298 203	297 880	292 160	302 840	86,04
Hrvatska	29 223	23 377	24 329	21 862	18 972	19 366	18 603	18 930	18 551	20 798	71,17
Italija	526 219	469 879	494 091	499 885	476 823	457 078	443 141	458 020	461 990	475 164	90,30
Cipar	7 962	6 808	6 954	6 564	6 236	7 172	7 186	10 268	10 259	-	-
Latvija	61 430	60 088	58 691	67 016	72 723	67 148	71 836	67 811	60 962	58 687	95,53
Litva	36 379	34 344	37 869	42 661	41 033	39 757	41 105	43 128	46 236	49 856	137,05
Malta	3 373	3 369	3 796	3 345	3 326	3 101	3 460	3 705	3 788	4 114	121,97
Nizozemska	530 359	483 133	538 702	550 745	557 264	558 542	571 636	594 272	588 772	595 810	112,34
Poljska	48 833	45 079	59 507	57 738	58 825	64 282	68 744	69 530	72 926	78 076	159,88
Portugal	65 275	61 714	65 981	67 506	67 875	78 244	80 156	86 769	91 344	93 356	143,02
Rumunjska	50 458	36 094	38 122	38 918	39 520	43 577	43 753	44 533	46 295	46 182	91,53
Slovenija	16 554	13 356	14 591	16 198	16 907	17 184	18 012	19 931	21 171	22 311	134,78
Finska	114 725	93 239	109 326	115 452	105 120	105 117	105 537	99 962	105 887	110 468	96,29
Švedska	187 778	161 823	179 579	177 093	172 976	161 570	167 530	169 685	171 324	175 964	93,71
Ujedinjeno Kraljevstvo	562 166	500 863	511 875	519 495	500 860	503 324	503 171	496 708	484 048	481 815	85,71

Izvor: Izradila autorica prema European Commission, 2019

Najveći promet tereta u zadnjoj promatranoj 2017. godini ali i tokom svih promatranih godina imala je Nizozemska te je prate Španjolska i Ujedinjeno Kraljevstvo na drugom i trećem mjestu. Ukoliko se promatra povećanje tereta u 2017. godini u odnosu na prvu promatranu 2008. godinu, tada je predvodnik Poljska čije povećanje iznosi 59,88%. Najmanje prometa tereta ostvaruju Malta, Hrvatska i Slovenija, sve tri male europske zemlje. No, ukoliko se promatra promjena tereta u 2017. u odnosu na 2008. godinu, Malta ostvaruje povećanje prometa tereta od 21,97%, Slovenija povećanje od 34,78%, dok Hrvatska ostvaruje smanjenje prometa tereta od 28,83% što je ujedno i najveće smanjenje prometa tereta promatranih zemalja. Hrvatska je najveći promet tereta ostvarila u prvoj promatranoj 2008. godini te je nakon toga uslijedilo opadanje količine tereta nakon čega slijedi stagniranje od oko 18 000 000 – 19 000 000 tona tereta. Ukoliko se uspoređuju podaci iz 2017. s 2016. godinom, Hrvatska ostvaruje povećanje prometa tereta ali ono i dalje nije na razini iz 2008. godine.

Kao što je prethodno rečeno, nije moguće obuhvatiti sve lučke regije Europske unije jednom tablicom tokom više promatranih godina, stoga je na sljedećem zemljovidu nalaze se lučke regije i ostvareni promet tereta u 2016. godini koja je zadnja godina s dostupnim podacima na Eurostatu.

Zemljovid 2. Promet tereta u regijama Europske unije u 2016. godini (u tisućama tona)

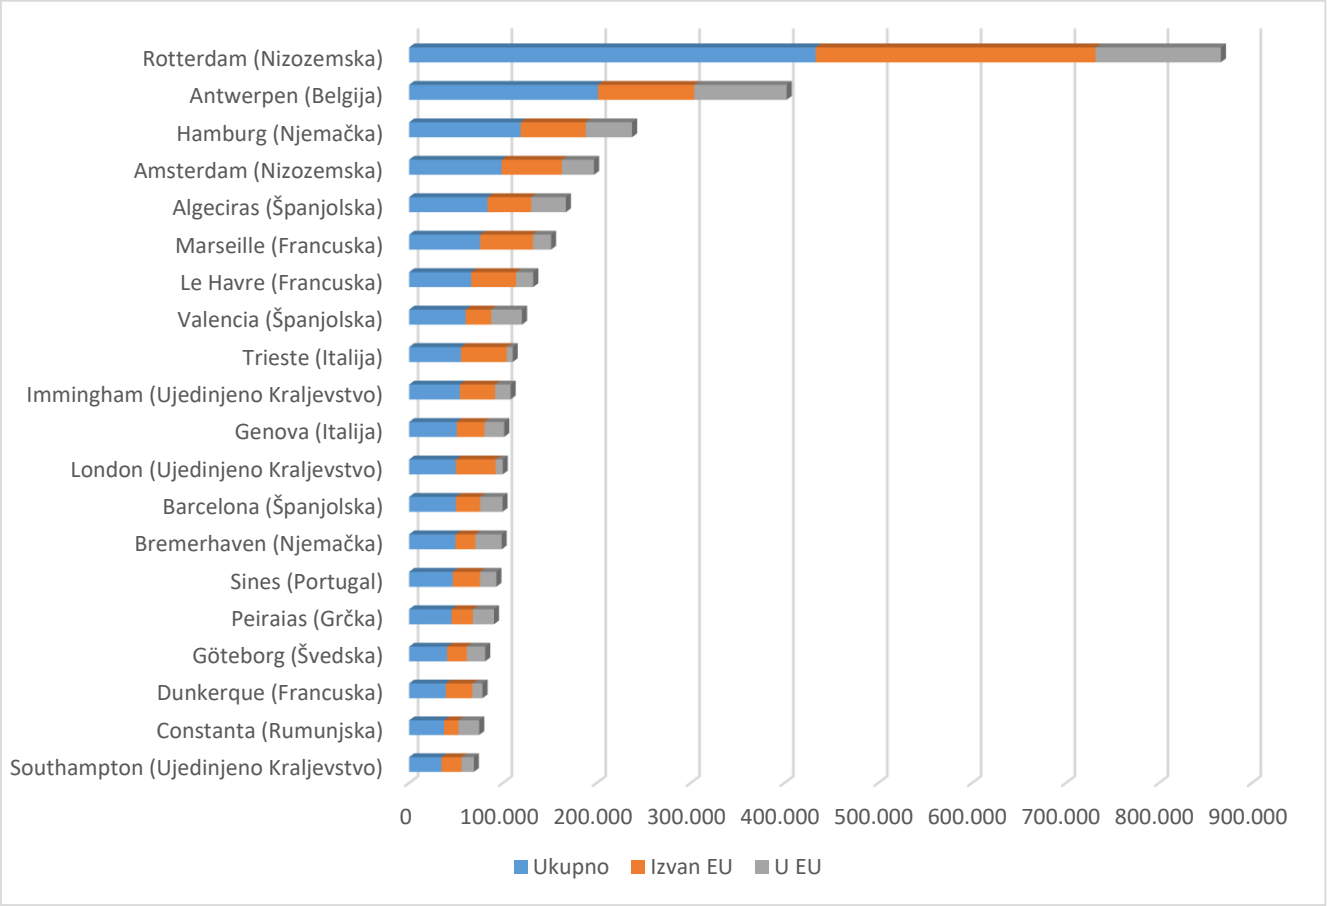


Izvor: European Commission, 2016

Najveći promet tereta od 445 211 000 tona u promatranoj 2016. godini ostvarila je nizozemska regija Zuid-Holland što je analogno podacima na agregatnoj razini gdje je Nizozemska predvodnik u prometu tereta. U navedenoj regiji Zuid-Holland nalazi se luka Rotterdam koja je prva među morskim lukama Europske unije ne samo po prometu tereta već i po razvijenosti i korištenju najsuvremenijih tehnologija. Najmanji promet tereta ostvarile su njemačke regije Hessen, Darmstadt, Münster i Arnsberg. Svaka od navedenih regija ostvarila je po 1 000 tona tereta. Njemačka općenito ima relativno veliku količinu tona tereta, no kao što se moglo vidjeti iz prethodne tablice, promet tereta se u posljednjim godinama djelomično smanjio u usporedbi s 2008. godinom (smanjenje od 6,69%).

Sljedeći grafikon prikazuje 20 najvećih luka Europske unije po prometu tereta u 2017. godini. Glavna područja aktivnosti bila su koncentrirana na obalama Sjevernog mora, u blizini nekih od najgušće naseljenih regija Europske unije koje imaju široku mrežu autocesta, željeznica, rijeka i kanala.

Grafikon 3. Top 20 morskih luka u Europskoj uniji po prometu tereta u 2017. godini (u tisućama tona)



Izvor: Izradila autorica prema European Commission, 2017b

Nizozemska luka Rotterdam je vodeća luka u Europskoj uniji kako po prometu tereta tako i po tehnološkoj razvijenosti. Rotterdam je imao promet tereta od 433 milijuna tona što čini oko 11% ukupnog prometa tereta u Europskoj uniji. Nadalje, druga luka na ljestvici je Antwerpen s 201 milijun tona tereta, treća je Hamburg sa 118 milijuna tona te četvrta Amsterdam s 98 milijuna tona tereta. Navedene luke nalaze se relativno blizu Rotterdama tj. prve četiri luke u Europskoj uniji nalaze se na Sjevernom moru i zajedno čine oko 22% ukupnog prometa tereta u Europskoj uniji.

Top 20 najvećih luka u Europskoj uniji zajedno su imale 1,68 milijardi tona tereta u 2017. godini što čini oko 43% ukupnog tereta koji je ukrcan i iskrcan u svim lukama Europske unije. Od ukupne količine tereta najvećih luka, 63% pristiglo je ili je bilo namijenjeno tržištima izvan Europske unije, dok je 37% pristiglo ili je bilo namijenjeno za tržišta unutar Europske unije.

London i Trst su luke koje su imale više od 85% tereta koji je pristigao ili je bio namijenjen za tržišta izvan Europske unije. Nasuprot tome, luke koje su imale više od 50% tereta koji je pristigao ili je namijenjen za tržišta unutar Europske unije su Constanta, Bremerhaven i Valencia (European Commission, 2017b).

Europska unija ima relativno mnogo morskih luka koje su različitih stupnjeva razvijenosti, no tokom godina ukupan promet tereta u morskim lukama Europske unije raste te nije zanemariv. Dovršenje transeuropske prometne mreže imati će pozitivan učinak na morske luke gdje se očekuje dodatno povećanje prometa tereta kao i cjelokupno poboljšanje poslovanja s manjom birokracijom i učestalijim korištenjem novih tehnologija. Europska integracija omogućila je lakše uključivanje u međunarodno tržište te suradnju između različitih luka i međunarodnih poduzeća. Morske luke svojim poslovanjem stvaraju razne pozitivne efekte na gospodarstvo, između ostaloga izravno i neizravno zapošljavanje. Vodeće europske pomorske zemlje po količini prevezenog tereta su Nizozemska, Španjolska te Ujedinjeno Kraljevstvo. Važno je istaknuti kako je najbolja europska luka Rotterdam istodobno vrlo tehnološki napredna iz čega se može povezati kako je suvremena tehnologija važna za uspješno poslovanje morskih luka. Navedena tema će detaljnije biti obrađena u sljedećem potpoglavlju.

3.3. Suvremeni trendovi u poslovanju morskih luka s posebnim osvrtom na ulaganja u tehnološki napredak

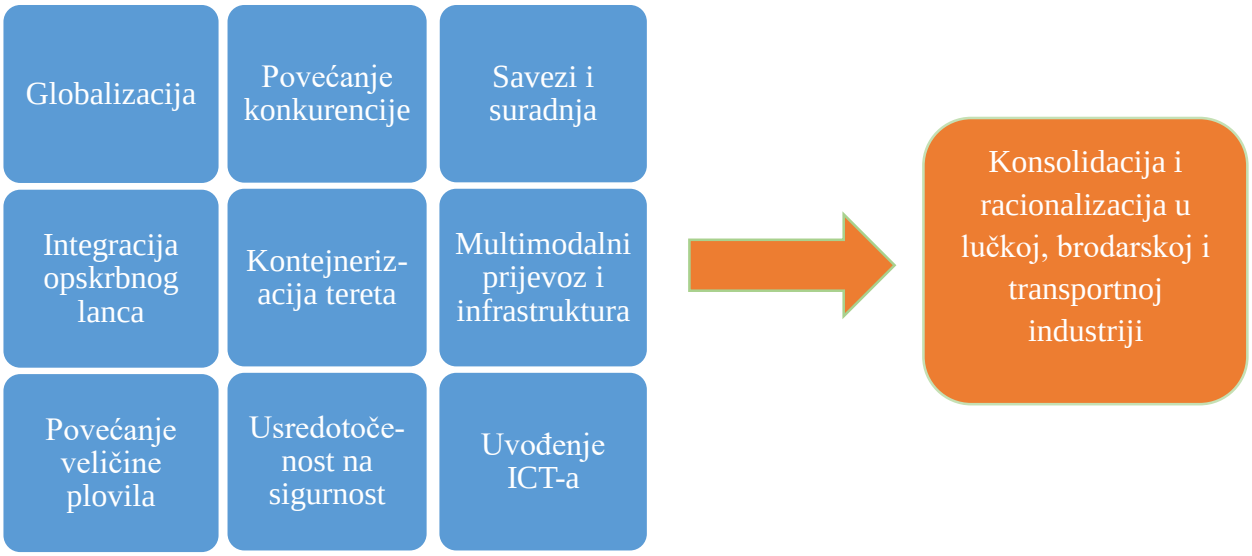
Poslovanje u morskim lukama dinamično je te je sklono promjenama i praćenju novih trendova što je povezano s ulaganjem u nove tehnologije i inovacije. Korisnici morskih luka više ne zahtijevaju samo prevoženje tereta, ujedno je potrebno da rukovanje podacima bude automatizirano te da se primjenjuju suvremene tehnologije. Morske luke prate razne trendove od kontejnerizacije, primjene multimodalnog prometa, povećanja kapaciteta do primjene 5G mreže i Interneta stvari. Kao i u svakom drugom poslovanju, tako i u pomorskom prijevozu, važno je pratiti trendove te primjenjivati nova rješenja i novu tehnologiju. Primjena novih tehnologija te njihov razvoj doprinose kvalitetnom prometnom sustavu što je bitan čimbenika razvoja gospodarstva. Globalizacija i gospodarski rast stvaraju pozitivne efekte na okolinu čime generiraju više razine prihoda čime promet dobiva na važnosti. U nastavku će se navesti neki od trendova u poslovanju morskih luka te mogući smjerovi razvoja. Zatim će se dati osvrt na inovacije u pomorstvu te primjer luke Rotterdam kao najrazvijenije luke u Europskoj uniji.

3.3.1. Postojeći i budući trendovi u poslovanju morskih luka

Prijevoznici u kontejnerskoj industriji u posljednje vrijeme sve više ulažu u izgradnju većih kontejnerskih brodova. Potražnja za kontejnerskim prijevozom sve je veća, a raspoloživost prijevoza ne može u potpunosti zadovoljiti potražnju. Obujam tereta raste oko 4,5% godišnje u usporedbi s kontejnerskom flotom koja raste oko 3,9% godišnje zbog čega se javila potreba za izgradnjom većih kontejnerskih brodova kako bi se uravnotežila ponuda i potražnja. Ukoliko se promatraju prazni kontejnerski brodovi koji nisu bili iskorišteni tokom godine, može se uočiti pozitivan trend. U 2015. godini 330 plovila ukupnog kapaciteta 1,36 milijuna TEU-a je bilo prazno i nekorišteno, dok je 2018. samo 65 brodova ukupnog kapaciteta 191 000 TEU-a ostalo neiskorišteno. Budući da brodovi postaju sve veći, stvara se pritisak na morske luke, terminale i njihove operatore. U nekim lukama dolazi do zagušenja jer im nedostaju valjana rješenja za ulazak brodova u luku te nemaju dovoljno kapaciteta za učinkovito rukovanje teretom (Safety4Sea, 2018).

Što se tiče novih tržišta, pretpostavka je da će Kina i dalje biti važno tržite pomorske industrije te se istovremeno očekuje povećanje potražnje iz drugih regija. Nigerija bi mogla biti jedno od većih tržišta budući da ima 174 milijuna stanovnika te se tokom budućih godina očekuje povećanje. Nadalje, ostale industrije također sve više prilagođavaju svoj teret kontejnerskom prijevozu. Primjer je industrija papira koja je prilagodila veličinu rola papira tako da mogu stati u kontejnere. Kontejnerski prijevoz zastupa koncept „od vrata do vrata“ koji proizvodnju i distribuciju može učiniti kvalitetnijom i bržom te pritom može smanjiti rizik od onečišćenja okoliša. Trend održivosti poslovanja i brige za okoliš važan je čimbenik u brodarstvu te u poslovanju morskih luka općenito. Industrija ulaže u nove tehnologije kako bi se smanjio utjecaj na okoliš, a prijevoznici u brodarstvu moraju slijediti razne propise te prilagoditi svoje brodove u skladu s njima. Navedeno utječe na troškove prijevoza ali istodobno pruža pozitivnu sliku o prijevoznicima čime stvaraju konkurentsku prednost jer brinu za okoliš i nude nova održiva prometna rješenja (Safety4Sea, 2018). Na sljedećoj shemi mogu se vidjeti neki od glavnih trendova u poslovanju morskih luka.

Shema 7. Trendovi u poslovanju morskih luka



Izvor: Izradila autorica prema Deloitte, 2015

Globalizacija utječe na rast bruto domaćeg proizvoda čime raste robna razmjena, a posljedično i pomorska trgovina. Povećanje konkurencije također je jedno od trendova u morskim lukama te su najuspješnije one luke koje se uspijevaju prilagoditi novonastalim uvjetima. Što se tiče saveza i suradnje, određena pomorska poduzeća u proteklih nekoliko godina dominirala su tržištem te vršila razna preuzimanja i sklapala saveze s ostalima. Nadalje, pojavili su se globalni lanci opskrbe, a fokus se pomaknuo s performansi luke na performanse opskrbnog lanca. Kapacitet i broj kontejnerskih brodova značajno se povećao, kao i njihova veličina te najnoviji kontejnerski brodovi mogu primiti više od 20 000 TEU-a. Bitan aspekt je i usredotočenost na sigurnost gdje se značajna sredstva troše kako bi teret sigurno došao na odredište. Nadalje, razvijene luke vrlo brzo usvajaju sofisticirana ICT rješenja za optimizaciju logistike (Deloitte, 2015).

Navedeni su trendovi u poslovanju morskih luka koji su se do sada pojavljivali, no postoje i trendovi koji se predviđaju u budućnosti. Brzi razvoj 5G mreže odgovoriti će na zahtjeve automatizacije i umjetne inteligencije koji su potrebni za zadovoljenje rastućih operativnih zahtjeva. Luka Hamburg je testirala 5G tehnologiju koja se priprema postati čvorištem industrijske mobilne komunikacije sljedeće generacije. Prema istraživanjima luke Hamburg, navedena tehnologije će pružiti pomoć inženjerima prilikom praćenja i optimiziranja izgradnje luka i cjelokupnog sustava. Moguće je da će se 5G mreže primjenjivati i u svakodnevnim operacijama u većim lukama i terminalima jer one pružaju mogućnost sigurnog prijenosa

podataka u nekoliko milisekundi te mogu podržati digitalnu transformaciju industrije kontejnerskih brodova, sigurno povezujući luke i logistička poduzeća kao temelj za inteligentniji opskrbni lanac. Pojava i korištenje 5G mreže omogućiti će pojavu i razvoj drugih tehnologija kao što je koncept Internet stvari *(eng. Internet of Things – IoT)* koji je sredstvo povezivanja fizičkih objekata. Morske luke i terminali mogu ga implementirati na način da lučka oprema prenosi podatke putem senzora kako bi se postigle neovisnije i učinkovitije operacije. U konačnici, stvoriti će se velika količina podataka na koje se luke i terminali mogu usredotočiti ukoliko žele poboljšati svoje usluge te razviti nove usluge i platforme za iskorištavanje novonastalih informacija (The Motorways of the Sea Digital Multichannel Platform, 2019).

Mnoga pametna rješenja temeljena su većinom na prethodno spomenutom Internetu stvari (IoT) te potiču automatizaciju i mogu biti široko primjenjiva u velikim lukama i na terminalima. S druge strane postoji ideja Interneta vozila *(eng. Internet of Vehicles – IoV)* koja je nešto manje razvijena. Navedena tehnologija omogućila bi učinkovitije upravljanje lučkim prometom te omogućila povećanu sigurnost i manje sudara vozila. Neke luke su već uvele koncept Interneta vozila u svoje poslovanje te je jedan od primjera luka Valencia koja zajedno s kompanijom MSC Mediterranean Shipping Company radi na njegovom integriranju. Kamioni MSC-a koji posluju u Španjolskoj opremljeni su uređajima za Internet stvari kojima prate vozila u stvarnom vremenu te pružaju potporu luci Valencija u predviđanju potencijalnih gužvi. Uređaji za praćenje mogu biti postavljeni ne samo na kamione već i na druga mjesta npr. na parkirališne i lučke objekte gdje bi mogli pružati informacije o dostupnim mjestima, najoptimalnijem putu do njih i očekivanom trošku. Sve navedeno dovodi do smanjenja vremena isporuke te ušteda u troškovima (The Motorways of the Sea Digital Multichannel Platform, 2019).

Očekuje se daljnja globalizacija te prirodni i demografski rast što će potaknuti rast globalnog teretnog prometa. Očekuje se da će azijske zemlje dominirati u svjetskom brodarstvu te da će se luke Azije i Afrike sve više povezivati. Nadalje, očekuje se i pojava neusklađenosti ponude i potražnje za fosilnim izvorima energije te povećanje robnih tokova sirovina iz Afrike. Trend urbanizacije podrazumijeva da luke moraju biti jače povezane s većim gradovima te da imaju brzu željezničku vezu. Udio obnovljivih izvora energije raste te se očekuje povećanje bio goriva i kemijskih proizvoda temeljenih na biološkom razvoju. Tehnologija će također znatno promijeniti i način organiziranja i provođenja logistike. Digitalizacija će omogućiti optimizaciju postojeće infrastrukture, smanjujući potrebu za ulaganjem u dodatnu

infrastrukturu. Očekuje se da će autonomni brodovi biti sve zastupljeniji kao i upotreba dronova za inspekciju. 3D printanje omogućuje određenim proizvođačima otklanjanje otpreme te može promijeniti način na koji će se brodovi opskrbljivati u budućnosti u smislu da postoji mogućnost da će biti više isporuka sirovina nego krajnjih proizvoda. Također će proizvođači slati materijale na recikliranje i obnovu kao odgovor na nove proizvodne i okolišne zahtjeve. Korištenje različitih upravljačkih sustava i povećanje automatizacije općenito, smanjiti će rizik od ljudskih pogrešaka, a automatizacija će povećati pouzdanost sustava čime će se ograničiti broj kašnjenja. Takvi sustavi imaju i lošu stranu, a to su hakerski napadi na što će luke morati obratiti posebnu pozornost (Deloitte, 2015).

U poslovanju morskih luka sve će više biti potrebno zapošljavati visokoobrazovane ljude, posebice one koji imaju obrazovanje iz STEM područja *(eng. Science Technology Engineering Mathematics).* Znanje i inovacije postaju sve dominantniji čimbenici u određivanju konkurentske snage luke te se konkurencija za kvalificirane zaposlenike povećava. Potrebna je suradnja između sveučilišta i luka kako bi se osigurali kvalitetni ljudski potencijali koji su specijalizirani za područja koja su lukama potrebna. Očekuje se daljnja integracija opskrbnih lanaca gdje veze sa zaleđem luke postaju vrlo bitan aspekt poslovanja. Uloga lučke uprave mijenjati će se od vlasničke uloge do aktivnog sudionika u lancu opskrbe, dok će špediterska poduzeća, pružatelji logističkih usluga, operatori terminala postati sve globalniji. Veličina i kapacitet brodova, vlakova i kamiona ubrzano raste te se očekuje njihovo daljnje povećanje. Veći brodovi zahtijevaju i veću dubinu, šire pristanište i veće dizalice što luke moraju unaprijed planirati. Fokus na održivost luke jednako je bitan te propisi o zaštiti okoliša postaju sveobuhvatniji i stroži. Luke se mogu fokusirati na energetsku učinkovitost, recikliranje ostataka materijala, skladištenje i ponovno korištenje ugljika čime se istodobno promoviraju i pružaju bolju sliku o sebi i svojem poslovanju (Deloitte, 2015). Nadalje, blockchain tehnologija napreduje što može dovesti do novih mogućnosti za inovacija u brodarstvu budući da postoji potreba za zajedničkom platformom i većom transparentnošću u cijelom logističkom lancu.

3.3.2. Inovacije i tehnološki napredak u poslovanju morskih luka

Inovativni kapaciteti u poslovanju postaju sve češće pokazatelji gospodarskog uspjeha poduzeća i sektora odnosno luka i sektora brodarstva (Geerlings i Wiegmans, 2018:332). Definicije tehnike i tehnologije razlikuju se u mnogočemu stoga je potrebno definirati oboje. Tehnika se može definirati kao tvorevina koja olakšava aktivnosti rukovanja kao što je na primjer sofisticirani IT sustav za optimizaciju operacija kontejnera. S druge strane, tehnologija

je usko povezana sa znanjem te je usmjerena na rješavanje određenih izazova. Tehnologija se ne smije promatrati kao proces koji započinje i završava u jednom ciklusu, već kao mreža koju je konstantno potrebno nadograđivati. Ona se može definirati kao skup svih kognitivnih i društvenih koncepata te tehnika koje društvo koristi u rješavanju izazova te se sastoji od kombinacije postojećih teorija, ciljeva, postupaka i prakse (Geerlings, 1998:41).

Razvoj i primjena tehnologije doprinosi učinkovitom prometnom sustavu, što je ključni preduvjet za gospodarski rast lokalne, regionalne i međunarodne mobilnosti. Slobodan prijevoz robe smatra se bitnom sastavnicom modernog društva. Integracija svjetskog tržišta, gospodarski rast i više razine prihoda čine promet vrlo važnim gospodarskim sektorom. Koristi od transporta i tehnološkog razvoja, međutim, imaju visoku cijenu koja se manifestira u raznim aspektima. Na primjer, niti jedan način motornog prometa nije dobar za okoliš iako pomorski prijevoz, u odnosu na zračni prijevoz, ima manji negativni utjecaj. Određeni aspekti smatraju tehnologiju uzrokom mnogih problema, dok je drugi vide kao potencijalni odgovor na nove potrebe i nove izazove kao što su smanjenje utjecaja na okoliš i korištenje alternativnih izvora energije ali i poboljšanje učinkovitosti u poslovanju morskih luka (Geerlings i Wiegmans, 2018:335).

Klasificiranje inovacija u pomorskom prijevozu može se razvrstati u nekoliko kategorija (Geerlings i Wiegmans, 2018:337-339):

1) Inovacije u dizajnu i izradi plovila
2) Inovacije tehnologije brodskih motora
3) Inovacije na području tehnologije goriva
4) Inovacije na ostalim tehnološkim područjima
5) Inovacije u razvoju infrastrukture i same luke
6) Integracija i prijenos tehnologije

Inovacije vezane uze dizajn i izradu plovila vežu se uz konstrukciju plovila. Plovila koja imaju manju masu i niži aerodinamični otpor imati će manju potrošnju goriva i manju emisiju stakleničkih plinova. Inovativni napori usmjereni su na odabir materijala, metode gradnje te konstruiranje oblika i veličine plovila. Nadalje, alternativne mogućnosti dizajna uključuju uporabu novog laganog materijala te računalno potpomognuto projektiranje koje može poboljšati sposobnost dizajnera da minimizira težinu materijala koji se koristi za određenu funkciju. Inovacije u tehnologije brodskih motora poboljšavaju učinkovitost potrošnje goriva i smanjuju razinu emisije ugljičnog dioksida i ostalih štetnih plinova. Tri područja koja imaju

najveći inovativni potencijal unutar ove kategorije su mjere za smanjenje gubitaka energije u motorima s unutarnjim izgaranjem, suzbijanje emisije štetnih plinova te smanjenje buke motora. Tehnologija goriva i inovacije na tom području prvenstveno zahtijevaju brigu o klimatskim promjenama. Inovacije na ovom području imaju četiri glavna dijela na kojima mogu raditi poboljšanja: eklektični pogon, vodik, bio gorivo i ugljikovodično gorivo. Električna energija i vodik smatraju se izvorima energije koji ne onečišćuju okoliš te su povezana s obnovljivim izvorima energije. Alternativna goriva proizvode manju emisiju stakleničkih plinova po jedinici korisne energije te mogu poslužiti za smanjenje emisije ugljičnog dioksida. Ona također nude mogućnost da se smanji ovisnost o neobnovljivim izvorima fosilnih goriva dobivenim iz nafte. Inovacije na području tehnologije goriva imaju četiri glavna područja na kojima mogu raditi poboljšanja: eklektični pogon, vodik, bio gorivo i ugljikovodično gorivo.

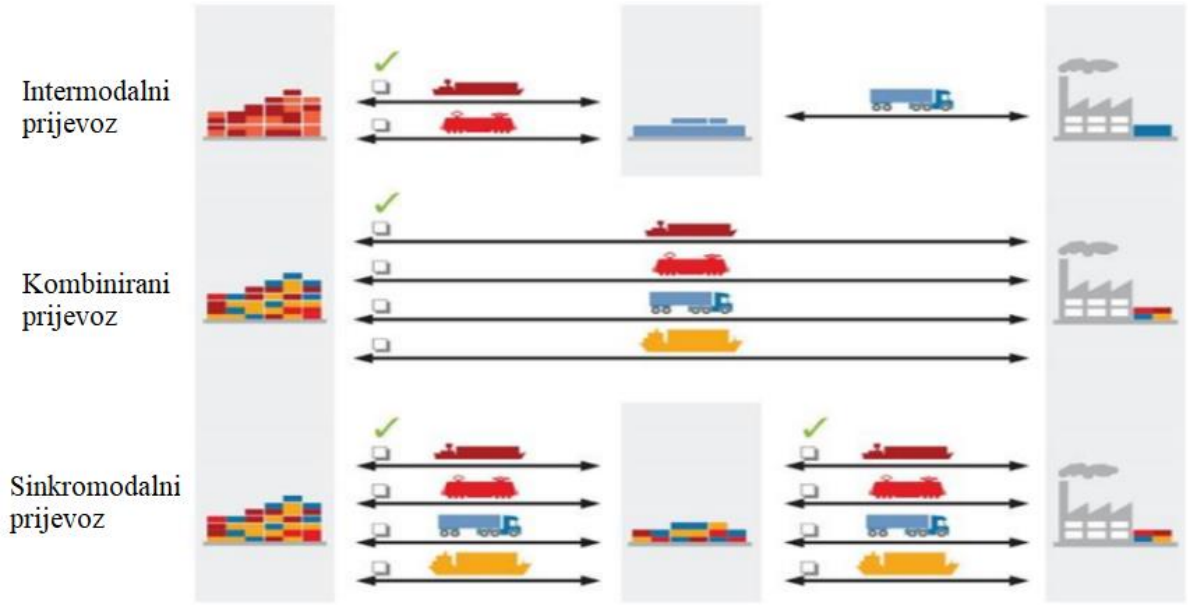
Ostala tehnološka područja vezana uz pomorski promet na kojima se odvijaju inovacije obuhvaćaju kontrolu prometa. Ona podrazumijeva proces koji omogućuje nesmetani protok prometa. Sustavi kontrole prometa mogu se unaprijediti kako bi se poboljšali prometni tokovi te kako bi se utjecalo na manje zagađenje okoliša. Inovacije u razvoju infrastrukture i same luke mogu pridonijeti zaštiti kvalitete života građana osiguravanjem mogućnosti da se promet odvoji od drugih aktivnosti u gradu. No, istodobno, sama infrastruktura može smanjiti kvalitetu života svojim vizualnim karakteristikama. Postoje mogućnosti za bolje usklađivanje učinaka putem korištenja novih materijala i korištenja novih tehnologija.

Integracija i prijenos tehnologije također su važan aspekt inovacijskih aktivnosti. Nije dovoljno samo da se određeni aspekt poslovanja inovira već je potrebno da svi sudionici novu inovaciju prihvate te implementiraju u poslovanje što često zna biti veliki izazov. Nova tehnologija zahtijeva nove sporazume i pravila te nove načine upravljanja koji posljedično zahtijevaju novu tehnologiju. Novi načini upravljanja u literaturi se nazivaju i *„orgware“. Orgware* je definiran kao mrežna sastavnica informacijskih sustava koja obuhvaća sve metode, propise i specifikacije kojima se usklađuje djelovanje svih sastavnica u poslovnom sustavu. U lučkom sustavu *orgware* uključuje nove ugovore i modele između brodara, špeditera, brodarskih poduzeća, operatera terminala, transportnih poduzeća, države i ostalih sudionika na tržištu (Geerlings i Wiegmans, 2018:337-339).

3.3.3. Razvojne mogućnosti poslovanja morskih luka u budućnosti

U sektoru unutarnjih plovnih putova razvijaju se mnoge inovacije koje su većinskim dijelom orijentirane na propulziju plovila što znači da su usmjerene na postojeće tržište. Nešto manji broj inovacija usmjeren je na povećanje korištenja ICT-a, a zadnja skupina inovacija usmjerena je na stvaranje manjih mreža za prijevoz paletizirane robe ili za prijevoz robe unutar grada pomoću unutarnjih plovnih putova i kanala. Inovacija koja ima najbolju mogućnost napretka i implementacija je sinkromodalni prijevoz. Sinkromodalni prijevoz je vrsta intermodalnog prijevoza kod kojeg se koriste paralelni načini prijevoza i rukovanja na terminalnima u mreži različitih poduzeća. Pošiljatelj daje teret davatelju usluga, a davatelj usluga odlučuje o vrsti prijevoza koja je najpodobnija (željeznica, unutarnja plovidba ili kamioni). Dok se u intermodalnom teretnom prijevozu željeznica, unutarnji plovni putovi i kamionski prijevoz međusobno natječu, u sinkromodalnom prijevozu ti načini prijevoza djeluju na koordiniran način (Geerlings i Wiegmans, 2018:340). Primjer sinkromodalnog prijevoza može se vidjeti na sljedećoj shemi gdje se uspoređuje s intermodalnim prijevozom i kombiniranim prijevozom.

Shema 8. Prikaz sinkromodalnog prijevoza



Izvor: Prilagodila autorica prema Control Tower, 2018

Prednost sinkromodalnog prijevoza je pružanje mogućnosti odabira optimalnog načina prijevoza koji se temelji na različitim kriterijima koji su bitni poduzećima kao što su troškovi ili vrijeme prijevoza. Sinkromodalni prijevoz je fleksibilan i pruža pravovremenu isporuku

kupcu. On je temelj za sinkro logistiku koja se temelji na sinkronizaciji različitih odjela u poduzeću te na sinkronizaciji opskrbnog lanca (Control Tower, 2018). Omogućava korištenja naprednih IT paketa, povećano i optimalno korištenje prijevoznih sredstava i terminala čime se nudi bolja usluga potencijalnim kupcima. Navedeno omogućuje veću fleksibilnost, dobro usklađivanje s ciljevima politike Europske komisije, poboljšanu pouzdanost intermodalnog teretnog prometa i poboljšanu održivost prometnog sustava. No, postoje i određeni nedostaci, prvenstveno potreba za usklađivanjem IT sustava svih sudionika što je skupo i može usporiti ili spriječiti formiranje sinkromodalnog prijevoza. Postoji mogućnost preferencije morskog i željezničkog prijevoza nad cestovnim prijevozom što može dovesti do smanjenja obima posla cestovnih prijevoznika. Nadalje, konkurencija između različitih načina prijevoza trebala bi imati jednake uvjete te bi određena sinkromodalna rješenja mogla eliminirati mnogo konkurencije zbog čega postoji mogućnost da europske vlasti to ne bi dopustile (Geerlings i Wiegmans, 2018:340).

Postoje mnoge zapreke za uspješno uvođenje naprednih tehnologija, odnosno postoje tehnološke, ekonomske, institucionalne i političke zapreke. Osim toga, postoji paradoks na koji je potrebno obratiti pozornost. Tehnološka rješenja mogu biti politički poželjnija jer uključuju najmanji iznos državne intervencije. No, da bi se tehnologija smatrala isplativom mora biti ekonomski korisna za njene dobavljače i kupce. Ako se unaprijede ekološki najštetniji načini prijevoza, oni će imati utjecaja i na smanjenje operativnih troškova. U tom slučaju mogu istodobno privući promet od manje štetnih ka štetnijim načinima prijevoza što bi bilo kontraproduktivno (Geerlings i Wiegmans, 2018:345).

Nadalje, još neke od razvojnih mogućnosti luka i njihovog logističkog lanca moru ići u sljedećim smjerovima:

1) Primjena oblaka *(eng. cloud)* u poslovanju luka
2) Primjena *blockchain* tehnologije u poslovanju luka
3) Primjena dronova u poslovanju luka

Luke i terminali teže većoj povezanosti te pokušavaju pronaći najučinkovitiji način prelaska na automatizirane procese te se kao jedno od rješenja postavlja korištenje oblaka *(eng. cloud).* Platforme za planiranje ruta koje se temelje na oblaku omogućuju korisnicima dijeljenje informacija u stvarnom vremenu. Povezivanje putem oblaka također pruža platformu za operativne sustave Interneta stvari, omogućujući komunikaciju unutar luka kao i između luka.

Primjer je luka Antwerpen koja u sklopu svojeg projekta *„Smart Port Vision“* koristi automatizaciju koja se temelji na oblaku. Oblak je djelotvorna baza za prikupljanje i korištenje korisnih podataka, no ako se stavi u kombinaciju s Internetom stvari može doći do još većega poboljšanja (Port Technology, 2018).

Blockchain tehnologija se od svojih početnih faza razvoja vrlo brzo širila u različitim industrijama. Poslovanje u morskim lukama i logistika smatraju se podobnima za provedbu *blockchain-a* zbog velikog broja sudionika uključenih u logističke procese. Unatoč brojnim privatnim projektima i *start-up-ovima* koje provode luke, posebice luka Rotterdam, još uvijek postoji velika neizvjesnost oko implementacije i prednosti *blockchain* rješenja za poslovanje morskih luka. Prema autoru Francisconi (2017:5-6) *blockchain* tehnologija u poslovanju luka može se implementirati na četiri različita načina. Prvi je način korištenje *blockchain* tehnologije za pohranu i prijenos dokumentacije tereta te bi se time osigurale točne i dosljedne informacije o dokumentaciji o teretu diljem logističkog lanca. Drugi način se fokusira na procesne informacije gdje se omogućava vidljivost svih procesa čime bi se mogla povećati koordinacija među svim sudionicima. Time bi se ubrzalo planiranje prijevoza tereta u zaleđe, kao i carinjenje. Treći način primijenio bi se na poboljšanje trgovinskog financiranja čime bi se smanjilo vrijeme potrebno za komercijalna odobrenja. Omogućila bi se vidljivost cjelokupnog procesa stranama koje se nalaze izvan luka (npr. banke, osiguranja) što bi bilo korisno za rješavanje uskih grla koja nastaju zbog sekvencijalnih aktivnosti kao što su komercijalna odobrenja. Četvrti način primjene *blockchain* tehnologije je automatiziranje operacija koristeći Internet stvari i pametne ugovore.

Korištenje dronova također je novitet u poslovanju morskih luka koji ima potencijal za daljnji razvoj. Prvenstveno se dronovi koriste za praćenje i kontrolu emisija plinova budući da je s njima lakše doći do plovila koja su na moru (Xia *et al.* 2019:174). Dronovi se također mogu koristiti u procesu logistike. Njima se mogu obavljati manje logističke operacije isporuke paketa i upravljanja skladištem. U kombinaciji s dobrim logističkim softverom, dronovi mogu poboljšati učinkovitost poslovanja. Amazon je dobio patent za dostavu paketa dronovima koji mogu odgovoriti na razne ljudske geste kao što su palac gore, povik ili mahanje rukom što može uzrokovati da dron promijeni svoje ponašanje. Nadalje, Wallmart također testira dronove u svojim skladištima posljednjih nekoliko godina predviđajući da će oni biti budućnost upravljanja skladištima (Capterra, 2018).

3.3.4. Primjer implementacije inovacija i suvremenih tehnologija u poslovanju – luka Rotterdam

Nizozemska je vrlo napredna po pitanju inovacija u pomorskom prometu što se u konačnici očituje u rezultatima poslovanja. Osim luke Rotterdam koja je vodeća luka po primjeni novih tehnologija ali i po količini prevezenog tereta u Europi, Nizozemska ima i poseban Institut za istraživanje mora *(eng. Dutch Maritime Research Institute Netherlands - MARIN).* Institut provodi istraživanja u pomorskom sektoru te pruža nova inovativna dizajnerska rješenja čime spaja akademska istraživanja i potrebe tržišta. Glavne teme kojima se Institut bavi su sljedeće (Dutch Maritime Research Institute Netherlands (MARIN)):

1) Održiva propulzija
2) Utjecaj valova i hidro struktura
3) Manevriranje
4) Pomorstvo, oceanski inženjering i obnovljivi izvori energije
5) Autonomija i kontrola

Institut ima rasprostranjenu mrežu sudionika: brodograditelje, vlasnike pomorskih flota te razna međunarodna poduzeća na pomorskom tržištu. Pomorska industrija ima sve kraće poslovne cikluse i sve je veća globalna konkurencija te se Institut nastoji brzo priključiti u različite projekte čime rješava poslovne izazove. Institut ulaže napore u inovativnost, neovisnost i pouzdanost te time stvara snažnu sinergiju s pomorskom industrijom (Geerlings i Wiegmans, 2018:339).

Opsežna mreža znanja nalazi se u blizini lučkog područja luke Rotterdam, uključujući centre izvrsnosti i druge institute znanja kao što su Erasmus Sveučilište Rotterdam, Delftsko sveučilište za tehnologiju te Fakultet za brodarstvo i transport. Nadalje, u blizini se nalaze i svjetski poznati operatori i objekti za nautičku obuku te inovacijski objekti kao što je RDM-ov centar ekspertize i inovacije. Luka Rotterdam također ima razvijenu „pametnu“ infrastrukturu za ICT modalitet kako bi mogli omogućiti velike i napredne tokove podataka. Nadalje, mnoga vodeća poduzeća nalaze se u luci Rotterdam, primjerice AkzoNobel, Broekman Logistics, Maersk, SBM Offshore, Shell i mnogi drugi od kojih je većina aktivna na međunarodnoj razini i visoko specijalizirana. Budući da navedena poduzeća imaju vrlo visoke zahtjeve u pogledu proizvoda i usluga, oni svojom prisutnošću u luci Rotterdam stvaraju pritisak za inovacije i povećanje produktivnosti (van den Bosch *et al.,* 2018:46).

Luka Rotterdam prva je luka na svijetu s automatskim vođenim vozilima *(eng. Automated guided vehicles – AGV)* te prva s automatiziranim terminalima. Poslovanje na terminalima u luci Rotterdam odvija se 24 sata dnevno, 7 dana u tjednu, a svi terminali opremljeni su najsuvremenijom, učinkovitom i održivom opremom. Štoviše, terminali su izravno povezani sa željezničkim, cestovnim i unutarnjim plovnim putovima za brze veze s ostatkom Europe. Sve navedeno rezultira visokim kapacitetom rukovanja i impresivnom razinom produktivnosti. Lučka uprava Rotterdam uložila je 200 milijuna eura u proširenje jednog od lučkih bazena zahvaljujući čemu luka Rotterdam može primiti današnja najveća plovila te je pripremljena za buduću generaciju kontejnerskih prijevoznika (Port of Rotterdam, 2018a).

Luka je specijalizirana za digitalizaciju te potiče i ostale luke te lučke korisnike i pružatelje usluga da se preusmjere na digitalizaciju. Njeni softverski inženjeri i znanstvenici koji se bave podacima prikupljaju, analiziraju i obogaćuju podatke i poslovanje luke. Oni zajedno s IT poduzećima rade na softverskim i podatkovnim tješenjima koja razvijaju za lučki sektor. U određenim dijelovima luka ima potpuno digitalizirane terminale gdje fizičke osobe upravljaju dizalicama i drugim operacijama iz svojih ureda. Lučka uprava, skladišta, poduzeća za vuču, obalna straža, brodari, inspekcijske službe i lučki klijenti u luci Rotterdam su usmjereni na digitalizaciju. Svi uključeni u lučki proces aktivno dijele informacije integrirajući svoje IT sustave unutar jedinstvenog digitalnog okruženja. Nadalje, luka Rotterdam potiče da i sudionici u zaleđu koriste digitalnu komunikaciju s lučkom zajednicom gdje uključuju željezničke i brodske operatere, brodare, kopnene terminale itd. Na taj način prijevoz tereta može se pratiti na Internetu što dovodi do koordinacije i veće transparentnosti i učinkovitosti poslovanja. Luka Rotterdam predviđa budući scenarij gdje će se digitalna komunikacija između luke i njezinog zaleđa povećati na globalnu razinu. Luka bi tada trebala razmjenjivati digitalne informacije širom svijeta s drugim lukama i logističkim poduzećima. Tranzicija u potpunu digitalizaciju je još uvijek u počecima, no ima veliki potencijal. Potpuna digitalizacija omogućila bi lukama veću učinkovitost čime bi se smanjili troškovi i vrijeme čekanja u luci te bi se ubrzao promet tereta (Port of Rotterdam, 2018c).

Neke od usluga koje pruža luka Rotterdam, a koje su povezane s digitalizacijom su sljedeće: Portmaster, Portinsider, Navigate, Pronto, OnTrack i Streamline te su ukratko objašnjene u nastavku. Portmaster je sustav za upravljanje lukama koji integrira alate i module za planiranje, nadzor i administraciju u jedinstveni sustav. Nadzorne ploče pružaju informacije u stvarnom vremenu o brojnim područjima kao npr. dolazak i odlazak plovila, čime se omogućuje

optimalno planiranje i praćenje potrebnih informacija. Nadalje, Portinsider je središnji sustav za luke koji objedinjuje sve informacije za optimizaciju ticanja brodova u luci te koordinira rukovanje teretom unutar luke i putovanje tereta u zaleđe. Sustav Navigate je sveobuhvatna online platforma koja čini mrežu vezova, terminala i drugih objekata i usluga u luci. Alat korisnicima omogućuje usporedbu različitih vezova, modaliteta i potrebnih usluga za odabir i planiranje optimalne rute. Aplikacija pod imenom Pronto služi brodarskim poduzećima, agentima, terminalima i drugim pružateljima usluga za optimalno planiranje, izvršavanje i nadzor svih aktivnosti tijekom ticanja broda na temelju standardizirane razmjene podataka. Svaki dolazak broda u luku traži mnogo različitih operacija u pravom trenutku. Razmjena podataka o planiranom, očekivanom i ostvarenom vremenu omogućuje bolje planiranje ticanja brodova te manje čekanja. Prema informacijama luke Rotterdam brodovi mogu ostvariti oko 20% uštede vremena čekanja koristeći aplikaciju. Razne druge prednosti aplikacije Pronto su bolja iskorištenost kapaciteta terminala poboljšanjem vremena obrta i smanjenjem vremena čekanja, više vremena za usluge klijentima, bolja usluga zahvaljujući boljoj predvidljivosti i bržem razumijevanju trenutne situacije, povećana predvidljivost količine tereta te smanjenje emisije CO_2.

Usluga OnTrack vezana je za poslovanje željeznice koje se odvija nakon što teret dođe u luku. Za mnoge luke, željeznički je promet vitalna komponenta poslovanja prema zaleđu. Ideja za razvoj usluge nastala je iz želje za pristupom točnim informacijama u stvarnom vremenu o kapacitetu vlakova, rasporedu vožnje i njihovom statusu. OnTrack pruža uvid u očekivano vrijeme dolaska i rukovanje vlakovima na terminalu te pruža točne informacije o željeznici i teretu kroz cijeli lanac. Nadalje, u luku Rotterdam pristižu milijuni kontejnera te su raspoređeni na više kontejnerskih terminala. Brodarska poduzeća žele što brže nastaviti svoj put te preferiraju da se brzo istovari teret te se taj teret na terminalima naknadno razmjenjuje s drugim terminalima za prekrcaj i tranzit. Navedeni proces zahtijeva da brodarska poduzeća stupe u odnos s desecima različitih operatera što je dugotrajan posao. Streamline je digitalna platforma koja traži optimalnu razmjenu kontejnera između terminala i dostupnih transportnih kapaciteta kopnenih operatora (Port of Rotterdam, 2018b). Sve navedene usluge implementiraju koncept Interneta stvari koji im pomaže u boljem i kvalitetnijem poslovanju.

Morske luke važna su karika u procesu trgovine te u gospodarstvu općenito, budući da su proizvodnja i potrošnja proizvoda rasprostranjene diljem svijeta, a morske luke su te koje ih spajaju. Teretne luke češće su zastupljene u odnosu na putničke te u većoj mjeri pridonose

gospodarskom rastu. Sudionici u lučkom poslovanju raznoliki su te obuhvaćaju lučke korisnike i pružatelje usluga koji svojim poslovanjem doprinose gospodarstvu stvarajući nova radna mjesta te novu vrijednost. Morske luke u Europskoj uniji imaju značaj za regionalna gospodarstva ali i za cjelokupnu Europsku uniju. Ekonomska i politička integracija te uspostavljenje jedinstvenog europskog tržišta pogodovali su poslovanju morskih luka. Između ostaloga Europska unija potiče razvoj transeuropskih prometnih mreža unutar kojih se nalazi i pomorski promet. Morske luke suočene su s mnogim promjenama na tržištu te je potrebno da prate trendove i prilagođavaju se novim uvjetima. Izgradanja većih brodova, nova tržišta, briga za okoliš i uvođenje ICT tehnologije u poslovanje, samo su neki od suvremenih trendova u poslovanju morskih luka. U budućnosti se predviđaju noviji trendovi kao što je primjena 5G mreže u poslovanju, Internet stvari i primjena 3D pisača. Nadalje, sinkromodalni prijevoz jedna je od novijih ideja koja se javlja u prometnom poslovanju, zajedno s primjenom oblaka, *blockchain* tehnologije i dronova u poslovanju. Luka koja ostvaruje najveći promet tereta u Europskoj uniji je luka Rotterdam te je ujedno i jedna od najsofisticiranijih luka u primjeni novih tehnologija. Luka ulaže mnogo truda, napora i sredstava u novu tehnologiju i digitalizaciju poslovanja što rezultira kvalitetnijim poslovanjem i privlačenjem novog tereta. Uspješnost luke je velika što se može zaključiti iz količine tereta kojim rukuje dok ulaganje u nove tehnologije sigurno pridonosi njenoj uspješnosti.

4. MORSKE LUKE KAO SUBJEKTI RASTA REGIONALNIH GOSPODARSTAVA

Gospodarska vrijednost morskih luka sastoji se od direktnog utjecaja na stvaranje dodane vrijednosti i novih radnih mjesta te indirektnog i induciranog utjecaja koji nastaju zbog postojanja luke na određenom prostoru i njenog poslovanja. Morske luke pospješuju konkurentnost regija u kojima se nalaze, no istovremeno zbog prirode njihovog posla vrlo je lako prebaciti poslovanje iz jedne luke u drugu luku. Radi toga morske luke moraju konstantno raditi na poboljšanju svoje konkurentnosti i truditi se pružati kvalitetne usluge koje će zadovoljiti potrebe tržišta. Pomorsko tržište rada promijenilo je svoje zahtjeve od većinskih nisko obrazovanih radnika do zahtjeva za visokim obrazovanjem. Sve češća upotreba tehnologija i informacijsko komunikacijskih sustava također ide u prilog visokoobrazovanim osobama koje su specijalizirane za navedena područja. Utjecaji poslovanja luka na regionalno gospodarstvo većinom su pozitivni, no luke generiraju i određene negativne učinke. Negativni učinci poslovanja morskih luka u većini slučajeva imaju efekte na onečišćenje okoliša, odnosno onečišćenje zraka, mora i tla, proizvodnju otpada te stvaranje buke. Navedeno se nastoji ograničiti i kontrolirati te svesti na minimum zakonskim okvirima i preporukama. MARPOL konvencija svojim tehničkim prilozima nastoji ograničiti i smanjiti onečišćenje okoliša dok uz nju postoje i razna poboljšanja u načinima upravljanja i planiranjima kao što je koncept „zelenih luka“. Važnost poslovanja morskih luka može se sagledati i iz aspekta stvaranja multiplikativnih učinaka na pripadajuće regionalno gospodarstvo, odnosno poslovanje luke ne potiče samo razvoj pomorske industrije već potiče i razvoj ostalih povezanih i nepovezanih industrija. Aktivnosti koje se odvijaju u lučkom poslovanju potiču luke na kupnju proizvodnih faktora od povezanih poduzeća dok istovremeno radnici u pomorskom sektoru troše svoje plaće na dobra i usluge u širem gospodarstvu čime se učinak širi izvan samog lučkog sektora.

U sljedećim potpoglavljima analizirati će se važnost morskih luka za regionalno gospodarstvo s naglaskom na unaprjeđenje regionalne konkurentnosti kao posljedice poslovanja morskih luka na njihovom području. Sagledati će se karakteristike tržišta rada u lučkom sektoru te koje zahtjeve luka postavlja za svoje radnike. Analizirati će se utjecaj globalizacije na morske luke i lučke regije kao i značaj infrastrukture za regionalno gospodarstvo. Sagledati će se i druga, negativna, strana poslovanja luka i utjecaja na regionalno gospodarstvo. Obraditi će se multiplikativni učinci poslovanja morskih luka na gospodarstvo općenito i na primjeru Europske pomorske industrije.

4.1. Važnost morskih luka za regionalno gospodarstvo

Ekonomska vrijednost luke može se definirati se u okvirima vrijednosti koja je ostvarena u određenom razdoblju zbog prisutnosti luke, kao što je iznos dodane vrijednosti i broj zaposlenih ljudi u luci. Međutim, sa strateškog gledišta, važno je sagledati na koji način poduzeća u lučkoj regiji imaju koristi od luke u smislu međunarodne konkurentnosti. Gospodarska vrijednost luke sastoji se od izravne i neizravne dodane vrijednosti, izravnog i neizravnog zapošljavanja, veličine ulaganja i drugih kvantificiranih pokazatelja. Nadalje, strateška vrijednost luke sastoji se od njene ekonomske vrijednosti uvećane za inovacijski doprinos koji je teško kopirati (van den Bosch *et al.,* 2018:39).

Prije početka detaljnije analize, potrebno je definirati što su to lučke regije nakon čega će se povezati utjecaj poslovanja morskih luka s gospodarstvom lučkih regija. Formalna definicija lučke regije ne postoji, već ona obuhvaća različite pojmove poput gospodarskog područja oko luke, logističkog područja oko luke te područja na kojima se odvijaju lučki poslovi (Ducruet, 2009:43). Lučka regija može se zamijeniti za lučko zaleđe ako se definira kao prostor neposredno pored obale luke. No, navedeno može varirati u velikoj mjeri te je u praksi teško odrediti točnu definiciju. Lučka regija se u nekim slučajevima može protezati izvan nacionalnih granica te se može razlikovati od zaleđa na temelju svoje specifične gospodarske strukture. Nadalje, može se definirati kao predio u kojem se nalazi luka, a gospodarski život tog predjela u velikoj mjeri određuju aktivnost koje obavlja luka (Vleugels, 1969). Zaleđe se definira kao skupina mjesta povezanih s lukom kroz robne tokove, dok je lučka regija područje u sklopu kojega djeluje ekonomski utjecaj. Međutim, nedostatak preciznih podataka o kretanju robe u unutrašnjosti često sprječava jasnu definiciju zaleđa (Mccalla *et al.,* 2004). Neka od zaleđa luka dosegla su i područje izvan lučkih regija, uglavnom zbog poboljšanja prometnih sustava. Trend regionalizacije luke ukazuje na sve veću složenost i premještanje logističkih aktivnosti na kopno unutar većeg dijela lučke regije te na razvoj satelitskih terminala u blizini luka i gradova u unutrašnjosti (Slack, 1999).

Luka se također može smatrati lučkim sustavom, odnosno sustavom od dvije ili više luka (ili terminala) koje se nalaze u blizini određenog područja. Dakle, lučki sustav pretpostavlja da određene luke uživaju ne samo geografsku blizinu već i funkcionalnu međuovisnost tako što zajedno pružaju usluge na moru i kopnu. Veliku važnost za kvalitetno funkcioniranje lučkih sustava imaju lokalna i regionalna obilježja, no lučki stručnjaci ih često ignoriraju te luke

smatraju izoliranom entitetom povezanim s prekograničnim mrežama (Ducruet, 2009:44). Svaka regija ima svoje specifičnosti te ih se u dobrom poslovnom sustavu mora uzeti u obzir. U većem dijelu svijeta, luke su smještene na obalama gradova. Takve lokacije su visoko cijenjene s mnogim alternativnim namjenama; ne samo da se prostor može koristiti za brodske terminale, već i za turizam i rekreaciju, stambene i poslovne zgrade, parkove prirode i komercijalnu ribarsku industriju što sve pozitivno utječe na rast gospodarstva (Talley, 2009:2). U literaturi se može pronaći postupni razvoj interakcije morskih luka s gradom, a zatim i s regijom što je prikazano na sljedećoj shemi.

Shema 9. Razvoj interakcije morskih luka i okolnog područja



Izvor: Izradila autorica prema Hoyle, 1989

U samim početcima izgradnje i poslovanja morskih luka, bila je prisutna maksimalna funkcionalna međuovisnost između luke i grada. Morska luka i grad bili su usko prostorno povezani te se pozitivni utjecaji poslovanja luka nisu mnogo širili. Nakon nekog vremena došlo je do proširenja lučkog područja prvenstveno zbog uvođenja željeznica kojima su se luke povezivale s ostatkom zemlje, razvoja industrije u blizini te širenja gradova u lučkom području. Faza moderne industrijske luke obuhvaćala je prostorno razdvajanje luke i grada čime se utjecaj poslovanja luka proširio na šire regionalno područje. U ovoj fazi dodavale su se razne industrijske operacije u blizini luke te se razvila kontejnerizacija. Daljnje odvajanje luke od svoga pripadajućeg grada te daljnje napredovanje poslovanja morskih luka dovelo je do razvoja pomorskih industrijskih područja. U ovoj fazi neke luke su se preselile na dislocirana područja u odnosu na grad u kojemu su početno obitavala. Zadnja faza obuhvaća prenamjenu lučkih područja u druge svrhe u onim gradovima u kojima se luka preselila dalje od centra grada (Hoyle, 1989). Veliki broj luka došao je do zadnje faze. No, u slučajevima gdje se prenamjena nije dogodila, još uvijek postoji tendencija da se pomorska područja geografski šire i da funkcioniraju kao zasebne industrijske zone. Razdvajanje luke i grada također se dogodilo jer su visoki troškovi zemljišta i jeftin prijevoz stvorili poticaje za dislociranje prerađivačke industrije od gradskih centara na područja gdje su zemljišta dostupnija i pristupačnija (Grobar,

2008:498). Navedena shema prikazuje postupni razvitak lučkih područja gdje se može zaključiti kako utjecaj poslovanja morskih luka obuhvaća veće područje od samoga grada u kojemu luka obitava.

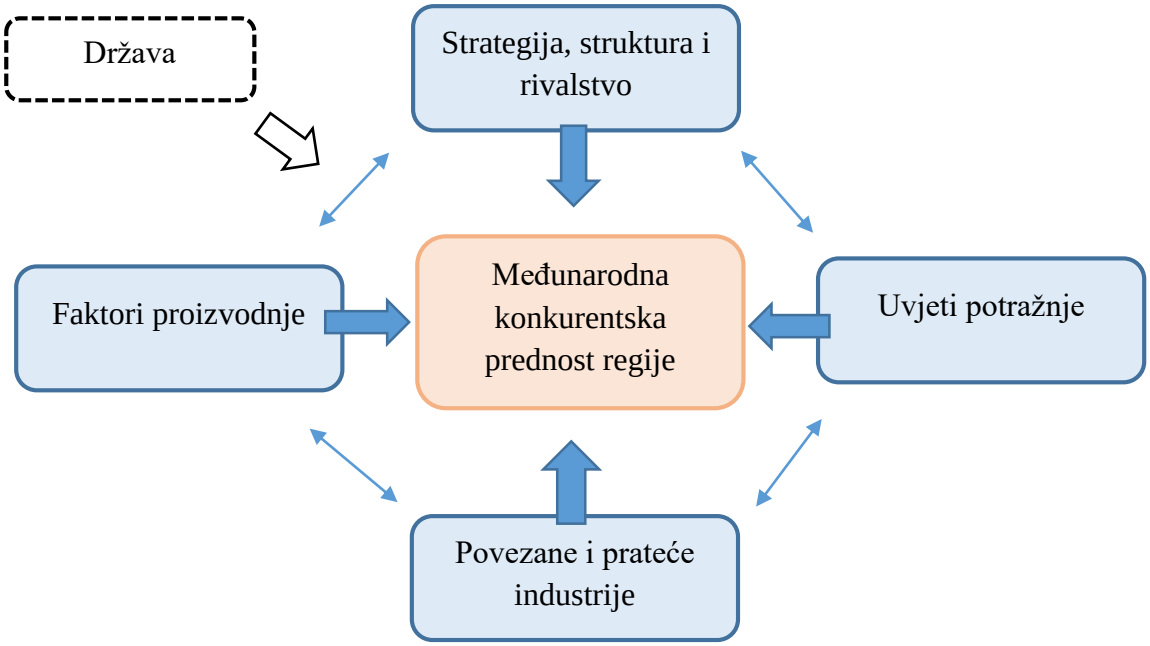
4.1.1. Unaprjeđenje regionalne konkurentnosti kao posljedica poslovanja luka

Morske luke u svojem poslovanju suočavaju se s dva strateška izazova. Prvi je doprinos međunarodnom konkurentskom položaju luke, dok je drugi doprinos međunarodnom konkurentskom položaju regije ili zemlje u kojoj se luka nalazi. Konkurentski položaj luke karakterizira njen tržišni udio u smislu količine tereta koji se prevozi, dok konkurentski položaj regije karakteriziraju pokazatelji kao što su zaposlenost i izravna ili neizravna dodana vrijednost. Za sagledavanje i analizu regionalne međunarodne konkurentnosti lučkog sektora može se primijeniti strateški okvir Michaela Portera koji je zbog svog oblika dobio ime Porterov dijamant (Porter, 1990). Porterov strateški okvir koristi se za analizu četiri interakcijske determinante koje potiču na inovacije, povećavaju produktivnost i poboljšavaju međunarodnu konkurentnost. Odrednice međunarodne konkurentnosti regije su sljedeći:

1) Faktori proizvodnje
2) Strategija, struktura i rivalstvo pojedinih sudionika
3) Uvjeti potražnje
4) Povezane i prateće industrije

Također se u obzir uzima i država koja ima utjecaj na same odrednice te na formiranje njihovih interakcija. Male strelice na sljedećoj shemi prikazuju formalne i neformalne veze između organizacija, dok velike strelice označavaju izravan utjecaj na međunarodnu konkurentnost. Sljedeća shema prikazuje Porterov dijamant koji će se interpretirati u okvirima poslovanja morskih luka te njihovog utjecaja na međunarodnu konkurentnost regije.

Shema 10. Odrednice međunarodne konkurentnosti lučke regije



Izvor: Prilagodila autorica prema Porter, 1990*;* van den Bosch *et al*., 2018:41

Faktori proizvodnje u lučkom sektoru odnose se na proizvodne faktore kao što su prirodni resursi, kapitalni resursi, infrastruktura (luka, vezovi, ceste, željeznice), ljudski resursi, znanje, informacijske i komunikacijske tehnologije i slično. Kako se faktori proizvodnje poboljšavaju npr. unaprjeđenjem ljudskog kapitala ili ulaganjem u nove tehnologije, tako njihov doprinos međunarodnoj konkurentnosti regije raste. Strategija, struktura i rivalstvo pojedinih sudionika obuhvaća dva aspekta tj. bave se time na koji način su poduzeća organizirana i da li zadovoljavaju potrebe svojih dionika te se bave intenzitetom rivalstva poduzeća i njihovom fleksibilnošću. Uvjeti potražnje u sektoru pomorstva vezani su uz međunarodnu orijentaciju klijenata koji zahtijevaju da se posao obavi u što kraćem vremenu i sa što manje troškova čime se potiče morske luke i ostala poduzeća koja posluju u lučkom sektoru na inovacije i uvođenje konstantnih promjena. Povezane i prateće industrije odnose se na prisutnost međunarodno konkurentnih industrija npr. brodski agenti, osiguranje, pravne usluge i slično. Država može utjecati na navedene četiri odrednice te na njihovu interakciju uvođenjem politika, propisa, odlukama o ulaganjima u inovacije ili infrastrukturu i slično, čime mogu potaknuti ili spriječiti stvaranje međunarodne konkurentnosti (van den Bosch, *et al.* 2018:41-42).

Liberalizacija trgovine, razvoj prometa, logistike i komunikacijskih tehnologija, drastično su oslabili vezu između proizvodnje i lokacije na kojoj se nalaze proizvodni čimbenici. Veza je u prošlosti bila jaka budući da je za proizvodnju proizvoda bilo potrebno biti u blizini proizvodnih čimbenika kako bi učinkovitost bila što veća, a troškovi što manji. U sadašnjosti veza je slabija jer se pomorskim putem može relativno brzo i relativno jeftino prevesti proizvodne čimbenike na željenu lokaciju čime se stvara pomak u proizvodnim aktivnostima prema zemljama s komparativnim prednostima. Učinkovitost prijevoza uvjetovana je povećanim zahtjevima za što kraćim vremenom transporta kako bi se povećao promet i smanjili troškovi zaliha. Navedeni troškovi nastoje se svesti na minimum korištenjem logističkih koncepata kao što su *Just-in-Time* i *Make-to-Order*. Luke su postale najdinamičnije poveznice u međunarodnim prometnim mrežama te neučinkovite luke mogu lako umanjiti koristi od izvoza i liberalizacije trgovine. Stoga nacionalne ekonomije često poduzimaju razne korake kako bi poboljšale učinkovitost svojih morskih luka (Haralambides, 2015:226-227).

Poslovanje u morskim lukama općenito je usmjereno na međunarodno poslovanje te postoji velika razina konkurencije između morskih luka. Mobilnost tereta i slobodan odabir luke prijevoza zajedno s kopnenim prometnicama znatno su pojačali konkurenciju među lukama. Poduzeća koja se bave prijevozom tereta imaju malu lojalnost prema morskim lukama te se vrlo lako prebacuju iz jedne u drugu morsku luku. Stoga je cjenovna elastičnost potražnje za uslugama rukovanja teretom prilično visoka, odnosno poduzeća se lako prilagođavaju i ukoliko im ne odgovaraju određeni uvjeti, pronalaze novu opciju (Haralambides, 2015:228).

Pretovar tereta može biti profitabilan za određene luke ali istovremeno može biti i prilično riskantan za druge budući da luke iziskuju prilično velika ulaganja. Određivanje cijena u morskim lukama može imati značajne utjecaje na susjedne morske luke na nacionalnoj i međunarodnoj razini. Nadalje, što je veći doprinos navedenih odrednica međunarodne konkurentnosti na razini luke (Shema 10), to će luke stvarati veću stratešku vrijednost za svoju regiju. S druge strane, suradnja s ostalim lukama također je važna te može stvarati konkurentsku prednost za domaću luku. Razvojem strateških veza s drugim lukama, luka istovremeno jača svoju konkurentnost, ali i doprinosi međunarodnoj konkurentnosti regija. Što je luka bolje povezana s ostalim lukama, biti će ju teže zamijeniti alternativnom lukom čime se automatski stvara vrijednost za pripadajuću regiju. Povezivanje luka može primjerice omogućiti jedinstven pristup inovacijama ili korištenje novih znanja i nove tehnologije (van den Bosch *et al.,* 2018:43).

Poseban aspekt konkurencije koji se javlja u poslovanju morskih luka jest porezna konkurencija koja će se objasniti na primjeru Europske unije. Pomorska industrija strateški je važna za Europsku uniju budući da omogućuju međunarodnu trgovinu te istovremeno opskrbljuje Europsku uniju energijom kroz uvoz nafte i drugih goriva. No, pomorska industrija ima jedinstvene značajke koje omogućuju primjenu povoljnije porezne politike nego u drugim industrijama. Općenito, pomorska industrija može se vrlo lako premjestiti iz jedne zemlje u drugu i time se prilagođavati boljim poreznim uvjetima. Brodovlasnici mogu vrlo jednostavno registrirati svoja plovila u zemljama s nižim porezom što je rezultiralo većom međunarodnom konkurencijom u poreznim i regulatornim režimima. Zemlje se prilagođavaju i pružaju povoljnije porezne politike kako bi privukle pomorstvo k sebi.

Prepoznajući potrebu da se podupre međunarodna konkurentnost pomorske industrije Europske unije, nacionalne vlade zemalja članica uvele su niz potpora za podršku pomorskoj industriji kao što je poseban sustav poreza na tonažu pri čemu brodovlasnik plaća porez povezan s količinom tonaže koju prevozi bez obzira na ostvarenu dobit ili gubitak. Nadalje, primjenjuju se smanjene stope poreza na dohodak i doprinosa za socijalno osiguranje za pomorce. Ovakav pristup vođen je politikom na europskoj razini, putem smjernica Europske komisije o državnim potporama (Oxford Economics, 2014:44-46).

Poslovanje pomorskih poduzeća Europske unije u većini slučajeva uključuje trgovinu s lukama koje se nalaze izvan Europske unije. Stoga, ako strane zemlje pružaju bolje porezne uvjete, može se dogoditi da se neka od europskih poduzeća premjeste u druge zemlje čime dolazi do gubitka radnih mjesta u pomorskom sektoru Europske unije te do smanjenja udjela u bruto domaćem proizvodu. Nadalje, utjecaj može biti i širi jer multiplikativni utjecaj obuhvaća ne samo pomorsku industriju već i povezane industrije što će biti detaljnije objašnjeno u kasnijim potpoglavljima.

4.1.2. Tržište rada u lučkom sektoru

Tržište rada u lučkim regijama ima određene karakteristike koje ga razlikuju u odnosu na ostale regije. Luke obavljaju specifične djelatnosti kao što je primjerice ukrcaj i iskrcaj tereta, stoga zahtijevaju i specifičnu radnu snagu. Nadalje, luke privlače i druge gospodarske djelatnosti kao što je industrija čelika koja za sobom povlači ostale gospodarske aktivnosti kao što su uslužne djelatnosti. Prema tome, luke mogu imati direktne i indirektne učinke na zapošljavanje u regiji u kojoj se nalaze. Tradicionalno, poslovi vezani za poslovanje morskih luka tražili su većinom

niskokvalificiranu radnu snagu te nije bio potreban visoki stupanj obrazovanja. No, pojava novih tehnologija i automatizacije te sve češće korištenje informatičkog sektora u administrativnom radu i komunikaciji, zahtijeva drugačiju strukturu zaposlenika, odnosno sve se više traže visokokvalificirani radnici.

Poslovi koji su direktno vezani uz poslovanje morskih luka su sljedeći (de Koning *et al.,* 2018:351):

- Pomorske djelatnosti, kao što su:
    - brodarstvo
    - unutarnja plovidba
    - ribarstvo
    - brodogradnja
    - građevinarstvo povezano s lukom
- Lučke djelatnosti, kao što su:
    - skladištenje i prekrcaj
    - logistika
    - pomorski agenti i brokeri
    - stivadori
    - carinske i lučke usluge
- Prijevoz u luci cestom i vlakom

Povezane djelatnosti koje se većinom nalaze u blizini luka mogu biti razne proizvodne djelatnosti kao što su petrokemija, kemijski proizvodi, metalurška industrija, zatim proizvodnja energije, održavanje, trgovina i razne specijalizirane komercijalne djelatnosti (osiguranja, ekonomske djelatnosti, pravne djelatnosti).

Kao što je prethodno napomenuto, u prošlosti su se većinom tražili niskokvalificirani radnici za rad u morskim lukama koji su se bavili poslovima prekrcaja tereta. Trenutno prekrcaj predstavlja tek relativno mali dio lučkog zapošljavanja. Kao primjer može se uzeti luka Rotterdam u kojoj udio zaposlenih u skladištenju i prekrcaju zajedno iznosi manje od 2%. Nadalje, u luci Antwerpen taj je postotak manji od 10% ukupnog broja zaposlenih. Navedene luke su vrlo tehnološki razvijene, čemu teže i sve ostale luke te je u njima manipulacija teretom u velikoj mjeri mehanizirana. Iako rad na dokovima više ne dominira lukama u smislu broja radnika, on još uvijek ispunjava vitalnu funkciju. Učinkovitost luke još uvijek uvelike ovisi o

učinkovitosti kojom se rukuje teretom s time da je manualni rad većinom zamijenjen dizalicama i kontejnerima (de Koning *et al.,* 2018:354). Navedeno implicira znatno povećanje produktivnosti koje istovremeno smanjuje zaposlenost na određenim radnim mjestima. No, radna mjesta sada zahtijevaju reorganizaciju i povećanje vještina radne snage te istovremeno nude bolje radne uvjete.

Što se tiče strukture radne snage, u lučkim regijama značajan dio potrebne radne snage čine tehničari. Važnu ulogu u prekrcaju tereta, koji je većinom automatiziran, igraju operateri. Nadalje, logističari su također potrebni u poslovanju kao i tehničari povezani uz prerađivačku industriju koja se nalazi u blizini luke. Stoga je za gospodarstvo lučkih regija od vitalne važnosti da ponuda radne snage bude u skladu s njenom potražnjom. Međutim, sektor proizvodnje te ostali prateći sektori već dva desetljeća prolaze kroz procese nedostatka tehničara, odnosno kvalificirane radne snage. Ovaj fenomen može se pronaći u mnogim zemljama zapada, primjerice u Njemačkoj i Sjedinjenim Američkim Državama. Uzrok nedostatku kvalificirane radne snage je pad zaposlenosti u proizvodnji budući da su se mnoge industrije preselile u zemlje s nižim troškovima rada. Kao posljedica pada proizvodnje, mnogi mladi ljudi prilikom odabira zanimanja opredjeljuju se za ne tehničke vrste zanimanja. Starenje radno sposobnog stanovništva te povećanje broja odlazaka u mirovinu također utječu na ponudu radne snage. Iako su mogućnosti zapošljavanja u proizvodnom sektoru bolje nego u mnogim drugim sektorima, mnogi mladi ljudi imaju negativnu percepciju o uvjetima zapošljavanja.

Mogućnost da se poduzeće zatvori i preseli svoje aktivnosti u drugu zemlju s jeftinijom radnom snagom ne ide u korist atraktivnosti zapošljavanja što se reflektira i na tržište rada u pomorstvu. Socio-kulturni čimbenici također utječu na negativno stajalište tehničkih radnika. Gradovi poput Rotterdama i Antwerpena su dom mnogim ljudima stranog podrijetla od kojih su se neki tek nedavno preselili dok su neki potomci druge ili treće generacije migranata. Među tim skupinama izbor za studiranje i rad u tehničkom zanimanju rjeđi je nego među ljudima domaćeg podrijetla jer su često pod utjecajem kulture zemlje iz koje su došli gdje tehnički rad većinom ima niži status u odnosu na ostale visokokvalificirane poslove. Također, prve generacije migranata često su bile zaposlene u proizvodnom sektoru koji se uvelike razlikovao od današnjeg proizvodnog sektora i u kojemu su uvjeti rada bili prilično loši, stoga njihovi potomci ne žele proživljavati isto (de Koning, Zandvliet i Gelderblom, 2018:357-358).

Luke u određenim segmentima poslovanja surađuju no istovremeno se i nadmeću čime se posljedično povećava njihova produktivnost. Ljudski kapital može se okarakterizirati kao

ključni čimbenik u povećanju konkurentnosti morskih luka. Tokom vremena radnici rade na unaprjeđenju svojih vještina i postaju fleksibilniji te je na morskim lukama i svim ostalim sudionicima u pomorskom poslovanju da potiču svoje zaposlenike na promjene i veću produktivnost. U procesu natjecanja za kvalitetnu radnu snagu, veliki utjecaj imaju plaće radnika koje su glavni motivator produktivnosti i truda radnika (de Koning *et al.*, 2018:353). Veći kapitalni intenzitet i automatizacija stvorili su novu skupinu radnika koja je podjednako važna za dobro funkcioniranje luka. U globalu, prisutnost morske luke u regiji ima pozitivan učinak na zapošljavanje u regiji što je dokazano i od strane autora Bottasso i suradnici (2013.) gdje je utvrđena pozitivna veza između prometa tereta i razine regionalne zaposlenosti, odnosno zaključeno je kako poslovanje luke znatno povećava regionalnu zaposlenost. Sličnom temom bavili su se i Ferrari i suradnici (2010.) te su u svome radu utvrdili pozitivnu vezu između poslovanja luka i zaposlenosti s nešto većom značajnošću u tercijarnom sektoru.

4.1.3. Utjecaj globalizacije na morske luke i regionalna gospodarstva

Regionalna okolina morskih luka važna je za njihovo poslovanje budući da luke nisu izolirane jedinice već dio vrijednosnih i opskrbnih lanaca. Luke su dio regionalnog gospodarstva čiji razvoj utječe na njihovu uspješnost poslovanja. Intenzivna globalizacija izaziva industrijske pomake u regijama. Globalizacija je potaknuta spoznajom da resursi i dobra nisu uvijek na istoj lokaciji proizvodnje i potrošnje, stoga su potrebne globalne prijevozne usluge među kojima se nalazi i pomorski prijevoz. Ona se može opisati kao povećanje prekograničnih međuovisnosti i integracije, što rezultira većom mobilnošću čimbenika proizvodnje te roba i usluga (Campbell, 1994; Milanović, 2013). Globalno kretanje tereta ključni je element u svjetskom sustavu prijevoza tereta koji uključuje oceane i obale, unutarnje plovne puteve, željeznicu, ceste i zračni prijevoz. Globalizacija proizvodnje glavni je čimbenik koji pokreće širenje lučkih djelatnosti, budući da su globalno isprepleteni proizvodni sustavi doveli do sve veće potrebe za trgovinom sirovinama i poluproizvodima, kao i gotovim proizvodima (Hesse, 2006). Nadalje, javlja se sve veća tendencija za lociranjem logističkih i distribucijskih aktivnosti dalje od luka, čime se opravdava korištenje regija, a ne gradova kao čimbenika na koje djeluje poslovanje luka.

Prema Domijan-Arneri (2014:81), postoje četiri glavna stupa globalizacije:

1) Međunarodna standardizacija
2) Liberalizacija trgovine
3) Telekomunikacije
4) Prijevoz

Međunarodna standardizacija poboljšala je sklapanje poslovanja između međunarodnih poduzeća. Poduzeća lakše mogu dogovoriti uvjete poslovanja jer su upućeni u proizvodne standarde, standarde upravljanja, standarde sigurnosti i slično, što posljedično povećava globalnu konkurentnost. Liberalizacija trgovine u širem smislu obuhvaća uvođenje pravnih propisa koji uklanjaju restrikcije i ograničenja u trgovini. Njome je postignuta učinkovita globalna alokacija resursa koja posljedično pospješuje važnost i rad morskih luka. Telekomunikacije i prijevoz postali su globalni sustav za prijenos informacija, robe i ljudi (Domijan-Arneri, 2014:81).

Iz perspektive morskih luka, implementacija procesa globalizacije i liberalizacije u pomorskom prometu proizlazi iz dva čimbenika. Prvi čimbenik je da implementacija globalizacije i liberalizacije u sustavu brodarstva dovodi do razvoja luka. Globalizacijski procesi povezani su sa specijalizacijom luka za određenu vrstu tereta te sa specijalizacijom tehnologije prekrcaja i prijevoza kao što su primjerice kontejnerizacija, multimodalni prijevoz, kombinirani transport i slično. Drugi čimbenik je taj da geografska globalizacija podrazumijeva promjene u redoslijedu glavnih svjetskih morskih luka, uzrokovane kretanjem robnih tokova. Globalizacija i liberalizacija odnose se na prestrukturiranje luka vezano uz promjene u brodarstvu koje su izazvane tim procesima (Kesić, 2003:43).

Globalizacija trgovine utjecala je na smanjenje troškova proizvodnje budući da se proizvodnja proizvoda sve češće odvija u područjima u kojima je radna snage jeftinija. Padom trgovinskih barijera pojavio se pojam pod nazivom *outsourcing* koji obuhvaća prethodno navedeno premještanje proizvodnje u područja s jeftinijom radnom snagom. Samim time se sirovine transportnim putevima šalju u navedena područja a vrlo često se kao način prijevoza koristi pomorski prijevoz. Uz jeftinu pogonsku energiju brodova, olakšanu ekonomijom razmjera, troškovi po jedinici poluproizvoda i gotovih proizvoda minimizirani su lancima opskrbe koji se nalaze na više kontinenata. Uobičajeno je, na primjer, da se poljoprivredni proizvodi ubiru na jednom kontinentu, šalju na drugi kontinent na preradu, transportiraju na treći kontinent na

konačnu doradu, a zatim isporučuju na tržište. Nadalje, globalizacija je potaknula brži tempo trgovanja; robe i usluge isporučuju se u manjim paketima po konceptu „Točno-na-Vrijeme“ *(eng. Just-in-Time)* čime je povećana brzina kretanja tereta. U globaliziranom gospodarstvu kontejnerizacija nudi mogućnost integriranog prijevoza tereta u svim vidovima prijevoza te smanjuje troškove prijevoza većine gotovih proizvoda (Corbett i Winebrake, 2008:7).

Zemlje u razvoju bez adekvatne pripremljenosti bile su izložene snazi globalizacije i pojačanoj međunarodnoj konkurenciji što im prvenstveno nije donijelo pozitivne efekte. No, mnoge zemlje u razvoju su sada svjesne da otvaranje granica prema međunarodnoj trgovini ima velike pozitivne učinke koji proizlaze iz njihovih komparativnih prednosti te jeftine radne snage. U literaturi se često raspravljalo da visoki troškovi prijevoza štete izvozu zemalja u razvoju koji je ionako premalo diverzificiran te ovisi o vrlo nestabilnim međunarodnim cijenama roba. Zbog toga su zemlje u razvoju često odbacivale načelo komparativnih prednosti kao pozitivan aspekt poslovanja budući da ono vodi ka lošijim uvjetima trgovine, stvara uska grla pri formiranju platnih bilanci te na taj način sprječava njihov rast kroz diverzifikaciju. Iako sve više zemalja u razvoju ulazi na svjetsko tržište dobara, zapravo nude lošije proizvode budući da se većinom odlučuju natjecati s cijenom, a ne kvalitetom. Radi toga lučko poslovanje, zbog nižih cijena prijevoza, za njih ima veću ulogu nego za razvijenije zemlje (Haralambides, 2018:68). Kako bi se luke i u budućnosti što bolje prilagođavale procesu globalizacije, potrebno je da modificiraju poslovanje prema sljedećim smjernicama čime mogu djelovati na vanjske izazove i prilagođavati se unutarnjim izazovima.

Tablica 6. Interni i eksterni izazovi u morskim lukama koje nameće globalizacija

INTERNI IZAZOVI	EKSTERNI IZAZOVI
• Rast poslovanja • Traženje visokoobrazovane radne snage • Kontinuirane inovacije/istraživanje i razvoj • Novo organizacijsko razmišljanje • Poboljšanje učinkovitosti i produktivnosti rada terminala • Upoznavanje i implementacija najnovijih *know-how* načina rada • Upoznavanje i implementacija najnovijih tehnologija za rad terminala • Pružanje lučkih usluga orijentiranih na korisnike • Oslobađanje od birokratskih pravila i postupaka • Razvoj vlastite stručnosti za upravljanje lukama i razvoj lučke strategije	• Novi konkurenti/tehnologija/poslovni modeli • Promjene na tržištu • Geopolitički razvoj • Promjene rizika • Promjene atraktivnosti posla • Regulatorni izazovi

Izvor: Prilagodila autorica prema Inoue, 2010; Buck, 2018

Kao što je u prethodnim poglavljima bilo navedeno, budući trendovi poslovanja morskih luka ići će u smjeru digitalizacije poslovanja, stoga je potrebno poslovanje morskih luka tome prilagoditi. Iz prethodnih smjernica može se vidjeti da su mnoge usmjerene upravo na poboljšanje pružanja usluga primjenom novih tehnologija, smanjenje birokracije koja se također može digitalizirati te na razvoj vlastitih znanja i oplemenjivanju ljudskog kapitala. Potrebe korisnika trebale bi biti u fokusu poslovanja svakog poslovnog subjekta pa tako i morskih luka što se očekuje i u budućnosti. Interni izazovi pod kontrolom su morskih luka te luke mogu samostalno odlučiti da li će im se prilagoditi kako bi nastavili unaprjeđivati svoje poslovanje, dok su eksterni izazovi izvan kontrole morskih luka te su im se morske luke primorane prilagođavati, u protivnom neće dugoročno opstati.

4.1.4. Značaj lučke infrastrukture za regionalno gospodarstvo

Lučka infrastruktura je skup stabilnih objekata i uređaja koji služe za organiziranje i obavljanje lučke djelatnosti. Ona ima niz zajedničkih obilježja s gradskom i regionalnom infrastrukturom jer čini njihov sastavni dio. Lučku infrastrukturu čine objekti u luci koji služe javnom prometu, koji su dugoročni te pri čijoj je izgradnji potrebno dugoročno planiranje potreba. Infrastrukturne objekte u morskim lukama čine sljedeći objekti (Kesić, 2003:93):

- Lučki akvatorij
- Lukobrani
- Operativne obale i organizirane lučke kopnene površine
- Lučki željeznički sustav
- Lučke cestovne prometnice
- Lučki elektrovodi
- Lučki plinovodi
- Lučka vodovodna mreža
- Telefonski vodovi
- Mostovi

Lučka infrastruktura čini dio cjelokupne prometne infrastrukture s određenim posebnostima koja utječu na njen proizvodni sustav. Neka od obilježja su sljedeća: lučka infrastruktura je kapitalno intenzivna te se skupe investicije moraju izvoditi u većim tehnološkim cjelinama, dug je vijek sazrijevanja lučke infrastrukture što znači da se ona gradi za buduće, a ne za sadašnje potrebe. Ulaganja u prometnu infrastrukturu, posebice ulaganja u morske luke, autoceste i željeznice trebaju se dugoročno planirati te zahtijevaju dugoročne financijske obveze (Tsekeris and Tsekeris, 2011). Navedeno dovodi do zaključka da određene karakteristike lučke infrastrukture nepovoljno djeluju na poslovanje morskih luka jer se treba investirati u skupu infrastrukturu koja sporo vraća uložena sredstva. Višak kapaciteta infrastrukture ne znači ekonomsku korist jer on ne vraća uložena sredstva, a istovremeno uvećava amortizaciju i kamate te stvara fiksne troškove koji posljedično utječu na povećanje cijene lučke usluge (Kesić, 2003:93).

No, postojanje adekvatne lučke infrastrukture mora postojati ukoliko morske luke žele kvalitetno poslovati budući da su troškovi prijevoza izravno povezani s postojanjem dobro

razvijene prometne infrastrukture. Morske luke, kao dio gospodarskog sustava, u uzročno-posljedičnoj su vezi s djelovanjem prometnog sustava i kvalitetom objekata prometne infrastrukture. Iz toga slijedi da izgradnja i modernizacija objekata prometne infrastrukture moraju biti u funkciji valorizacije uložene društvene akumulacije i one koja se planira uložiti u pojedina gospodarska, odnosno lučka područja (Kesić i Jugović, 2006:171). Što se tiče utjecaja prometne infrastrukture na rast gospodarstva i konkurentnost zemlje, rezultati mnogih istraživanja su različiti. Mnogi autori dokazali su pozitivan utjecaj prometne infrastrukture na gospodarski rast (Aschauer, 1989; Fujita i Mori, 1996; Yoo, 2006; Bottasso *et al.*, 2014; Song i van Geenhuizen, 2014; Jouili, 2016) jer prometna infrastruktura potiče razne pozitivne efekte poput boljeg pristupa faktorima proizvodnje i njihove povećane produktivnosti, nižih troškova proizvodnje, rasta proizvodnje, rasta trgovine, intenzivnije konkurencije, poticanja izravnih stranih ulaganja i slično. Napredak gospodarstva manje razvijenih zemalja i regija ovisi o učinkovitosti prijevoza putnika i robe, dok nedostatak prometne infrastrukture ostaje prepreka (Vlahinić Lenz *et al.*, 2018:1961). Kod visokorazvijenih zemalja prometna je infrastruktura, u većini slučajeva, dobro razvijena te izgradnja dodatne infrastrukture dovodi do prezasićenosti i ne vodi ka gospodarskom rastu. U istraživanju Deng i suradnika (2014) definiran je prag do kojeg je optimalno ulagati u infrastrukturu te je dokazano kada ulaganje u infrastrukturu pređe navedeni prag, dodatna ulaganja ne vode ka boljoj ekonomskoj efikasnosti. S druge strane, niti premalo ulaganje u infrastrukturu ne vodi ekonomskom rastu, stoga je zaključeno kako ulaganje mora biti na optimalnoj razini tj. unutar utvrđenog praga. Crescenzi i Rodrigues-Pose (2012) u svome radu ukazali su da infrastruktura nema jaki učinak na gospodarski rast te da bi se pažnja trebala preusmjeriti na druge čimbenike koji potiču ekonomiju.

Mnoga istraživanja ukazuju kako uz procjenu utjecaja prometne infrastrukture na gospodarski rast treba uzeti u obzir druge važne pokretače rasta jer je infrastruktura potreban ali ne i dovoljan preduvjet za gospodarski rast (Crescenzi i Rodríguez-Pose, 2012; Jugović, 2012; Vlahinić Lenz *et al.*, 2018). U Europskoj uniji je posebice veliki naglasak stavljen na ulaganja u prometnu infrastrukturu dok su ostali čimbenici djelomice zanemareni. U ekonometrijskom dijelu doktorske disertacije će se, između ostaloga, testirati u kojoj mjeri infrastruktura utječe na regionalni gospodarski rast te da li bi se fokus trebao staviti na druge pokretače gospodarskog rasta kao što su ljudski kapital i ulaganje u istraživanje i razvoj.

4.1.5. Negativni učinci morskih luka na regionalno gospodarstvo

Poslovanje morskih luka generira mnoge pozitivne učinke na okolna gospodarstva, no potrebno je sagledati i drugu perspektivu tj. negativne učinke koji nastaju zbog egzistiranja morskih luka u određenoj regiji. Jedan od čimbenika su eksternalije koje proizlaze iz gospodarskih aktivnosti morskih luka. Lučke aktivnosti generiraju značajnu količinu cestovnog prometa u svojoj blizini, zbog pojačanog korištenja kamiona, što dovodi do zagušenja lokalnih cesta i autocesta te do buke i zagađenja okoliša. Utovar i istovar tereta također stvara zagađenja i buku, dok skladišni prostori koji su smješteni u blizini luke čine okolni prostor manje atraktivnim za stanovanje i život. Stoga, poslovanje luka može uzrokovati manju poželjnost za stanovanjem u okolnim područjima. Kao rezultat, cijene nekretnina mogu pasti ili sporije rasti od vrijednosti u ostalim područjima (Grobar, 2008:508).

Stanovnici okolnih lučkih područja se u određenim slučajevima mogu protiviti širenju luke, dok je širenje luke istovremeno neophodno za daljnji razvoj trgovine. Uloga kreatora politike je tražiti načine za ublažavanje negativnih utjecaja luka na regionalna gospodarstva kako bi se i dalje moglo imati koristi od širenje trgovine. Primjeri ovih vrsta politika uključuju politike osmišljene za smanjenje emisija plinova brodova i kamiona u lukama, ulaganja u cestovnu i željezničku infrastrukturu s ciljem smanjenja zagušenja na lokalnim cestama i autocestama, veću upotrebu satelitskih terminala za smanjenje lokalnih zagušenja te ulaganja u nova tehnološka rješenja čime se povećava briga za okoliš i smanjuje njegovo onečišćenje (Grobar, 2008:514).

Briga za okoliš važan je čimbenik poslovanja općenito, stoga i morske luke moraju u svome poslovanju obratiti pažnju na očuvanje okoliša i održivi razvoj. Luke i brodarstvo stvaraju niz negativnih utjecaja na okoliš koji su uzrokovani rukovanjem tereta, povezanim pomorskim prometom, distribucijom tereta u zaleđe i slično. Neki od štetnih učinaka za okoliš su sljedeći (Trozzi i Vaccaro, 2000):

1) Onečišćenje zraka
2) Onečišćenje mora
3) Proizvodnja otpada
4) Stvaranje buke
5) Onečišćenje tla

Onečišćenje zraka javlja se pri prijevozu brodova ali i pri samom poslovanju morskih luka. Djelatnosti brodova odgovorne su za emisije štetnih tvari u zrak, a osobito šteti kretanje brodova u luci, aktivnosti brodova vezane uz rasvjetu, grijanje, hlađenje, ventilacija i slično te aktivnosti vezane uz utovar i istovar tereta. U samom lučkom okruženja javlja se mnogo aktivnosti koje su vezane uz onečišćenje zraka a neke od njih su sljedeće: utovar i istovar naftnih derivata koji proizvodi emisije isparljivih organskih spojeva, promet automobila, promet teških vozila, željeznički promet, uništavanje ili nadogradnja brodova koja u okoliš emitira azbest, teške metale, ugljikovodike te tvari koje oštećuju ozon (Trozzi i Vaccaro, 2000). Zagađenje zraka uzrokuje kumulativan učinak koji doprinosi izazovima kvalitete zraka s kojima se stanovništvo u mnogim područjima susreće te utječe na prirodni okoliš primjerice uzrokujući stvaranje kiselih kiša.

Onečišćenje mora može se javiti u luci ili u blizini luke te postoje razni uzročnici kao što su: ulje iz kaljuže, curenje motornih goriva s brodova, curenje benzina i dizelskog goriva, slučajno curenje nafte i kemijskih tvari prilikom utovara i istovara tereta, toplinsko zagađenje mora te prijenos štetnih vodenih organizama s balastnom vodom koja se koristi za stabilizaciju plovila na moru. Budući da plovila putuju sve brže, povećala se stopa preživljavanja štetnih vodenih organizama u balastnim tankovima te su se kao posljedica pojavili mnogi neautohtoni organizmi na novim lokacijama koji mogu imati loše posljedice na lokalni ekosustav, posebice na ribe (Trozzi i Vaccaro, 2000). Prema podacima Međunarodne pomorske organizacije, tankeri svake godine transportiraju oko 2,9 milijuna tona nafte i naftnih derivata te se u većini slučajeva transportiraju sigurno i bez onečišćenja, dok se povremeno znaju dogoditi ispuštanja bilo u rutinskim ili izvanrednim operacijama (International Maritime Organization, 2019b). Ispuštanje otpadnih voda u more može imati posljedice na zdravlje ljudi te može vizualno onečistiti obalna područja što predstavlja izazov za turističke zemlje.

U toku plovidbe broda stvaraju se razni otpadni proizvodi te brod treba skupljati otpad koji baca kada stigne u luku. Prema propisima, većina otpada mora se deponirati na kopno te se ne smije ispuštati u more. Brodovi često znaju čuvati otpad te ga deponirati na mjestima gdje su troškovi najniži dok se u nekim slučajevima otpad nelegalno deponira u more čime se stvaraju dodatne štete za okoliš. Vrlo velika opasnost za okoliš stvara se od plastike koja može plutati morem godinama. Ribe i morski sisavci mogu zamijeniti plastiku za hranu te se zarobiti u plastičnim predmetima (International Maritime Organization, 2019c). Uništavanje, odnosno rušenje starih brodova stvara dodatan otpad, posebice u zemljama poput Indije, Bangladeša i Pakistana koje

nemaju postrojenja za rukovanje ostacima otpada. Održavanje i rekonstrukcija starijih plovila također generira otpad i to ne isključivo u nerazvijenim zemljama nego i u razvijenim zemljama (Trozzi i Vaccaro, 2000).

Stvaranje buke još je jedan od izvora onečišćenja okoliša te su glavni izvori buke na brodovima pogonski strojevi, motori, propeleri, poprečna pogonska jedinica te sustav grijanja, ventilacije i klimatizacije. Strojevi proizvode buku u okolni zrak te izazivaju vibracije površine na kojoj se nalaze. S druge strane izvori buke u poslovanju luka dolaze iz cestovnog prometa kamiona, željezničkog prometa u luci ili okolnim područjima te od utovara i istovara tereta korištenjem strojeva, dizalica, pumpa i slično. Najčešća buka za lučko područje je buka koja se prenosi zrakom te je vrlo često prisutna buka koja se nalazi u područjima oko luke.

Različiti su izvori onečišćenja tla u lučkom poslovanju kao, na primjer, slučajno ispuštanje nafte u tlo prilikom operacija na terminalima i nalazištima goriva, izlijevanje ulja iz uređaja za rasute terete i raspršivanje prašine tijekom njihovog rukovanja, izlijevanje ulja i drugih tvari iz vozila koji mogu uzrokovati raspadanje asfalta te izlijevanje kemikalija tokom procesa rekonstrukcije i uništavanja starih brodova (Trozzi i Vaccaro, 2000).

Kako bi se smanjio štetan utjecaj poslovanja morskih luka i brodova na okoliš, Međunarodna pomorska organizacija izdala je Međunarodnu konvenciju o sprječavanju onečišćenja s brodova (MARPOL). Konvencija obuhvaća propise kojima je cilj sprječavanje i minimiziranje onečišćenja s brodova koja su nastala iz rutinskih operacija ili iz slučajnih razloga (International Maritime Organization, 2019a). MARPOL uključuje šest tehničkih priloga koja su navedeni u nastavku:

1) Propisi za sprječavanje onečišćenja mora uljima (Prilog I)
2) Propisi za kontrolu onečišćenja mora kemikalijama (Prilog II)
3) Sprečavanje onečišćenja mora opasnim tvarima u posebnim pakovanjima, kontejnerima ili prijevoznim tankovima (Prilog III)
4) Sprječavanje onečišćenja mora fekalnim vodama (Prilog IV)
5) Sprječavanje onečišćenja mora čvrstim otpadom (Prilog V)
6) Sprječavanje onečišćenja zraka emisijom plinova s brodova (Prilog VI)

MARPOL konvencija se konstantno nadopunjuje i mijenja ovisno o uočenim potrebama. Novosti se uvode gotovo svake godine te nije potrebno čekati ratifikaciju država već automatski stupaju na snagu iduće godine nakon donošenja.

Prema održivim načelima, luke moraju oblikovati svoju politiku i uspostaviti učinkovit sustav za praćenje potrošnje energije i vode, uključujući pokazatelje kvalitete okoliša (kakvoća zraka, energija i korištenje vode). Stoga moraju svoje napore ka poboljšanju okoliša usmjeriti ne samo na inženjerske projekte već i na promjenu postojećih načina upravljanja i planiranja (Ng *et al.*, 2013). Koncept „zelene luke" jedan je od načina upravljanja i planiranja koji vodi brigu o okolišu. Implementacija koncepta „zelene luke" u bilo kojoj organizaciji podrazumijeva usvajanje novog stila upravljanja, čime se poduzeću omogućava da utvrdi svoje ciljeve, obveze i odgovornosti prema društvu i okolišu, razvijajući lučku djelatnost pod dobro definiranim ekološkim zahtjevima koji smanjuju negativne učinke lučkih aktivnosti (Pavlic *et al.*, 2014:938).

"Zeleni rast" usmjeren je na razvoj novih tehnologija i stvaranje novih ideja. Luke mogu profitirati od implementacije „zelenog razvoja" u smislu poboljšanja gospodarskih, komercijalnih i operativnih aktivnosti. „Zelena luka" predstavlja model održivog razvoja luka, koji ne samo da zadovoljava zahtjeve okoliša, već i povećava gospodarske interese luke. Uvođenjem ovog koncepta u planiranje poboljšava se energetska učinkovitost, primjenjuju se tehnološke inovacije što omogućuje lakšu koordinaciju zaštite okoliša i poticanje održivog gospodarskog rasta. Mnoge luke koriste zastarjelu tehnologije koja ne pridonosi energetskoj učinkovitosti i zaštiti okoliša što koncept „zelenih luka" nastoji ispraviti. Nadalje, direktive Europske unije usmjerene su na „zeleni" razvoj morskih luka, što uključuje energetsku učinkovitosti i zaštitu okoliša (Badurina *et al.,* 2017:10).

U pogledu brige za okoliš i implementacije „zelenih luka" javljaju se osnovni elementi endogene teorije rasta što potvrđuje njenu važnost u raznim aspektima poslovanja. Kao što je prethodno spomenuto, briga za okoliš u morskim lukama podrazumijeva novu tehnologiju koja je energetski učinkovita te koja će smanjiti i spriječiti zagađenje okoliša, dok je istovremeno potrebno imati i ljudski kapital koji će znati primijeniti tehnologiju te biti educiran o brizi za okoliš.

4.2. Multiplikativni učinci morskih luka i njihov utjecaj na gospodarstvo

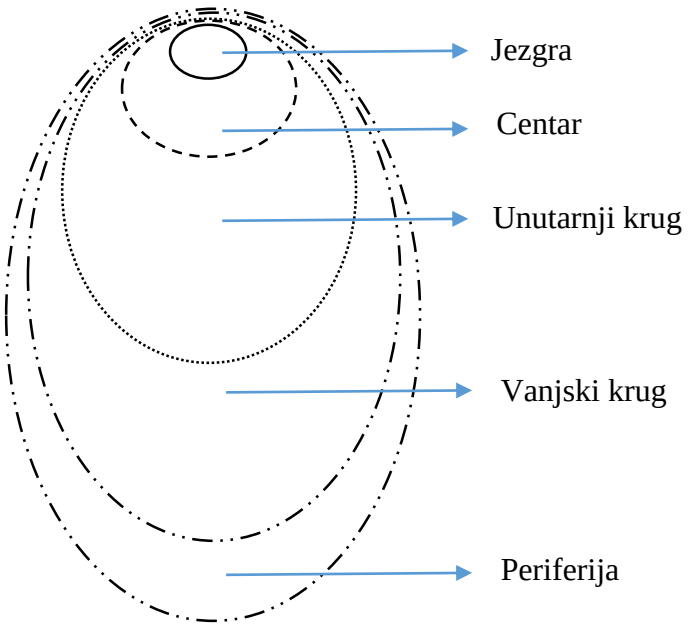
U ekonomskom smislu luka predstavlja multiplikativni financijski čimbenik za sve sudionike u poslovnim procesima, ali i za cijelo područje lučkih djelatnosti. Multimodalnost prometa u morskim lukama podrazumijeva korištenje mnogih prometnih sektora, uključujući širok spektar sudionika, od onih koji su direktno uključeni, kao što su prijevoz, utovar i istovar tereta, usluge skladištenja, do onih koji su indirektno uključeni, kao što je administracija i ugostiteljske usluge čije poslovanje ovisi o postojanju prometa između direktno uključenih sudionika (Perić Hadžić *et al.*, 2016:116)

Multiplikativni učinci mogu se definirati kao učinci koji od promjene jedne novčane jedinice dovode do promjene koja je veća od te novčane jedinice. Postoje mikromultiplikativni učinci i makromultipliktivni učinci koji čine temeljne razine promatranja gospodarskog života. Mikro razina obuhvaća pojedinca, obitelj ili poduzeće, dok makro razina obuhvaća gospodarstvo kao cjelinu. Multiplikatori se koriste kako bi se obuhvatili sekundarni učinci potrošnje i gospodarske aktivnosti u lukama. Analizom multiplikatora cilj je obuhvatiti sekundarne učinke koje stvaraju morske luke svojim poslovanjem (Kesić i Jugović, 2006:167).

Mjerenje multiplikativnih učinaka morskih luka kompleksan je proces te su provedena mnoga istraživanja i pokušaji njihovog mjerenja te ih karakteriziraju vrlo različiti rasponi metodologija. Literatura o regionalnom razvoju u velikoj se mjeri usredotočila na uspješnost (Porter, 2003) ali s malo radova vezanih uz prometnu infrastrukturu ili lučke aktivnosti. Zbog nedostatka usporedivih podataka na međunarodnoj razini, studije su većinom ograničene na istraživanje multiplikativnih učinaka na nacionalnim razinama ili razinama pojedinih luka. Na primjer studija autora De Langen (2007.) obuhvaća američke lučke regije, Perić Hadžić i suradnici (2016.) analiziraju multiplikativne učinke luke Rijeka, dok istraživanje koje je provelo Oxford Economics (2017. a) za Ministarstvo mora, prometa i infrastrukture Republike Hrvatske istražuje ekonomski utjecaj hrvatske pomorske industrije.

Određivanje ekonomskih aktivnosti koje ulaze u računanje multiplikacije složen je proces, posebice jer veličina regije utječe na jačinu multiplikacije. Stoga se mogu odrediti kružnice utjecaja koje definiraju unutarnje i vanjske krugove utjecaja ovisno o intenzitetu i važnosti. Sljedeća slika prikazuje kružnice utjecaja multiplikativnih učinaka.

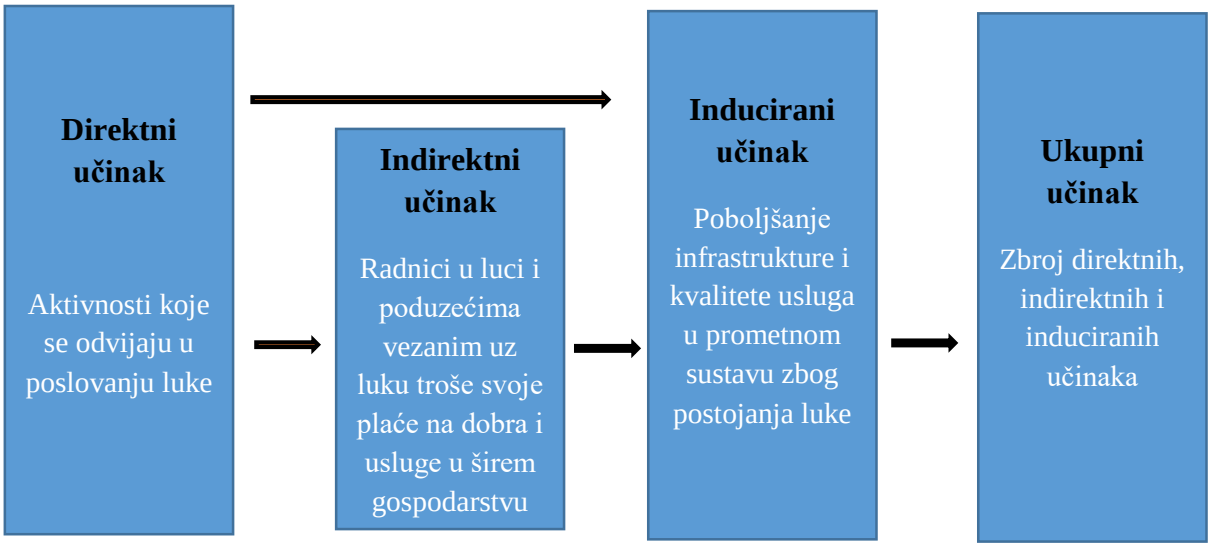
Shema 11. Kružnice ekonomskog utjecaja



Izvor: Prilagodila autorica prema Kesić i Jugović, 2006:165

Jezgra predstavlja grad ili općinu u kojem je smještena morska luka te ona uglavnom ima najveće koristi od luke. Prvenstveno su koristi vezane uz zapošljavanje i povećanje prihoda poduzećima koja su direktno vezana uz poslovanje morskih luka. Centar je područje u čijoj je blizini smještena luka te obuhvaća područja koja su udaljena najviše pola sata od luke. On također ima najveću korist koja proizlazi iz stvaranja novih radnih mjesta. Unutrašnji krug obuhvaća područja od sat vremena putovanja od luke te kvalitetnija prometna povezanost smanjuje vrijeme putovanja do udaljenih područja i povećava radijus kružnice što rezultira većim ekonomskim utjecajem. Vanjski krug sastoji se od područja od sat i pol udaljenosti od luke, dok se periferija sastoji od područja koja su dva sata udaljena od luke. Njihova tržišta većinom imaju mogućnost generirati prihode kroz opskrbu morskih luka i ostalih industrija faktorima proizvodnje (Kesić i Jugović, 2006:166-167). Multiplikativni učinci dijele se u tri kategorije: direktni učinci, indirektni učinci i izazvani učinci te se njihov opis može vidjeti na sljedećoj shemi.

Shema 12. Multiplikativni učinci poslovanja morskih luka



Izvor: Prilagodila autorica prema Oxford Economics, 2017:5

Općenito govoreći luka povećava zaposlenost, stvara dohodak te poslovnu zaradu u regijama. Prihodi koji se ostvaruju iz lučkih aktivnosti proizlaze iz različitih naknada koje se naplaćuju za brodove, teret i za korištenje luke. S pojavom modela koncesioniranja, lučke vlasti dobivaju dodatne prihode od koncesijskih naknada. Nadalje, mogu postojati dodatni prihodi od najma lučkih površina, kao što su logističke zone ili projekti vezani uz nekretnine. Navedene prednosti nastaju tokom korištenja luke ali mogu također nastati i u fazama izgradnje ili proširenja luke budući da se tijekom gradnje zapošljavaju regionalni građevinski radnici te se kupuje regionalni građevinski materijali. Radovi gradnje i samo poslovanje luke su direktni regionalni poslovi koje stvara luka. Poslovi u radu luke uključuju poslove operatora luke, korisnika luke (špeditera, morskih i kopnenih prijevoznika) i drugih davatelja usluga (npr. agent broda, popravak broda, pomorsko osiguranje, pilotaža, pružatelji usluga tegljenja i sl.). Zaposlenost, dohodak radne snage, poslovne zarade i porezni prihodi nastali izgradnjom i poslovanjem luke predstavljaju direktne regionalne prednosti luke. Implicitno se pretpostavlja da te pogodnosti ne bi postojale u regiji bez postojanja luke. Druga kategorija direktnih koristi odnosi se na prihode koje ostvaruju nacionalne prijevozničke poduzeća koja posluju s lukom, kao što su poduzeća za prijevoz kamionima i željeznice (The Geography of Transport Systems; Talley, 2009:7).

Indirektni učinci od poslovanja luke nastaju kada se njihovi inicijalni ostvareni dohodci od rada, poslovne zarade i poreznih prihoda naknadno troše ili djelomično troše u regiji. Ovi izdaci (npr., u restoranima i za zabavu i profesionalne usluge) generiraju dodatne prihode od radne snage, dodatne poslovne zarade i dodatne porezne prihode u regiji. Proces se nastavlja na drugi, treći i daljnji krug ponovne potrošnje. Kada se navedeni proces ponovne potrošnje iscrpi, ukupna zarada radne snage, ukupna poslovna zarada i ukupni porezni prihodi u regiji povećat će se za više od početnih iznosa faktorom većim od jedan tj. takozvanim faktorom multiplikacije. Sekundarne koristi od generiranih radnih mjesta, prihoda od radne snage, poslovne zarade i poreznih prihoda od potrošnje i ponovne potrošnje predstavljaju indirektne regionalne prednosti luke (Talley, 2009:7).

Indirektne koristi za korisnike luke mogu također uključivati i poduzeća koja uvoze ili izvoze robu iz luke. Nadalje, uključuju uštede koje proizlaze iz smanjenih operativnih troškova, od kojih se neki mogu ostvariti izvan neposrednog lučkog područja. Oni uključuju niže troškove prijevoza zbog smanjenog vremena obrta od poboljšanja kao što su više mjesta za vez, bolji pristup kanalima, bolja produktivnost terminala i skraćeno vrijeme obrade tereta u luci. Također mogu uključivati uštede u troškovima poslovanja broda zbog ekonomije razmjera prilikom korištenja većih brodova s više mjesta za teret. Poboljšani lučki objekti i poboljšane operacije također mogu smanjiti troškove te omogućiti manje zagušenje, povećanu produktivnost i brže vrijeme obrtaja. Druge koristi za korisnike mogu uključivati uštede u troškovima osiguranja zbog poboljšanja luke i uštede u troškovima kamata vezanih za zalihe (The Geography of Transport Systems).

Međutim, navedene koristi od luke bit će smanjene ako postoje regionalna curenja. Na primjer, u izgradnji ili proširenju luke mogu se zaposliti radnici i materijali kupljeni izvan regije te slijedom toga, direktne pogodnosti koje bi se dogodile u korištenju regionalnog rada i kupljenog materijala su izgubljene u drugim regijama ili državama. Slično tome, direktne prednosti luke bit će manje ako radna snaga koja prima dohotke i poslovne zarade od operacija luke nije stanovnik regije. Kada se izgube direktne koristi, indirektne (ili sekundarne) koristi također će biti izgubljene, budući da potonje proizlaze iz prvih. Zapravo, ako se u regiji ne potroši ni jedan od direktnih prihoda i poslovnih zarada luke, odgovarajuće indirektne pogodnosti tih izdataka za regiju bit će nula. Također, ako rezidentni primatelji direktnih primanja i poslovne zarade potroše dio tih sredstava u drugim regijama, marginalna sklonost potrošnje u regiji će se smanjiti, što će rezultirati manjim faktorom multiplikacije (Talley, 2009:7-8).

Uz direktne i indirektne učinke, luka također može generirati inducirane učinke koji proizlaze iz poboljšanja infrastrukture i kvalitete usluga u prometnom sustavu regije zbog postojanja luke. Na primjer, mogu se pojaviti poboljšanja u sustavu autocesta i željeznica što rezultira smanjenjem vremena tranzita za kretanje tereta unutar regije, povećava učestalost prikupljanja i isporuka, te povećava dostupnost prijevoznika regionalnim, nacionalnim i međunarodnim tržištima. Međutim, ako se promet tereta do i iz luke poveća do te mjere da dovodi do zagušenja autocesta, iz luke će se generirati negativne inducirane pogodnosti (Talley, 2009:8). Sve navedeno također stvara razne koristi za gospodarstvo koje uključuju pogodnosti za dobavljače proizvodnih faktora, prihode za direktno i indirektno zaposlene djelatnike u lukama te prihode industrija koje opskrbljuju luku raznim dobrima i uslugama. Ti prihodi zauzvrat generiraju ponovno trošenje što dodatno potiče zapošljavanje i dohodak kroz učinak ekonomskog multiplikatora. Lučka ulaganja također mogu imati učinak poticanja gospodarske aktivnosti u industrijama koje koriste luku. Takve koristi, međutim, nisu tako jednostavne kao koristi od uštede troškova. Inducirani učinci su sekundarni i obično se ne uzimaju u obzir u ekonomskim procjenama. To je djelomično zbog toga što je teško znati gdje se treba zaustaviti prilikom računanja krugova multiplikacije. Stoga postoji rizik od pretjerivanja prilikom analize ekonomske koristi od lučkih aktivnosti. Osim toga, u gospodarstvima u razvoju potencijalni inducirani učinci koji mogu nastati često cure u druga gospodarstva zbog nedostatka kapitala i kvalificirane radne snage te zbog uvoza roba i sirovina. Inducirani učinci također se mogu procijeniti iz ekološke perspektive gdje manje zagađenje okoliša donosi društvene koristi u smislu kvalitete života i troškova zdravstvene zaštite (The Geography of Transport Systems).

S druge strane, postojanje regionalne luke može stvarati i negativne učinke za određenu regiju. Primjer može biti ostvarivanje gubitka zbog inozemne konkurencije, zatim viši regionalni porezi namijenjeni za subvencioniranje luke ili gubitci u regionalnim prihodima od poreza na imovinu tj. nemogućnost oporezivanja državne imovine luka. Ukoliko se neki od negativnih učinaka javlja, pozitivne pogodnosti luke trebale bi biti prilagođene za negativne učinke kako bi se dobila prava mjera neto dobitka luke u regiji. Ukoliko se navedena prilagodba ne učini, vrlo je lako pretjerivati u utvrđivanju pozitivne uloge luka u regionalnom gospodarstvu (Gripaios i Gripaios, 1995:22).

Poslovanje luke ne mora samo obuhvaćati svoje multiplikativne učinke; u određenim segmentima luka u jednoj regiji može također imati učinke prelijevanja na drugu regiju. Primjerice, ukoliko jedna regija uvede novu tehnologiju ili novi način poslovanja, ideje se vrlo brzo mogu prenijeti na drugu regiju koja može kopirati prvu.

4.3. Primjer multiplikativnih učinaka morskih luka: Europska unija

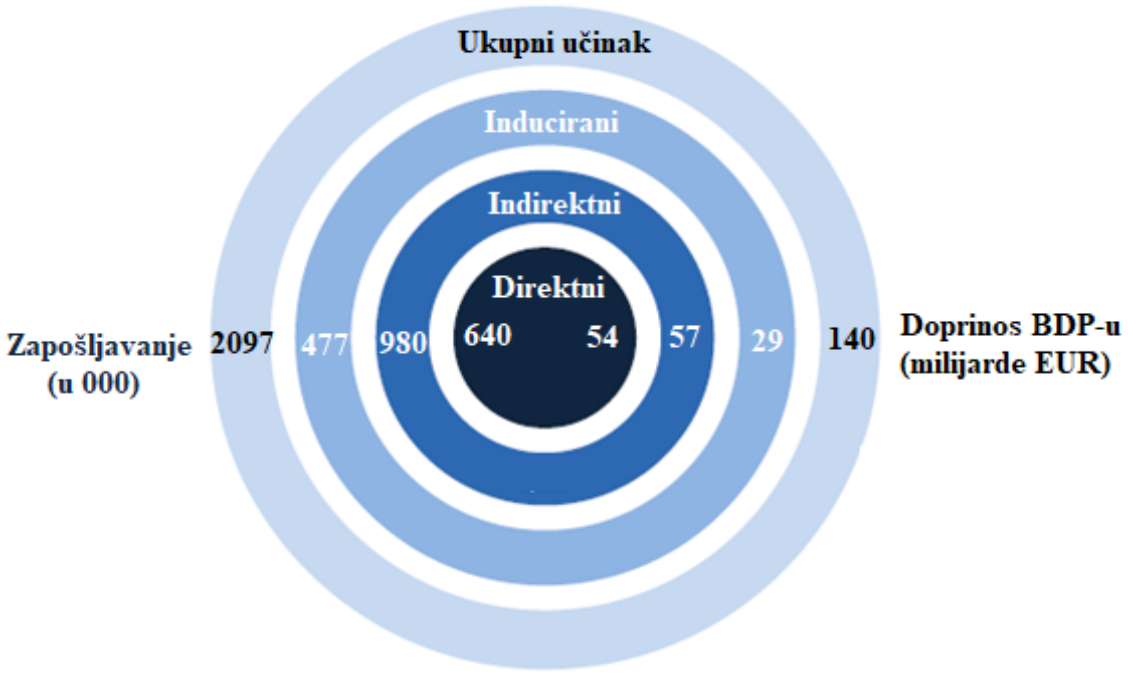
Europska unija, odnosno njene zemlje članice obuhvaćaju mnoge morske luke čiji multiplikativni učinci svakako postoje za okolna područja u kojima luke obitavaju. Oxford Economics je u svojoj studiji izrađenoj 2017. godine mjerio multiplikativni utjecaj pomorske industrije u Europskoj uniji, stoga će se u nastavku analizirati dobivene informacije. Informacije s kojima su raspolagali bile su iz 2015. godine. Pomorska industrija u ovoj studiji obuhvaća prijevoz tereta morskim putem u kontejnerima i bez kontejnera, prijevoz putnika morskim putem na trajektima i na brodovima za kružna putovanja, servisna plovila i plovila za podršku na moru te aktivnosti vuče i jaružanja na moru. U istraživanje su uključene sve zemlje članice Europske unije i Norveška.

Sagledani direktni učinci odražavaju ekonomski doprinos same pomorske industrije, dok indirektni učinci nastaju kao posljedica troškova pomorskih poduzeća na ulazne proizvode i usluge iz njihovog opskrbnog lanca Europske unije. Gospodarska aktivnost u ovoj kategoriji uključuje, na primjer, izgradnju brodova, popravke brodova, lučke usluge, osiguranje te financijske i pravne usluge povezane s otpremom. Inducirani učinci nastaju kada zaposlenici u pomorstvu i njegovom lancu opskrbe troše dio svojih plaća na robu i usluge za široku potrošnju. Navedeni učinci imaju najveći efekt na prodajna mjesta u blizini područja stanovanja zaposlenika, ali i na lance opskrbe poduzeća koja prodaju robu i usluge (Oxford Economics, 2014:10). Sljedeća shema prikazuje izračunate multiplikativne učinke pomorske industrije u Europskoj uniji. Izračunati su direktni učinci, indirektni učinci, inducirani te ukupni učinci u aspektu doprinosa bruto domaćem proizvodu te u aspektu zapošljavanja ljudi. Za svaki milijun EUR kojim europska pomorska industrija pridonosi bruto domaćem proizvodu, stvara se još 1,59 milijuna EUR drugdje u europskom gospodarstvu što znači da je multiplikator BDP-a te industrije 2,59[2]. Slijedeći isti pristup, procjenjuje se da za svaki direktan posao koji pomorska industrija stvara, negdje drugdje u europskom gospodarstvu stvara se novih 2,28 radnih mjesta,

[2] Multiplikator se izračunava kao: (direktni BDP + indirektni BDP + inducirani BDP) / direktni BDP) – formula preuzeta iz Oxford Economics, 2014:41

odnosno multiplikator zaposlenosti iznosi 3,28. Sljedeća shema prikazuje direktni, indirektni, inducirani te ukupni učinak pomorske industrije Europske unije u 2015. godini.

Shema 13. Multiplikativni učinci pomorske industrije u Europskoj uniji u 2015. godini



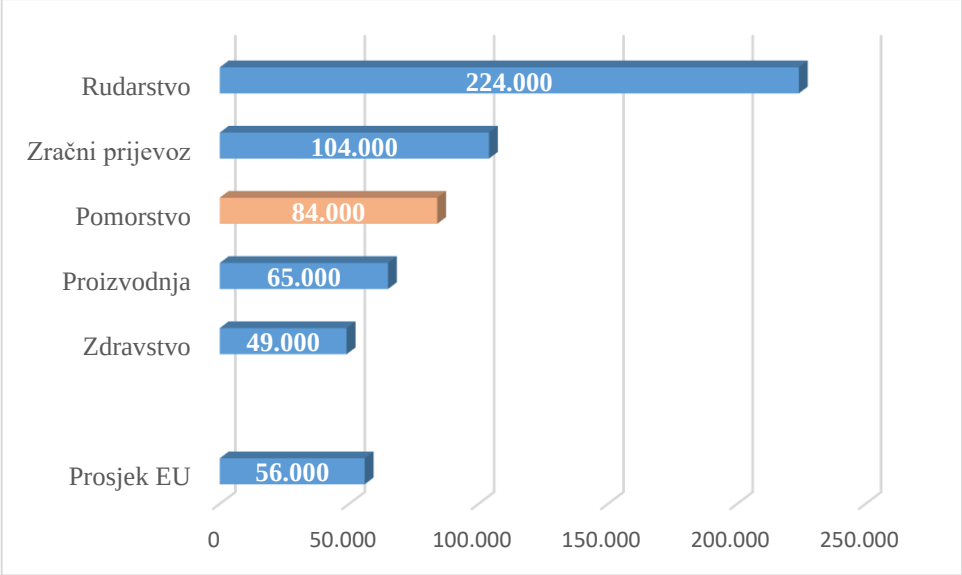
Izvor: Prilagodila autorica prema Oxford Economics, 2017b:17-18

Analizom podataka može se pružiti bolje razumijevanje ekonomske vrijednosti koju stvara pomorska industrija Europske unije, kako izravno tako i kroz interakcije s drugim dijelovima gospodarstva. Direktni doprinos pomorske industrije bruto domaćem proizvodu u Europskoj uniji procijenjen je na 54 milijarde EUR, dok se direktno zapošljava 640 000 ljudi. Indirektni učinak procijenjen na 57 milijardi EUR doprinosa bruto domaćem proizvodu te 980 000 zaposlenih ljudi. Inducirani učinak imao je 29 milijardni EUR u ukupnom bruto domaćem proizvodu u Europskoj uniji te je procijenjeno da mu pripada 477 000 zaposlenih ljudi. Inducirani učinci mogu se javiti u istoj zemlji u kojoj su nastali i direktni učinci, ali mogu se preliti i na druge zemlje Europe. Procijenjeno je da je nešto više od polovice radnih mjesta stvoreno je u istoj zemlji u kojoj se proizvodi direktni utjecaj, a nešto manje od polovice je stvoreno u drugim europskim zemljama (Oxford Economics, 2014:38).

Ukupan učinak multiplikacije ima znatan iznos od oko 140 milijardi EUR doprinosa u BDP-u te 2 097 000 zaposlene radne snage. Ukoliko se sagleda direktni učinak, može se zaključiti kako

je produktivnost u pomorskoj industriji Europske unije oko 84 300 EUR po radniku. Nadalje, indirektni učinak produktivnosti po radniku iznosi oko 58 100 EUR, inducirani 60 700 EUR, dok ukupni učinak produktivnosti po radniku iznosi 66 700 EUR. Usporedba direktne produktivnosti pomorske industrije s ostalim odabranim industrijama u Europskoj uniji, kao i s prosječnom produktivnošću u Europskoj uniji, može se vidjeti na sljedećem grafikonu.

Grafikon 4. Produktivnost u Europskoj uniji – usporedba pomorske industrije s ostalim sektorima

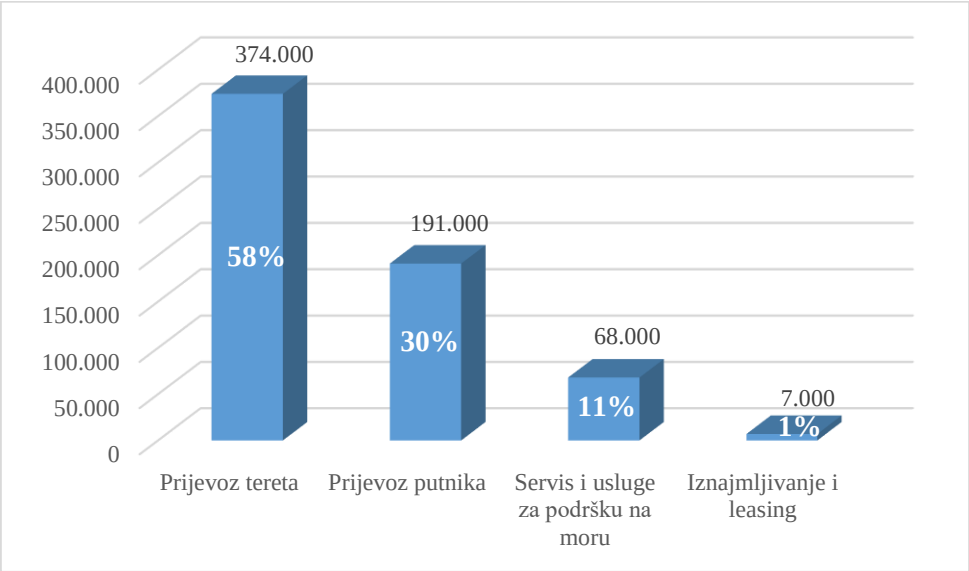


Izvor: Prilagodila autorica prema Oxford Economics, 2017b:15

Produktivnost pomorske industrije veća je od produktivnosti sektora proizvodnje te zdravstva. Također, nalazi se iznad prosjeka Europske unije koji iznosi 56 000 EUR po radniku što ukazuje na visoku značajnost pomorskog sektora. Od usporednih sektora, zračni prijevoz i rudarstvo imaju veću produktivnost po radniku od 104 000 EUR, odnosno 224 000 EUR te su to sektori koji imaju višu razinu zarade u odnosu na pomorski sektor. Visoka produktivnost industrije pomorstva znači iznadprosječni doprinos europskom bruto domaćem proizvodu čime pomaže u podizanju životnog standarda Europske unije.

U nastavku će se detaljnije analizirati samo direktni učinci pomorske industrije u aspektima zaposlenosti i doprinosa bruto domaćem proizvodu Europske unije prema podsektorima. Sljedeći grafikon prikazuje direktno zaposlene radnike u industriji pomorstva prema podsektorima prijevoza tereta, prijevoza putnika, servisa i usluga za podršku na moru te iznajmljivanja i leasinga.

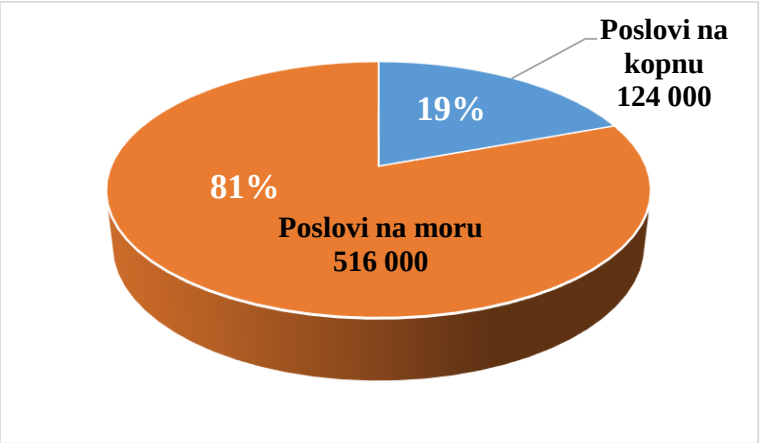
Grafikon 5. Direktno zaposleni radnici u pomorskoj industriji prema podsektoru



Izvor: Prilagodila autorica prema Oxford Economics, 2017b:9

Najviše direktno zaposlenih u industriji pomorstva je u podsektoru prijevoza tereta i to 374 000 ljudi, odnosno 58%. Nadalje, podsektor prijevoza putnika zapošljava 191 000 radnika na što otpada 30%. Budući da je prijevoz tereta općenito zastupljeniji od prijevoza putnika te je za rukovanje teretom potrebno više radne snage, navedeni udjeli bili su očekivani. Servis i usluge za podršku na moru zapošljavaju 68 000 djelatnika čime čine 11% od ukupno zaposlenih u pomorskoj industriji, dok se na posljednjem mjestu nalazi podsektor iznajmljivanja i leasinga sa 7 000 zaposlenih, odnosno 1% od ukupno zaposlenih u industriji pomorstva. Prema geografskom obuhvatu, najviše direktno zaposlenih je zaposleno u Ujedinjenom Kraljevstvu, Njemačkoj i Norveškoj (Oxford Economics, 2014:27). Udio zaposlenosti u podsektorima prijevoza tereta, prijevoza putnika, servisa i usluga za podršku na moru te iznajmljivanja i leasinga obuhvaća većinom zaposlene koji rade na moru što se može vidjeti iz sljedećeg grafikona.

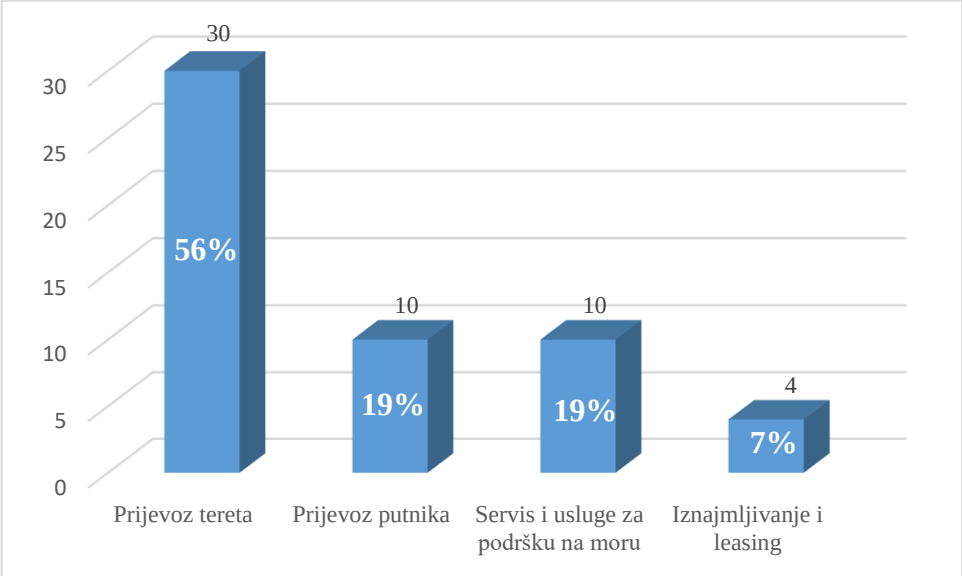
Grafikon 6. Direktno zaposleni radnici u pomorskoj industriji prema mjestu rada



Izvor: Prilagodila autorica prema Oxford Economics, 2017b:10

Poslove na moru u pomorskoj industriji obavlja 81% zaposlenih, dok poslove na kopnu obavlja 19% zaposlenih. Pretpostavka je da je cjelokupno zapošljavanje u podsektoru iznajmljivanja i leasinga smješteno na kopnu. Za prijevoz tereta i prijevoz putnika pretpostavlja se da se većinom odvijaju na moru što se dokazuje velikim udjelom poslova na moru. Prema geografskom obuhvatu zemlje koje zapošljavaju najviše radnika na moru su Ujedinjeno Kraljevstvo, Njemačka i Norveška (Oxford Economics, 2014:28). Nadalje, analiziran je direktan doprinos industrije pomorstva bruto domaćem proizvodu Europske unije prema podsektorima te se rezultati mogu vidjeti na sljedećem grafikonu.

Grafikon 7. Direktan doprinos pomorske industrije BDP-u Europske unije prema podsektoru (u milijardama EUR)



Izvor: Prilagodila autorica prema Oxford Economics, 2017b:14

Kao što je već prethodno definirano, direktan doprinos pomorske industrije bruto domaćem proizvodu je 54 milijarde EU. Unutar ukupnog doprinosa bruto domaćem proizvodu, prijevoz tereta doprinosi s 30 milijardi EUR ili 56%. Prijevoz putnika te servis i usluge za podršku na moru pridonose jednakim iznosima od 10 milijardi EUR ili 19%, dok iznajmljivanje i leasing pridonosi s 4 milijarde EUR ili 7%. Najveći doprinos bruto domaćem proizvodu dolazi iz sljedećih zemalja: Njemačka, Norveška i Grčka (Oxford Economics, 2014:32).

Morske luke doprinose svom međunarodnom konkurentskom položaju, a istovremeno doprinose i konkurentskom položaju regije u kojoj se nalaze. Pomorsko tržište izrazito je konkurentno zbog specifičnosti pomorskog prometa. Teret je vrlo lako prebaciti iz jedne luke u drugu zbog čega se luke natječu za isti teret što povećava njihovu konkurenciju. Što se tiče tržišta rada, poslovi vezani uz poslovanje morskih luka promijenili su se u odnosu na prošlost kada su se većinom tražili niskokvalificirani radnici, dok se sada češće traže radnici s višim stupnjevima obrazovanja zbog učestalije digitalizacije i tehnološke transformacije u lukama. Proces globalizacije doveo je do pada trgovinskih barijera te do jeftinije proizvodnje proizvoda. Poslovanje u morskim lukama je zbog globalizacije olakšano te stvara pozitivne učinke na regionalna gospodarstva. S druge strane, postoje i negativni učinci morskih luka na okolinu, a većinom se ogledaju u utjecajima na okoliš tj. onečišćenje zraka, mora, tla, proizvodnju otpada

i stvaranje buke. U tom segmentu morske luke moraju uložiti napore za smanjenjem zagađenja okoliša u što se mogu uključiti nove tehnologije koje su ekološki prihvatljive. U segmentu pozitivnih učinaka, luke stvaraju direktne, indirektne i inducirane učinke za okolinu. Pozitivni učinci većinom se ogledaju u stvaranju doprinosa bruto domaćem proizvodu te u radnim mjestima. Pomorska industrija uvelike pridonosi gospodarstvu ne samo kroz direktne učinke već i kroz indirektne i inducirane učinke što se moglo vidjeti na primjeru europske pomorske industrije. Morske luke važan su čimbenik za regionalna gospodarstva u kojima se nalaze te će se navedeno kvantificirati i testirati u idućem poglavlju.

5. MJERENJE EKONOMSKOG UTJECAJA MORSKIH LUKA NA REGIONALNA GOSPODARSTVA

U teorijskom dijelu rada opisana je važnost morskih luka za regionalna gospodarstva kao i važnost ulaganja u istraživanje i razvoj te ljudski kapital. Definirano je da morske luke svojim direktnim i indirektnim zapošljavanjem te direktnom i indirektnom dodanom vrijednošću stvaraju pozitivne efekte na okolinu u kojoj se nalaze. Razvoj novih ideja, bilo da se radi o malim otkrićima ili velikim tehnološkim izumima, zasigurno će imati pozitivne efekte na pripadajuće regionalno gospodarstvo. Istovremeno je potrebno imati i adekvatan ljudski kapital koji će sudjelovati u procesu inovacija ali i implementirati nova rješenja te ih dugoročno koristiti. Ukoliko luke žele ostati konkurentne na tržištu, moraju pratiti nove trendove te im se prilagođavati. Većina trendova u morskim lukama vezuje se uz automatizaciju i digitalizaciju te usmjerenje na inovacije zbog čega se javila potreba za uvođenjem navedenog čimbenika i u kvantitativni dio istraživanja, zajedno sa prethodno spomenutim ljudskim kapitalom. Kvantitativni dio istraživanja baviti će se testiranjem postavljenih hipoteza i tvrdnji iz teorijskog dijela doktorske disertacije. Testirati će se utjecaj morskih luka na regionalna gospodarstva zajedno s utjecajem ulaganja u istraživanje i razvoj i ljudskim kapitalom te utvrditi njihova povezanost.

Ekonomski utjecaj morskih luka na regionalno gospodarstvo u okviru endogene teorije rasta temeljene na istraživanju i razvoju istražiti će se primjenom dinamičke panel analize. Koristiti će se Generalizirana metoda momenata i njen procjenitelju dva koraka. Uzorak istraživanja čini 107 lučkih regija Europske unije čija je razina klasifikacije na NUTS 2 razini. Podaci su promatrani za jedanaest uzastopnih godina, odnosno od 2005. godine do 2015. godine.

U nastavku će se objasniti što su to panel podaci i panel analiza te koje vrste modela panel analize postoje. Nadalje, opisati će se Generalizirana metoda momenata te definirati uzorak istraživanja i dati detaljan opis korištenih varijabli. Deskriptivom statistikom analizirati će se glavni statistički pokazatelji varijabli nakon čega će se specificirati model. Nakon što se model testira opisati će se rezultati istraživanja zajedno s testiranjem glavne hipoteze i pomoćnih hipoteza. Na kraju poglavlja dati će se smjernice za primjenu modela u donošenju odluka te preporuke za budući rad.

5.1. Metodološki okvir modela za mjerenje utjecaja morskih luka na regionalna gospodarstva

Mjerenje utjecaja morskih luka na regionalna gospodarstva provesti će se linearnom panel analizom podataka. Panel analiza je metoda koja se sve češće koristi u ekonomskim istraživanjima budući da se njome mogu testirati kompleksniji ekonometrijski modeli te omogućuje veći obuhvat podataka. Pokazatelji uspješnosti poslovanja morskih luka biti će podaci o prometu tereta u morskim lukama. Navedeni podaci široko su prihvaćeni u literaturi kao pokazatelji uspješnosti poslovanja morskih luka. Pokazatelji stanja regionalnih gospodarstava biti će bruto domaći proizvod po glavi stanovnika izražen standardom kupovne moći (*eng. Purchasing power standard – PPS*). Izražavanje bruto domaćeg proizvoda standardom kupovne moći eliminiraju se razlike u razinama cijena između regija. Izračuni bruto domaćeg proizvoda po stanovniku omogućuju usporedbu gospodarstava i regija koje se značajno razlikuju u apsolutnoj veličini. Bruto domaći proizvod po glavi stanovnika izražen standardom kupovne moći ključan je pokazatelj za određivanje prihvatljivosti regija u okviru strukturne politike Europske unije (European Commission, 2018i).

5.2. Metoda panel analize podataka

Panel podaci se sastoje od vremenske serije za svaki član poprečnog presjeka u skupu podataka. Točnije, panel podaci obuhvaćaju podatke vremenskog niza i vremenskog presjeka, odnosno obuhvaćaju dvije dimenzije, vremensku dimenziju i prostornu dimenziju. Budući da panel podaci zahtijevaju sagledavanje istih jedinica tijekom vremena, skupove panel podataka teže je prikupiti nego podatke vremenskog presjeka i vremenskog niza. S druge strane, promatranje istih jedinica tijekom vremena dovodi do nekoliko prednosti u odnosu na podatke vremenskog presjeka i vremenskog niza. Višestruka opažanja nad istim jedinicama omogućuju kontrolu određenih nepromatranih karakteristika promatrane pojave, odnosno korištenje više od jednog promatranja može olakšati kauzalno zaključivanje u situacijama gdje bi zaključivanje o uzročnosti bilo vrlo teško ako bi bio dostupan samo jedan presjek. Druga prednost panel podataka je da omogućuju proučavanje važnosti vremenskih odmaka (*eng. lags*) te promatranje rezultata donošenja odluka nakon određenog vremena, budući da mnoge ekonomske politike imaju učinak tek nakon određenog vremenskog perioda (Wooldridge, 2015:9-10).

Korištenjem panel podataka može se dobiti točniji zaključak parametara modela jer panel podaci obično sadrže više stupnjeva slobode i više varijabilnosti uzorka od podataka vremenskog presjeka i vremenskog niza čime se poboljšava učinkovitost ekonometrijskih procjena. Nadalje, veći je kapacitet obuhvaćanja složenosti istraživanja u odnosu na podatke vremenskog presjeka ili vremenskog niza, čime se mogu definirati i testirati složeniji ekonometrijski modeli. Također se može kontrolirati utjecaj varijabli koje su izostavljene i nisu uključene u istraživanje, odnosno panel podaci mogu dopustiti da se kontroliraju učinci nedostajućih ili nepromatranih varijabli (Hsiao, 2007:3-4).

Neka od najčešćih ograničenja korištenja panel analize podataka su razlike u mjerenju i prikupljanju podataka koje mogu dovesti do neispravno definiranih podataka. Dostupnost podataka je također jedno od ograničenja budući da često dostupni podaci za različite vremenske serije nisu jednaki za sve promatrane jedinice. Kratka dimenzija vremenske serije također se može javiti kao ograničenje kao i problem nedostajućih podataka u pojedinim razdobljima (Baltagi, 2005:7).

Podaci obuhvaćeni dvjema dimenzijama moraju biti homogeni što znači da njihove jedinice promatranja trebaju imati zajednička svojstva. Ukoliko taj uvjet nije ispunjen rezultati analize mogu biti nerelevantni. Panel podaci prema kriteriju raspoloživosti mogu biti balansirani i nebalansirani. Balansirani panel podaci su oni koji za svaku jedinicu promatranja, u svakom razdoblju, za sve varijable imaju dostupne potrebne podatke, a ukoliko za bilo koju jedinicu promatranja nedostaje podatak za neku varijablu u nekom razdoblju tada je riječ o nebalansiranim podacima (Škrabić Perić, 2018). Prema ovisnosti o zavisnoj varijabli razlikuju se statički panel modeli i dinamički panel modeli koji će detaljnije biti obrađeni u nastavku.

Panel analiza ne može otkloniti u potpunosti sve nedostatke, no istovremeno ima mnoge prednosti u odnosu na podatke vremenskog niza i vremenskog presjeka. Stoga panel analiza postaje sve popularnija u ekonomskim istraživanjima različitih grana, a između ostaloga prisutna je i u istraživanjima koja se bave ekonomijom luka.

5.2.1. Vrste panel modela

Panel modeli sagledavani iz aspekta ovisnosti o zavisnoj varijabli dijele se u dvije kategorije: statički panel modeli i dinamički panel modeli. Postoji više pristupa statičkoj varijaciji panel modela kao što su združeni model, model „između“ jedinica promatranja, model s fiksnim efektom i model sa slučajnim efektom koji su ukratko opisani u nastavku.

Statički modeli

Združeni panel model (*engl. pooled OLS*) je najjednostavniji panel model, a definira se kao:

$$y_{it} = \alpha + \beta_1 x_{it1} + \beta_2 x_{it2} + \ldots + \beta_K x_{itK} + \varepsilon_{it}; \qquad i = 1 \ldots N, t = 1 \ldots T$$

pri čemu je y_{it} zavisna varijabla, α konstantni član koji je jednak za sve jedinice promatranja i ne mijenja se kroz vrijeme, $\beta_1 \ldots \beta_K$ su parametri koje je potrebno procijeniti, x_{it} označava nezavisne varijable, ε_{it} označava grešku relacije, i označava subjekt promatranja, t vremensku jedinicu te k vrijednost pojedine nezavisne varijable.

Združeni panel model pretpostavlja međusobnu nekoreliranost grešaka i nekoreliranost grešaka i nezavisnih varijabli. No, s obzirom da se u panel podacima podaci o jednoj jedinici promatranja ponavljaju kroz više razdoblja, gotovo je nemoguće očekivati međusobnu nekoreliranost grešaka relacije u različitim razdobljima. Također je gotovo nemoguće očekivati nekoreliranost grešaka relacije i nezavisnih varijabli. Združeni panel model ne pretpostavlja različitosti između jedinica promatranja te očekuje konstantnu varijancu između jedinica promatranja. Radi svega navedenoga, združeni panel model može dati pristrane i nekonzistentne procjene te se standardne greške mogu podcijeniti jer zanemaruju pozitivnu korelaciju unutar jedinica promatranja, odnosno neke varijable se mogu smatrati statistički značajnima, a zapravo to nisu (Škrabić Perić, 2018).

Model „između“ (*eng. between*) jedinica promatranja izračunava prosječnu vrijednost za svaku jedinicu promatranja, a definira se na sljedeći način:

$$\bar{y}_i = \beta + \beta_1 \bar{x}_{i1} + \beta_2 \bar{x}_{i2} + \ldots + \beta_K \bar{x}_{iK} + \bar{\varepsilon}_i; \qquad i = 1 \ldots N$$

pri čemu je $\bar{y}_i$ prosječna vrijednost zavisne varijable i-te jedinice promatranja, $\beta_1 \ldots \beta_K$ su parametri koje je potrebno procijeniti, $\bar{x}_{iK}$ je prosječna vrijednost k-te nezavisne varijable i i-te

jedinice promatranja, $\bar{\varepsilon}_i$ je prosječna vrijednost greške *i*-te jedinice promatranja, *i* označava subjekt promatranja, *t* vremensku jedinicu te *k* vrijednost pojedine nezavisne varijable.

Procjenitelji modela „između" jedinica promatranja mogu procijeniti utjecaj varijabli koje nisu promjenjive kroz vrijeme. Oni su konzistentni ali nisu efikasni jer se uprosječivanjem podataka gubi vremenska komponenta te se gubi na preciznosti rezultata. Navedeni model nije primjenjiv za podatke koji sadrže varijable koje su promjenjive kroz vrijeme i imaju veliki broj opažanja (Škrabić Perić, 2018).

Model s fiksnim efektom je jednostavni linearni model u kojem je konstantni član konstantan u vremenu ali se mijenja sa svakom jedinicom promatranja. Model se definira na sljedeći način:

$$y_{it} = \alpha_i + \beta_1 x_{it1} + \beta_2 x_{it2} + \ldots + \beta_K x_{itK} + \varepsilon_{it}; \qquad i = 1 \ldots N, t = 1 \ldots T$$

pri čemu je y_{it} zavisna varijabla, α_i je konstantni član različit za svaku jedinicu promatranja, $\beta_1 \ldots \beta_K$ su parametri koje je potrebno procijeniti, x_{itK} označava vrijednost *k*-te nezavisne varijable, *i*-te jedinice promatranja u razdoblju *t*, ε_{it} je greška procjene *i*-te jedinice promatranja u trenutku *t* i pretpostavlja se da su ε_{it} nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu, sa sredinom 0 i varijancom σ_ε^2. Pretpostavlja se da su svi x_{itK} nezavisni s ε_{it} za sve *i, t, k.* Subjekt promatranja označen je s *i*, vremensku jedinicu označava *t*, a pojedine vrijednosti nezavisne varijable označene su s *k.*

Model s fiksnim efektom koristi transformaciju kako bi uklonio nepromatrani učinak prije procjene (Wooldridge, 2015:434). Procjenitelj fiksnih učinaka je djelotvoran kada su pogreške serijski nekorelirane i homoskedastične, a ne pretpostavlja se korelacija između neopaženog učinka i nezavisnih varijabli (Wooldridge, 2015:450). Prednost procjenitelja parametara u modelu s fiksnim efektom je konzistentnost procjene u slučaju kada postoji korelacija između slučajne komponente greške relacije α_i i nezavisne varijable (Škrabić Perić, 2018).

Model sa slučajnim efektom je jednostavan linearan model u kojem se pretpostavlja da su jedinice promatranja odabrane na slučajan način te da su razlike između jedinica promatranja slučajne. Definira se na sljedeći način:

$$y_{it} = \mu + \beta_1 x_{it1} + \beta_2 x_{it2} + \ldots + \beta_K x_{itK} + \alpha_i + \varepsilon_{it}; \qquad i = 1 \ldots N, t = 1 \ldots T$$

pri čemu je y_{it} zavisna varijabla, μ zajednički konstantni član za sve jedinice promatranja, β_1 ... β_K su parametri koje je potrebno procijeniti, x_{it} označava nezavisne varijable, α_i je slučajni efekt za svaku jedinicu promatranja. Pretpostavka ovog modela je da su α_i nezavisno i identično distibuirane slučajne varijable po jedinicama promatranja sa sredinom 0 i varijancom σ_α^2. Također, pretpostavka je da su ε_{it} nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu, sa sredinom 0 i varijancom σ_ε^2.

Model sa slučajnim efektom se koristi u slučaju kada je nepromatrani učinak nekoreliran sa svim eksplanatornim varijablama. Ukoliko se u model uvedu dobre kontrole, može se vjerovati da bilo koja ostala zanemarena heterogenost inducira samo serijsku korelaciju u terminu kompozitne pogreške, ali ne uzrokuje korelaciju između složenih pogrešaka i eksplanatornih varijabli. Procjena modela slučajnih učinaka generaliziranih najmanjih kvadrata je prilično jednostavna i rutinski se provodi u mnogim ekonometrijskim paketima (Wooldridge, 2015:434).

Dinamički modeli

Dinamički panel model javlja se kada se zavisna varijabla s vremenskim odmakom (*eng. lag*) koristi kao regresor. Većina ekonomskih pojava je dinamička, odnosno sadašnja vrijednost određene varijable ovisi o prethodnim vrijednostima iste varijable. U dinamičkim panel modelima kao jedna od nezavisnih varijabli javlja se zavisna varijabla s pomakom za jedan ili više perioda unatrag, ovisno o svojstvima zavisne varijable. Dinamički panel model definira se na sljedeći način:

$$y_{it} = \mu + \gamma y_{it-1} + \beta_1 x_{it1} + \beta_2 x_{it2} + \ldots + \beta_K x_{itK} + \alpha_i + \varepsilon_{it}; \qquad i = 1 \ldots N, t = 1 \ldots T$$

pri čemu je y_{it} zavisna varijabla, μ zajednički konstantni član za sve jedinice promatranja, γ procjenitelj parametra, y_{it-1} zavisna varijabla s pomakom za jedan period unatrag, β_1 ... β_K su parametri koje je potrebno procijeniti, x_{it} označava nezavisne varijable, α_i je slučajni efekt za svaku jedinicu promatranja, ε_{it} greške relacije za koje se podrazumijeva da su nezavisno i identično distribuirane slučajne varijable sa sredinom 0 i varijancom σ_ε^2. Oznaka *i* predstavlja subjekt promatranja, *t* vremensku jedinicu te *k* vrijednost pojedine nezavisne varijable.

U istraživanju u doktorskoj disertaciji kao zavisna varijabla javlja se bruto domaći proizvod po glavi stanovnika na kojega utječe njegova vrijednost iz prethodne godine, stoga će se u

ekonometrijskoj analizi koristiti dinamički panel model, točnije generalizirana metoda momenata i njen procjenitelj u dva koraka koja je opisana u nastavku.

5.2.2. Generalizirana metoda momenata i njen procjenitelj u dva koraka

Za potrebe testiranje modela primijeniti će se Generalizirana metoda momenata i njen procjenitelj u dva koraka *(eng. two-step Generalized Method of Moments – GMM).* Navedena metoda izvedena je od Arellano i Bond (1991.) te je zatim modificirana od Blundell i Bond (1998.). GMM procjenitelj koristi lagirane vrijednosti zavisne varijable kao nove nezavisne varijable. No, uvođenjem lagirane vrijednosti zavisne varijable kao nove nezavisne varijable mogao bi se javiti problem endogenosti varijabli te povratne kauzalnosti, stoga se nova varijabla uvodi kao instrument. Instrument je nova varijabla koja nije korelirana s greškom te utječe na zavisnu varijablu ali samo putem nezavisne varijable. Preporuka dosadašnjih istraživanja je da broj instrumenta ne smije biti veći od broja jedinica promatranja.

U kontekstu panel podataka, potrebno je baviti se nepromatranom heterogenošću. Sposobnost diferenciranja za uklanjanje nevidljive heterogenosti temelj je raznih procjenitelja koji su razvijeni za dinamičke panel modele. Jedan od navedenih procjenitelja je i Arellano – Bond procjenitelj koji će se koristiti u testiranju modela. Arellano – Bond procjenitelj i njegovo proširenje na GMM sustav koristi se u sljedećim slučajevima (Baum, 2014):

- Kada se radi o kratkom vremenskom razdoblju (N), a mnogo jedinica promatranja (T)
- Kada postoji linearni funkcionalni odnos
- Kada je zavisna varijabla dinamična tj. ovisi o vlastitim prošlim vrijednostima
- Kada nezavisne varijable nisu strogo egzogene tj. korelirane su s prošlim i moguće trenutnim realizacijama pogreške
- Kada se javljaju fiksni pojedinačni učinci što implicira nevidljivu heterogenost
- Kada postoji heteroskedastičnost i autokorelacija unutar pojedinih jedinica grešaka, ali ne i preko njih

Potencijalna slabost Arellano-Bond procjenitelja otkrivena je u kasnijim radovima Arellano i Bover (1995.) i Blundell i Bond (1998.). Lagirane razine često su prilično loši instrumenti za varijable koje imaju prvu diferencijaciju. Njihova modifikacija procjenitelja uključuje i lagirane razine kao i lagirane diferencijacije (Baum, 2014). Arellano-Bover/Blundell-Bond procjenitelj modificira Arellano-Bond procjenitelj dodatnom pretpostavkom da su prve diferencijacije

instrumentalnih varijabli nekorelirane s fiksnim učincima. To omogućuje uvođenje više instrumenata i može dramatično poboljšati učinkovitost. Procjenitelj gradi sustav od dvije jednadžbe - izvornu jednadžbu i transformiranu - i poznat je kao sustav GMM. (Roodman, 2009:86).

5.3. Testiranje modela

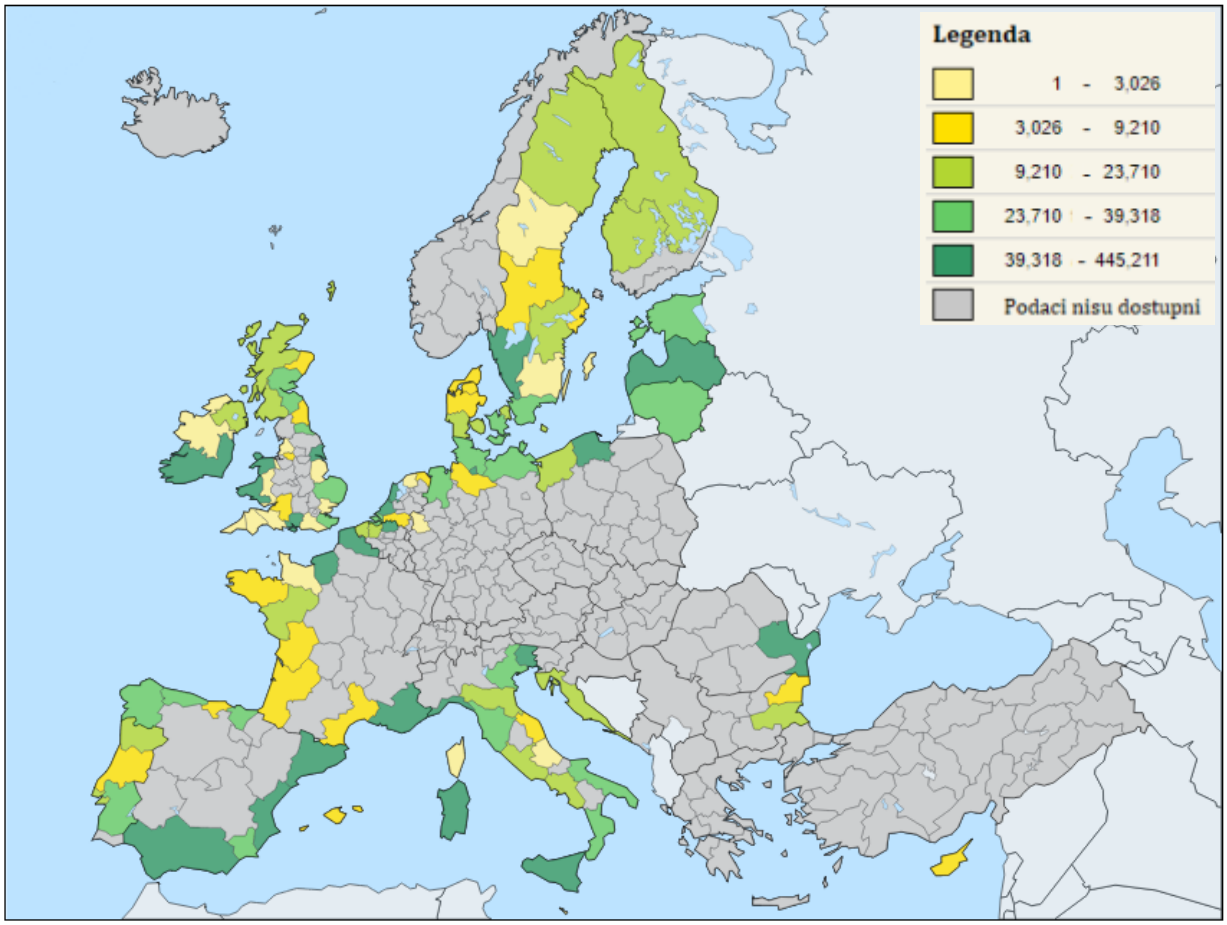
Važnost adekvatnog poslovanja morskih luka koje prate i primjenjuju nove tehnologije za rast gospodarstva teorijski je definirana u prethodnim poglavljima te je navedeno potrebno i testirati. U nastavku će se primjenom dinamičke panel analize definirati utjecaj poslovanja morskih luka na regionalno gospodarstvo kao i utjecaj ulaganja u istraživanje i razvoj te ljudskog kapitala na regionalno gospodarstvo. Testiranje će obuhvatiti gospodarski rast kao zavisnu varijablu analize te promet tereta, ulaganje u istraživanje i razvoj te ljudski kapital kao glavne nezavisne varijable. Kontrolne varijable također su dio panel analize te sadrže varijable koje se tiču stope nezaposlenosti, populacije, trgovinske otvorenosti i ulaganja u prometnu infrastrukturu svake regije zasebno. U sljedećim potpoglavljima definirati će se uzorak istraživanja te deskriptivnom statističkom analizom dati glavni zaključci o korištenim podacima. Nakon toga specificirati će se modeli te isti testirati i opisati rezultati testiranja modela.

5.3.1. Definiranje uzorka istraživanja i opis korištenih podataka

Za potrebe istraživanja, prikupili su se sekundarni panel podaci s Eurostata za razdoblje od 2005. do 2015. godine (European Commission, 2018i, 2018f, 2018e, 2018j, 2018l, 2018h, 2018a, 2018b). U obzir je uzeto 107 lučkih regija, odnosno regija koje u Eurostatu imaju definirani i kvantificirani promet tereta u morskim lukama. Razina agregacije podataka je NUTS 2 klasifikacija. NUTS (Nomenklatura prostornih jedinica za statistiku, *franc. Nomenclature des unités territoriales statistiques*) je hijerarhijski sustav za identifikaciju i klasifikaciju prostornih jedinica za potrebe službene statistike u zemljama članicama Europske unije. Sustav je razvijen od Europskog ureda za statistiku za potrebe uspoređivanja regija unutar Europe. Teritorijalne jedinice su grupirane prvenstveno za statističke svrhe te ne tvore nužno upravne jedinice (European Commission, 2018g). Zemlje čije regije su se obuhvatile u istraživanju su sljedeće: Belgija, Bugarska, Danska, Njemačka, Estonija, Irska, Španjolska, Francuska, Hrvatska, Italija, Cipar, Latvija, Litva, Malta, Nizozemska, Poljska, Portugal, Rumunjska, Finska, Švedska i Ujedinjeno Kraljevstvo. Grčka i Slovenija isključene su iz

istraživanja premda imaju podatke za promet tereta u morskim lukama ali nemaju zabilježene podatke o ulaganju u istraživanje i razvoj. Na sljedećem zemljovidu prikazane su korištene regije zajedno s intervalom količine prometa tereta koji se ostvario u svakoj pojedinoj regiji. U prilogu rada nalazi se popis regija korištenih u istraživanju.

Zemljovid 3. Regije Europske unije uključene u istraživanje



Izvor: European Commission, 2016

Razvijenost pomorskih regija Europske unije je različita te se analizom podataka o bruto domaćem proizvodu po glavi stanovnika, koji se nalaze u prilogu rada, može zaključiti kako su najrazvijenije lučke regije one koje se nalaze u Njemačkoj, Nizozemskoj, Švedskoj, Belgiji, Ujedinjenom Kraljevstvu i Irskoj, dok su najmanje razvijene one koje se nalaze u Rumunjskoj, Bugarskoj, Poljskoj, Hrvatskoj, Latviji, Italiji i Portugalu. Navedene razlike u razvijenosti potrebno je imati na umu i prilikom daljnjeg istraživanja i testiranja postavljenog modela. Što se tiče prometa tereta, najvećom količinom tereta prometuje se regijama koje pripadaju Nizozemskoj, Belgiji, Njemačkoj, Španjolskoj, Francuskoj, Ujedinjenom Kraljevstvu i Italiji te

se može uočiti povezanost razvijenosti regije i prometa tereta u morskim lukama. Ukoliko se sagleda najmanja količina prometa tereta u morskim lukama, može se uočiti da se odvija u regijama koje pripadaju Nizozemskoj, Španjolskoj, Ujedinjenom Kraljevstvu, Portugalu, Italiji, Francuskoj i Cipru. Zanimljivo je da se istovremeno najveća i najmanja količina tereta odvija u regijama koje pripadaju Nizozemskoj, Španjolskoj, Ujedinjenom Kraljevstvu, Italiji i Francuskoj što govori da su pomorske regije u istim zemljama na različitim razinama pomorske razvijenosti.

Kako bi se istražio utjecaj lučkih aktivnosti na regionalna gospodarstva, formulirao se regresijski model. Zavisna varijabla regresijskog modela je pokazatelj rasta regionalnog gospodarstva. Prateći literaturu (Bilbao-Osorio i Rodriguez-Pose, 2004; Crescenzi i Rodríguez-Pose, 2012; Bottasso *et al.*, 2014; Shan *et al.*, 2014; Jouili, 2016; Park i Seo, 2016) kao zavisna varijabla koristi se BDP per capita (GDPpc). Nezavisne varijable uključuju pokazatelj aktivnosti morskih luka, zatim varijable koje se povezuju s endogenom teorijom rasta te skup kontrolnih varijabli koje se povezuju s regionalnim gospodarskim rastom.

Glavnu nezavisnu varijablu čini promet tereta u morskim lukama (Freight) koji je izražen u tonama. Promet tereta u morskim lukama je široko prihvaćeni pokazatelj poslovanja luka (Ferrari *et al.*, 2010; Cheung i Yip, 2011; Bottasso *et al.*, 2013, Bottasso *et al.*, 2014; Shan *et al.*, 2014; Park i Seo, 2016). Kako bi se istražio učinak čimbenika relevantnih prema endogenoj teoriji rasta, uključene su i varijable ulaganje u istraživanje i razvoj (RD) i ljudski kapital (HC). U istraživanju je ljudski kapital reprezentiran kao postotak populacije od 25 – 64 godina koji su završili tercijarno obrazovanje po uzoru na sljedeće autore: Crescenzi i Rodriguez-Pose (2012.), Crescenzi (2005.), Hong i suradnici (2011.) i Ferrari i suradnici (2010.). Europska komisija također ljudski kapital objašnjava u sklopu obrazovnih dostignuća (European Commission, 2017a:1). Mogućnost objašnjavanja razlika u regionalnom rastu na temelju diferenciranih inovativnih aktivnosti temelji se na razumijevanju mehanizma kroz koji se znanje stvara, implementira te stvara efekte za rast gospodarstva. U većini slučajeva tehnološki napredak ovisan je o ljudskom znanju, prvenstveno potrebno je znanje da se razvije nova tehnologija ili inovacija, a zatim znanje da bi se ta tehnologija ili inovacija mogla primijeniti i koristiti. Radi toga je visoko obrazovanje uzeto kao varijabla koja reprezentira ljudski kapital jer je pretpostavka da će i pri aktivnostima istraživanja i razvoja sudjelovati visokoobrazovani ljudi kao i pri aktivnostima njihove implementacije (Bilbao-Osorio i Rodriguez-Pose, 2004; Crescenzi i Rodríguez-Pose, 2012).

U istraživanje se uključio i set kontrolnih varijabli kako bi se obuhvatili i drugi čimbenici osim samog učinka luke. Kontrolira se razina nezaposlenosti (Unempl), zatim populacija svake određene regije odnosno promjena broja stanovnika (Pop), trgovinska otvorenost (Open) te ulaganje u prometnu infrastrukturu (Transport).

U idućoj tablici može se vidjeti popis svih varijabli dok se u prilogu nalaze korišteni podaci za svaku varijablu.

Tablica 7. Popis i objašnjenje varijabli

Zavisna varijabla	**Opis**	**Formulacija**
GDPpc	Bruto domaći proizvod po glavi stanovnika	Izražen standardom kupovne moći *(eng. purchasing power standard – PPS)* u EUR
Nezavisne varijable	**Opis**	**Formulacija**
Freight	Promet tereta u morskim lukama	1 000 tona
RD	Ulaganje u istraživanje i razvoj	% od BDP-a
HC	Ljudski kapital	% populacije od 25 – 64 godina koji su završili tercijarno obrazovanje
Kontrolne varijable	**Opis**	**Formulacija**
Unempl	Stopa nezaposlenosti	% nezaposlenih u ukupnoj radnoj snazi
Pop	Populacija	% ukupne promjene stanovništva na 1 000 osoba
Open	Trgovinska otvorenost	% uvoza i izvoza u BDP-u
Transport	Ulaganje u prometnu infrastrukturu	% od BDP-a

Izvor: Izrada autorice

Svi podaci potrebni za testiranje modela bili su dostupni na NUTS 2 razini, osim trgovinske otvorenosti te ulaganja u prometnu infrastrukturu koji su samostalno izvedeni. Prvi korak je bio utvrditi udio tj. postotak BDP-a per capita svake pojedine NUTS 2 regije u ukupnom BDP-u per capita pripadajuće zemlje. U Eurostatu trgovinska otvorenost dostupna je samo na razini cjelokupnog gospodarstva, stoga se izračunati postotak udjela BDP-a per capita svake određene regije pomnožio s trgovinskom otvorenošću pripadajuće zemlje te se na takav način za svaku pojedinu regiju dobio podatak o njenoj trgovinskoj otvorenosti. Isti princip primijenio se i za izračun podataka o ulaganju u prometnu infrastrukturu. Podaci o ulaganjima u prometnu infrastrukturu u Eurostatu postoje samo na razini država te su se pomnožili s postotkom udjela BDP-a per capita svake određene regije kako bi se dobili podaci na NUTS 2 razini. Eurostatovi podaci o ulaganju u istraživanje i razvoj, podaci su za koje relativno mnogo vrijednosti nedostaje, stoga su se nedostajuće vrijednosti, koje su to dozvoljavale, izračunale linearnom interpolacijom.

5.3.2. Deskriptivna statistička analiza podataka

Deskriptivnom statistikom se najčešće analizira broj opažanja, srednja vrijednost, minimalna vrijednost opažanja, maksimalna vrijednost opažanja te standardna devijacija. U sljedećoj tablici može se pratiti deskriptivna statistika za svaku pojedinu varijablu.

Tablica 8. Deskriptivna statistika varijabli

Varijabla	Broj opažanja	Aritmetička sredina	Standardna devijacija	Minimum	Maksimum
GDPpc	1 175	25 269,19	7 617,80	7 100,00	59 500,00
Freight	1 176	31 178,99	45 982,07	240,00	448 598,00
RD	1 136	1,39	1,02	0,06	5,44
HC	1 165	26,96	8,73	7,30	52,20
Unempl	1 161	9,26	5,55	2,00	37,00
Pop	1 167	4,27	7,35	-28,90	54,80
Open	1 175	14,67	37,31	0,82	325,86
Transport	1 173	0,28	0,50	0,03	3,70

Izvor: Izračun autorice

Budući da se podaci promatraju za 107 regija kroz vremenski period od 11 godina (od 2005. do 2015. godine), maksimalan broj opažanja je 1 177. Promatrajući broj opažanja svake varijable zasebno, može se vidjeti kako većina varijabli ima gotovo sve podatke uz manje nedostatke. Najmanje podataka postoji za ulaganje u istraživanje i razvoj (1 136), odnosno za navedenu varijablu nedostaje 41 podatak.

Standardna devijacija kao prosječno odstupanje od prosječne vrijednosti promatranog uzorka pokazuje veće varijacije kod bruto domaćeg proizvoda po glavi stanovnika što upućuje na činjenicu da postoje znatne razlike između razvijenosti regija tj. neke od promatranih lučkih regija Europske unije su manje ili više gospodarski razvijene u odnosu na ostale. Najmanji BDP po glavi stanovnika iznosi 7 100,00 EUR te je ostvaren u rumunjskoj NUTS 2 regiji Sud Est 2005. godine, dok je najveći BDP po glavi stanovnika ostvaren u Njemačkoj, točnije NUTS 2 regiji Hamburg u 2015. godini i iznosi 59 500,00 EUR. Nadalje, standardna devijacija varijable prometa tereta u morskim lukama također pokazuje veće varijacije što ukazuje da u različitim regijama postoje velike razlike u prometu tereta. Isto pokazuje i minimum od 240,00 tona ostvaren 2013. godine u NUTS 2 regiji Friesland koja se nalazi u Nizozemskoj u odnosu na maksimum od 448 598,00 tona koji je ostvaren također u Nizozemskoj, no u NUTS 2 regiji Zuid-Holland u 2015. godini. Trgovinska otvorenost također ima nešto veću standardnu devijaciju što ukazuje na razlike između postotka uvoza i izvoza u BDP-u u različitim lučkim regijama. Potrebno je obratiti pozornost i na varijablu koja prikazuje populaciju te je iskazana kao postotak ukupne promjene stanovništva na 1 000 osoba. Navedena varijabla jedina sadrži negativne vrijednosti te njen minimum iznosi -28,90 % i ostvaren je 2010. godine u Litvi (NUTS 2 regija Lietuva) što ukazuje na činjenicu da je promjena stanovništva u navedenoj regiji bila negativna. Najveća vrijednost promjene stanovništva dogodila se 2013. godine u talijanskoj NUTS 2 regiji Lazio (54,80%). Najmanje standardne devijacije imaju varijable ulaganje u istraživanje i razvoj te ulaganje u prometnu infrastrukturu što je i očekivano budući da se omjeri ulaganja ne mijenjaju drastično tokom godina i unutar regija.

Navedeni rezultati deskriptivne statistike očekivani su budući da je pretpostavka da su različite lučke regije Europske unije različito gospodarski razvijene kao i da je i ostvareni promet tereta u regijama različit. Testiranjem modela želi se saznati što utječe na rast regija te koji su potencijalni čimbenici rasta na koje je potrebno obratiti pozornost. Prije samog formuliranje i testiranja modela provjerila se korelacija između varijabli. Tablica u nastavku prikazuje koeficijente korelacije varijabli.

Tablica 9. Koeficijenti korelacije

	***ln* GDPpc**	***ln* Freight**	**RD**	**HC**	**Unempl**	**Pop**	**Open**	**Transport**
ln GDPpc	1							
ln Freight	0,08	1						
RD	0,54	0,19	1					
HC	0,46	0,00	0,47	1				
Unempl	-0,36	0,05	-0,25	-0,16	1			
Pop	0,35	-0,16	0,16	0,18	-0,16	1		
Open	-0,09	-0,01	-0,07	0,04	-0,02	-0,07	1	
Transport	-0,19	0,08	-0,04	0,07	0,02	-0,22	0,76	1

Izvor: Izračun autorice

Kao prag za prisutnost korelacije uzela se pozitivna ili negativan korelacija veća od 0,80 (Lovrić, 2005). Niti jedan od koeficijenata korelacija nije viši od 0,80 niti niži od -0,80, što pokazuje izostanak multikolinearnosti. Viša korelacija između varijabli Transport i Open (0,76) ukazuje na srednje jaku povezanost između navedenih varijabli.

5.3.3. Specifikacija empirijskog modela

Model linearne regresije panel podataka pruža nekoliko prednosti. U usporedbi s modelom vremenskog presjeka ili modelom vremenskih serija, panel model sadrži više stupnjeva slobode i više varijabilnosti uzorka zbog čega se mogu dobiti uvjerljiviji rezultati. Nadalje, panel model omogućuje određivanje smjera uzročnosti. Iako je prvenstveno zanimanje vezano uz smjer utjecaj morske luke na regiju, gospodarski rast regije također bi mogao utjecati na luku. Model također uključuje skup kontrolnih varijabli koje mogu utjecati na gospodarski rast.

Kako bi se istražila veza između regionalnog gospodarskog rasta i poslovanja morskih luka ali i ostalih prethodno opisanih čimbenika, uvodi se model dinamičke panel analize. Model je sljedeći:

$$ln\,GDPpc_{it} = \beta_0 + \beta_1 lnGDPpc_{it-1} + \beta_2 lnFreight_{it} + \beta_3 RD_{it} + \beta_4 HC_{it} + Control_{it} + \lambda_t + u_{it}$$

pri čemu je $ln\ GDPpc_{it}$ logaritmirana vrijednost bruto domaćeg proizvoda po glavi stanovnika za regiju *i*, u vremenu *t*, $lnGDPpc_{it-1}$ je logaritmirana vrijednost bruto domaćeg proizvoda po glavi stanovnika za regiju *i*, u vremenu *t-1*, $lnFreight_{it}$ je logaritmirana vrijednost prometa tereta u morskim lukama za regiju *i*, u vremenu *t*, RD_{it} je vrijednost ulaganja u istraživanje i razvoj za regiju *i*, u vremenu *t*, HC_{it} je pokazatelj ljudskog kapitala za regiju *i*, u vremenu *t*, $Control_{it}$ predstavlja kontrolne varijable koje obuhvaćaju stopu nezaposlenosti, populaciju, trgovinsku otvorenost te ulaganje u prometnu infrastrukturu za regiju *i*, u vremenu *t* ($Control_{it} = Unempl_{it} + Pop_{it} + Open_{it} + Transport_{it}$). λ_t predstavlja vremenske učinke, u_{it} grešku relacije, a β_1, β_2, β_3, i β_4 su koeficijenti.

Kako bi se utvrdio značaj svake od nezavisnih varijabli zasebno, uvode se četiri varijacije modela. Prva varijacija obuhvaća promet tereta kao nezavisnu varijablu te skup kontrolnih varijabli koje se uključuju u svaku varijaciju modela.

Model 1:

$$\ln GDPpc_{it} = \beta_0 + \beta_1 lnGDPpc_{it-1} + \beta_2 lnFreight_{it} + Control_{it} + \lambda_t + u_{it}$$

Drugom varijacijom obuhvatio se promet tereta i ulaganje u istraživanje i razvoj kako bi se mogao ispitati značaj istraživanja i razvoja za rast gospodarstva.

Model 2:

$$\ln GDPpc_{it} = \beta_0 + \beta_1 lnGDPpc_{it-1} + \beta_2 lnFreight_{it} + \beta_3 RD_{it} + Control_{it} + \lambda_t + u_{it}$$

Treća varijacija obuhvaća promet tereta kao najvažniju stavku istraživanja i ljudski kapital za koji se prema endogenoj teoriji rasta tvrdi da ima veliki značaj za rast gospodarstva.

Model 3:

$$\ln GDPpc_{it} = \beta_0 + \beta_1 lnGDPpc_{it-1} + \beta_2 lnFreight_{it} + \beta_3 HC_{it} + Control_{it} + \lambda_t + u_{it}$$

Konačno, četvrta varijacija je model koji je postavljen na početku kojim se obuhvaćaju sve definirane varijable te kojim se želi ispitati ukupni utjecaj glavnih nezavisnih varijabli (promet tereta, ulaganje u istraživanje i razvoj i ljudski kapital) na rast gospodarstva.

Model 4:

$$\ln GDPpc_{it} = \beta_0 + \beta_1 lnGDPpc_{it-1} + \beta_2 lnFreight_{it} + \beta_3 RD_{it} + \beta_4 HC_{it} + Control_{it} + \lambda_t + u_{it}$$

Logaritamski oblici varijabli koriste se u regresijama kako bi se uzela u obzir mogućnost nelinearnog odnosa između ekonomskog rasta i eksplanatornih varijabli. Logaritamska transformacija također osigurava da su procijenjeni koeficijenti robusni prema mjernim jedinicama varijabli. To je rutinski postupak u poslovnoj i ekonomskoj literaturi, uključujući literaturu o pomorskoj ekonomiji (Cheung i Yip, 2011; Bottasso *et al.*, 2014; Shan *et al.*, 2014; Song i van Geenhuizen, 2014).

Kao što je u prethodnim poglavljima navedeno, model se testirao dinamičkom panel analizom, točnije Generaliziranom metodom momenata i njenim procjeniteljem u dva koraka. Kao što se iz navedenog modela može vidjeti, bruto domaći proizvod po glavi stanovnika iz prethodne godine uvršten je kao nezavisna varijabla budući da prošlogodišnje vrijednosti bruto domaćeg proizvoda svakako utječu na njegovu vrijednost u promatranoj godini. Uvođenjem lagirane vrijednosti zavisne varijable kao nove nezavisne varijable, mogao bi se javiti problem endogenosti varijabli te povratne kauzalnosti, stoga se nova lagirana varijabla uvodi kao instrument. Instrument je nova varijabla koja nije korelirana s greškom te utječe na zavisnu varijablu ali samo putem nezavisne varijable.

5.3.4. Rezultati empirijskog modela

Očekuje se da će promet tereta kao i ulaganje u istraživanje i razvoj te ljudski kapital pozitivno utjecati na gospodarski rast. Nadalje, očekivanja za kontrolne varijable su sljedeća: očekuje se da će nezaposlenost negativno utjecati na gospodarski rast, isto kao i populacija budući da se kao zavisna varijabla u model uvodi bruto domaći proizvod po glavi stanovnika, stoga ukoliko se populacija poveća, očekuje se pad bruto domaćeg proizvoda po glavi stanovnika. Za otvorenost ekonomije i ulaganje u prometnu infrastrukturu očekuje se pozitivan predznak kao i za bruto domaći proizvod po glavi stanovnika iz prethodne godine.

Testiranje modela provelo se u programskom paketu STATA. Rezultati modela prikazani su u sljedećoj tablici.

Tablica 10. Rezultati testiranja modela

	Model 1	**Model 2**	**Model 3**	**Model 4**
VARIABLES	*ln* GDPpc	*ln* GDPpc	*ln* GDPpc	*ln* GDPpc
L.*ln* GDPpc	0,967***	0,956***	0,961***	0,957***
	(0,00977)	(0,0128)	(0,0111)	(0,0124)
ln Freight	0,00545**	0,00526**	0,00539***	0,00541**
	(0,00221)	(0,00237)	(0,00201)	(0,00238)
RD		0,00624**		0,00203
		(0,00303)		(0,00383)
HC			0,000604**	0,000595**
			(0,000253)	(0,000282)
Unempl	-0,00212***	-0,00191***	-0,00196***	-0,00192***
	(0,000334)	(0,000361)	(0,000367)	(0,000380)
Open	0,000103**	0,000140***	0,000120**	0,000125***
	(4,69e-05)	(4,74e-05)	(4,74e-05)	(4,69e-05)
Pop	-0,000542**	-0,000510**	-0,000564**	-0,000618***
	(0,000226)	(0,000229)	(0,000227)	(0,000207)
Transport	-0,00147	-0,00530	-0,00395	-0,00552
	(0,00414)	(0,00404)	(0,00449)	(0,00454)
Time effects included	Yes	Yes	Yes	Yes
Constant	0	0,406***	0,366***	0,410***
	(0)	(0,130)	(0,110)	(0,121)
Observations	1 058	1 035	1 058	1 035
Number of regID	107	107	107	107
Hansen test (p-value)	1,000	1,000	1,000	1,000
AR (1) test (p-value)	0,000	0,000	0,000	0,000
AR (2) test (p-value)	0,736	0,761	0,751	0,780

Standard errors in parentheses

*** p<0.01, ** p<0.05, * p<0.1

Izvor: Izračun autorice

Prije interpretacije dobivenih rezultata, potrebno je obratiti pozornost na testove za autokorelaciju te validnost instrumenata koji su prikazani u donjem dijelu tablice. Arellano-Bond za serijsku korelaciju u prvim diferencijama reziduala odbacuje hipotezu o nepostojanju serijske korelacije prvog reda u svim varijacijama modela, dok istu hipotezu ne može odbaciti za više razine, što je poželjno. Navedeno omogućuje isključivanje prisutnosti rezidualne serijske korelacije pogreške. Nulta hipoteza Hansen testa je da su instrumenti valjani, odnosno da su instrumenti nekorelirani sa stohastičkom greškom modela što se potvrđuje s p-vrijednosti većom od 0,05.

Utjecaj prometa tereta na gospodarski rast ispituje se prvim modelom **(Model 1)** te se iz rezultata istraživanja može vidjeti kako navedeni utjecaj postoji. Procijenjeni koeficijent iznosi 0,00545 te je statistički značajan na razini od 5% što ukazuje da ukoliko se promet tereta poveća za 10%, regionalni bruto domaći proizvod po glavi stanovnika povećati će se u prosjeku za 0,0545%. Kontrolne varijable u modelu statistički su značajne i očekivanog predznaka, osim ulaganja u prometnu infrastrukturu koja je statistički neznačajna. Statistička neznačajnost se može objasniti malim varijacijama prometne infrastrukture unutar regija. Ukoliko bi se sagledavala agregatna razina gospodarstva, pretpostavka je da bi ulaganje u prometnu infrastrukturu bilo značajno budući da su velike razlike u prometnoj infrastrukturi na razini cjelokupnih gospodarstava, a varijacija unutar svake regije u svakoj godini je mala.

Iz perspektive endogene teorije rasta, stvaranje novih znanja i ideja smatra se ključnim pokretačem dugoročnog rasta, produktivnosti i prihoda. Stoga se u sljedećem modelu **(Model 2)** uvela varijabla koja reprezentira istraživanje i razvoj. No, kao i kod drugih reprezentirajućih varijabli (*eng. proxy*), tako i kod ulaganja u istraživanje i razvoj postoje ograničenja koja treba uzeti u obzir prilikom opisivanja rezultata istraživanja. Ulaganja u istraživanje i razvoj mogu imati heterogeni utjecaj u vremenskom smislu i smislu jačine utjecaja. Na primjer, velika ulaganja u nova područja mogu postati profitabilna tek nakon dugog vremenskog razdoblja. S druge strane ulaganja u postojeće proizvode i procese koja nisu nužno povezana s formalnim istraživanjem i razvojem, mogu proizvesti značajne ekonomske učinke (Crescenzi i Rodríguez-Pose, 2012:14). Navedeni učinci ograničavaju mogućnost potpune procjene utjecaja ulaganja u istraživanje i razvoj na rast gospodarstva. Rezultati testiranja Modela 2 ukazuju da ulaganje u istraživanje i razvoj ima pozitivan učinak na gospodarski rast uz 5% statističke značajnosti. Ukoliko se ulaganja u istraživanje i razvoj povećaju za 10 postotnih bodova, regionalni gospodarski rast u prosjeku će se povećati za 0,0624%. Promet tereta također se nalazi u modelu

kao najvažnija nezavisna varijabla istraživanja te je statistički značajan i utječe na rast gospodarstva. Kontrolne varijable su kao i u Modelu 1 statistički značajne i očekivanog predznaka, osim ulaganja u prometnu infrastrukturu.

Stvaranje novih ideja je prema endogenoj teoriji rasta temeljenoj na istraživanju i razvoju važan faktor koji dovodi do konstantnog rasta gospodarstva. Smatra se da gospodarstva koja stvaraju nove ideje neće dostići točku zasićenosti u kojoj gospodarski rast stagnira. Također se prema teoriji smatra da se stvaranjem novih ideja izbjegava konvergencija koja govori da slabija gospodarstva rastu brže jer kreću od minimuma te kopiraju ostale, a jača gospodarstva rastu sporije. Teorija se zalaže da do konvergencije ne mora uopće doći tj. bogate zemlje mogu vječno unaprjeđivati svoj životni standard, dok siromašne zemlje mogu zauvijek ostati slabije razvijene. Stvaranje novih znanja i ideja nije jedini izvor gospodarskog rasta vezan uz inovacije jer je istovremeno potrebna i apsorpcija novoproizvedenog znanja te prilagodba na nove ideje radi čega se razvila potreba za testiranjem utjecaja ljudskog kapitala na gospodarski rast.

Kvalitetno upravljanje morskim lukama koje dovodi do veće količine tereta u lukama i veće učinkovitosti morskih luka kao i ulaganje u istraživanje i razvoj pod snažnim su utjecajem kvalitetnog socio – ekonomskog okruženja. Reakcijske sposobnosti regije na nova ulaganja mogu se povezati s obrazovnim postignućima i produktivnim korištenjem ljudskih resursa. Uzimajući u obzir ograničenja regionalnih podataka, kao pokazatelj navedenih sposobnosti regije, koristili su se podaci o udjelu stanovništva sa završenim tercijarnim obrazovanjem u ukupnoj populaciji. **Modelom 3** testirao se utjecaj ljudskog kapitala na gospodarski rast te je utvrđen njegov utjecaj na razini od 5% statističke značajnosti. Procijenjeni koeficijent iznosi 0,000604 čime se dokazuje da ukoliko se ljudski kapital poveća za 10 postotnih bodova, regionalni bruto domaći proizvod po glavi stanovnika povećati će se u prosjeku za 0,00604%.

Ekonometrijska analiza potvrđuje povezanost navedenih varijabli, no utjecaj ljudskog kapitala na gospodarski rast je relativno malen. Jedan od razloga tome je priroda podataka jer je reprezentirajuća varijabla tercijarno odnosno visoko obrazovanje, dok bi bolji pokazatelj ljudskog kapitala bio Indeks ljudskog razvoja za koji ne postoje regionalni podaci. Nadalje, da bi stanovništvo došlo do tercijarnog tj. visokog obrazovanja potreban je dugi niz godina i mnogo sredstava stoga se utjecaj na gospodarski rast raspršuje. Također je potrebno uzeti u obzir da se radi o regionalnom utjecaju dok je agregatni utjecaj ljudskog kapitala na cjelokupno gospodarstvo zasigurno veći. Promet tereta također je jedna od nezavisnih varijabli Modela 3 te je testiranjem dokazana njegova statistička značajnost i postojanje utjecaja na bruto domaći

proizvod po glavi stanovnika. Kontrolne varijable su statistički značajne te očekivanog predznaka, osim ulaganja u prometnu infrastrukturu.

Modelom 4 obuhvatile su se sve nezavisne varijable istraživanja te rezultati ukazuju kao i u svim prethodnim modelima da promet tereta ima pozitivan utjecaj na regionalni gospodarski rast. Procijenjeni koeficijent prometa tereta u Modelu 4 iznosi 0,00541 te je statistički značajan na razini od 5%. Navedeni rezultat ukazuje da ukoliko se promet tereta poveća za 10%, regionalni bruto domaći proizvod po glavi stanovnika u prosjeku će se povećati za 0,0541%. Prema tome, promet tereta u morskim lukama ima pozitivan utjecaj na gospodarski rast regije domaćina što je dokazano u svim postavljenim modelima (Model 1, Model 2, Model 3 i Model 4), u skladu je s teoretskim pretpostavkama te ujedno i potvrđuje **pomoćnu hipotezu 1** *(kvantitativnim metodama moguće je analizirati kako efikasnost poslovanja luka utječe na rast regije).*

Ljudski kapital u Modelu 4 je statistički značajan na razini pouzdanosti od 5% te njegov procijenjeni koeficijent iznosi 0,000595 što ukazuje na sljedeće: ukoliko se ljudski kapital poveća za 10 postotnih bodova, regionalni bruto domaći proizvod u prosjeku će se povećati za 0,00595%. Navedeno potvrđuje teorijske pretpostavke endogene teorije rasta koja se bazira na pretpostavci da je ljudski kapital jedan od pokretača gospodarskog rasta, odnosno da ljudi imaju beskrajni kapacitet rekonfiguriranja fizičkih objekata te mogu svojim znanjem i idejama pronaći njihove nove načine upotrebe što vodi do povećanja profita i posljedično do gospodarskog rasta. Teorija smatra da ideje nisu podložne zakonu opadajućih prinosa kao što je to slučaj kod npr. infrastrukture, premda i jedna i druga strana iziskuju velika novčana ulaganja. Kvalitetan ljudski kapital koji posluje u lukama također može utjecati na poboljšanje poslovanja luka te unaprijediti poslovne procese i primijeniti svoja znanja o novih tehnologijama. Sve navedeno kao i zaključci iz Modela 3 potvrđuju **pomoćnu hipotezu 2** *(postoji pozitivna veza između ljudskog kapitala i regionalnog gospodarskog rasta te poslovanja luka).*

Kako bi se mogla testirati **pomoćna hipoteza 3** *(ulaganje u ljudski kapital i istraživanje i razvoj u većoj mjeri utječu na rast regionalnog gospodarstva nego ulaganje u prometnu infrastrukturu)* potrebno je sagledati varijable RD (ulaganje u istraživanje i razvoj) te Transport (ulaganje u prometnu infrastrukturu). Modelom 2 dokazan je pozitivan utjecaj ulaganja u istraživanje i razvoj na gospodarski rast, no u Modelu 4 varijabla RD je prema ekonometrijskoj analizi statistički neznačajna. Ulaganje u prometnu infrastrukturu također nije statistički

značajna varijabla u svim promatranim modelima. Dobiveni rezultati ne uspijevaju identificirati čvrste dokaze o odnosu između prometne infrastrukture i gospodarskog rasta na regionalnoj razini. Jedan od načina tumačenja tako dobivenih rezultata može biti u činjenici da je prisutnost dobre razine infrastrukture rezultat uspješnog gospodarstva, a ne njegov uzrok. Odnosno dobra prometna infrastruktura može biti čimbenik koji prati proces regionalnog rasta, a nije njegov pokretač. U obzir također treba uzeti i vremenski odmak nakon kojega ulaganja u prometnu infrastrukturu počinju imati utjecaj na rast gospodarstva. Stoga se pomoćna hipoteza 3 može djelomično potvrditi, odnosno dokazano je kako ljudski kapital ima pozitivan utjecaj na rast regionalnog gospodarstva, dok ulaganje u istraživanje i razvoj ima djelomični utjecaj na gospodarski rast. Ujedno se za ulaganje u prometnu infrastrukturu nisu identificirali dokazi o utjecaju na gospodarski rast.

Pomoćna hipoteza 4 *(trgovinska otvorenost pozitivno utječe na regionalni gospodarski rast lučkih regija)* nalaže sagledavanje varijable modela Open (trgovinska otvorenost). Varijabla je u Modelu 4 značajna na razini pouzdanosti od 1% te joj procijenjeni koeficijent iznosi 0,000125 što ukazuje da povećanje trgovinske otvorenosti od 10 postotnih bodova dovodi do povećanja regionalnog bruto domaćeg proizvoda po glavi stanovnika u prosjeku za 0,00125%, čime se potvrđuje postavljena pomoćna hipoteza 4. Trgovinska otvorenost važan je faktor za poslovanje morskih luka budući da se veliki dio međunarodne trgovine odvija u morskim lukama.

Ostale kontrolne varijable u Modelu 4 su značajne i odgovarajućeg predznaka. Nezaposlenost (Unempl) je značajna na razini pouzdanosti od 1% te se može interpretirati na sljedeći način: ukoliko se nezaposlenost poveća za 10 postotnih bodova, regionalni bruto domaći proizvod po glavi stanovnika će se smanjiti u prosjeku za 0,0192%. Nadalje, kontrolna varijabla populacija (Pop) je također značajna na razini od 1% te njena interpretacija glasi: ukoliko se populacija poveća za 10 postotnih bodova, regionalni bruto domaći proizvod po glavi stanovnika u prosjeku će se smanjiti za 0,00618% što je logično jer se ovdje sagledava BDP per capita koji u nazivniku ima broj stanovnika gospodarstva. Bruto domaći proizvod po glavi stanovnika iz prethodne godine također je statistički značajan u ovome modelu ali i u svim promatranim modelima što je očekivano jer BDP per capita iz prethodne godine uvelike utječe na BDP per capita u trenutnoj godini.

Navedenim modelom i njegovim rezultatima potvrdila se **glavna hipoteza** istraživanja koja glasi: *Znanstveno utemeljenim spoznajama o čimbenicima koji utječu na regionalni gospodarski rast moguće je predložiti novi model procjene utjecaja morskih luka na gospodarstvo pripadajuće regije te omogućiti bolje razumijevanje značaja morskih luka u cjelokupnom gospodarstvu.*

5.4. Prijedlog smjernica za primjenu modela u donošenju odluka i preporuke za budući rad

Rezultati testiranja pokazuju kako poslovanje morskih luka ima pozitivan utjecaj na gospodarski rast regija te kako je važno obratiti pozornost i na ostale pokretače regionalnog gospodarskog rasta kao što su ljudski kapital te ulaganje u istraživanje i razvoj. Nadalje, rezultati impliciraju na potrebu konstantnog unaprjeđenja poslovanja morskih luka te implementaciju novih znanja i tehnologija u poslovanju. Morske luke koje ulažu u nove tehnologije i sofisticirane sustave za obradu podataka većinom su uspješne u poslovanju. Također, obrazovano stanovništvo pridonosi uspješnosti regije ali i morskih luka budući da nove tehnologije zahtijevaju višu razinu obrazovanja zbog naprednijeg sustava rukovanja.

Kako bi regije bile uspješne i imale što veći rast gospodarstva, moraju istovremeno stvoriti preduvjete za uspješno napredovanje. Prvenstveno, moraju imati obrazovano stanovništvo, odnosno kvalitetan ljudski kapital koji će biti u mogućnosti inovirati te implementirati inovacije u poslovanje. Nadalje, potrebna je niska razina nezaposlenosti budući da su zaposleni ljudi skloniji promjenama i implementaciji novih tehnoloških rješenja nego nezaposleni. Također je potrebno da regije budu orijentirane na sektor industrije i sektor proizvodnje jer su takve regije sklonije poslovnom inoviranju u odnosu na regije koje se bave poljoprivredom. Lučke regije spadaju u navedeni segment industrije te se od njih očekuje da implementiraju nova tehnološka otkrića s obzirom da u svome sastavu imaju morske luke kojima je prilagođavanje novim trendovima jedan od preduvjeta očuvanja konkurentnosti.

Priroda poslovanja morskih luka dinamična je te je sklona promjenama i praćenju novih trendova što je usko povezano s ulaganjem u inovacije i nove tehnologije. Trendovi u morskim lukama većinom idu u smjeru digitalizacije i mehanizacije luka te se sve češće na pomorskom tržištu rada traže visokoobrazovne osobe koje imaju znanja o novim tehnologijama i načinima komunikacije (primjena oblaka u poslovanju, *blockchain* tehnologije, dronova, 3D pisača, 5G mreže). Tehnologija je proces koji ne završava u jednom ciklusu već čini mrežu koju je

potrebno konstantno nadograđivati. Istovremeno, razvoj nove tehnologije i njena primjena doprinose učinkovitom prometnom sustavu što je važno za razvoj regionalne gospodarske mobilnosti. Predviđanja su da će razvojne tendencije morskih luka u budućnosti ići u smjeru potpune digitalizacije gdje će se gotovo svi lučki poslovi obavljati primjenom informacijsko komunikacijske tehnologije. Stoga se kao preduvjet za očuvanje konkurentnosti i razvoj daljnjeg pozitivnog poslovnog trenda morskih luka pretpostavljaju inovacijske sposobnosti morskih luka i pripadajućih regija te kvalitetan ljudski kapital.

Testiranjem modela se utjecaj ulaganja u prometnu infrastrukturu na regionalno gospodarstvo nije uspješno identificirao što dovodi do potrebe razmatranja određenih politika Europske unije koje velikim dijelom ulažu sredstva u prometnu infrastrukturu od kojih je najvažnija Transeuropska mreža prometnica (TEN-T). Prema rezultatima, regionalni gospodarski rast lučkih regija povezuje se s kombinacijom ulaganja u istraživanje i razvoj, ljudskog kapitala te poslovanja morskih luka. No, elementi kao što su ulaganje u istraživanje i razvoj i ljudski kapital često su podcijenjeni u odnosu na ulaganja u prometnu infrastrukturu ne samo u Europskoj uniji nego i u većini svijeta. Smjernice za preusmjeravanje sredstava mogle bi ići u korist ulaganja u razvitak ljudskog kapitala te ulaganja u istraživanje i razvoj budući da su se oni pokazali kao značajni čimbenici gospodarskog rasta koji bi u konačnici mogli dovesti do boljeg povrata javnih sredstava.

Prostor za nova istraživanja postoji, ne samo u vidu testiranja postavljenog modela na novim setovima podataka, već i u vidu testiranja neuključenih varijabli koje djeluju na gospodarski rast a istovremeno poboljšavaju poslovanje morskih luka. Postavljeni model ima svojevrsna ograničenja gdje su temeljno ograničenje dostupni podaci. Općenito, podaci na agregatnoj razini raznolikiji su te potpuniji dok su podaci na regionalnoj razini ograničeni. Ograničenja modela potencijalno su sadržana i unutar određenih varijabli pomoću kojih je formiran model. Tako se, primjerice, razvoj novih ideja, odnosno inovacija, može prikazati uvođenjem različite reprezentirajuće varijable kao što je broj patenata u regiji ili izračun vlastitog inovacijskog indeksa, ukoliko to dostupnost podataka omogućava. Time bi se mogli donijeti novi zaključci o važnosti razvoja novih ideja i njihovom utjecaju na regionalni rast. Ljudski kapital se također može definirati kroz druge varijable kao što su Indeks ljudskog razvoja za koji trenutno ne postoje dostupni podaci za regionalnu razinu. Nadalje, izvjesno je da postoje i druge varijable koje je moguće testirati i interpretirati u kontekstu mjerenja utjecaja morskih luka na regionalna gospodarstva u okviru endogene teorije rasta.

Model je moguće testirati u kontekstu i na uzorku drugih gospodarskih sustava odnosno na drugim setovima podataka koji nisu isključivo vezani uz Europsku uniju čime bi se dobio uvid o važnosti morskih luka na različitim područjima. Rezultate testiranja drugih geografskih područja može se komparirati s rezultatima dobivenim u ovoj doktorskoj disertaciji te donijeti zaključke o utjecajima morskih luka u različitim gospodarskim sustavima. U nadogradnji predloženog modela moguće je ispitati postoje li određene dodatne varijable koje bi bilo moguće uključiti u model.

Preporuke za budući rad te daljnje istraživanje također mogu ići u smjeru grupiranja lučkih regija prema makroekonomskim pokazateljima i usporedbe utjecaja morskih luka na razvijene regije i one manje razvijene te analize njihovih razlika. Grupiranje podataka može se provesti i prema načelu starijih i novijih zemalja članica Europske unije čiji rezultati mogu dati uvid u stanje razvijenosti morskih luka i regionalnih gospodarstva. Također se podaci mogu grupirati prema geografskim pozicijama regija gdje bi jednu skupinu podataka činile regije koje imaju izlaz na Sredozemno more, a drugu skupinu podataka regije koje imaju izlaz na Atlantski ocean čime bi se došlo do detaljnijih podataka o utjecaju geografskog položaja na uspješnost poslovanja morskih luka i uspješnost i razvijenost samih lučkih regija.

6. ZAKLJUČAK

Morske luke važan su čimbenik regionalnih gospodarstava te svojim poslovanjem stvaraju pozitivne efekte na okolinu. One stvaraju izravan utjecaj bruto domaćem proizvodu te proizvode nova radna mjesta. Efekti utjecaja nisu ograničeni samo na usko područje oko morske luke već imaju utjecaja i na šire područje te se iz toga razloga učinci morskih luka sagledavaju na regionalnoj razini. No, morske luke nisu jedine koje utječu na gospodarski rast, već postoje i ostali pokretači regionalnog rasta, a u okvirima endogene teorije rasta temeljene na istraživanju i razvoju, najvažniji su ulaganje u istraživanje i razvoj i ljuski kapital.

Preteče endogene teorije rasta bile su teorije klasičnih i neoklasičnih ekonomista. Prvi klasični model koji se bavio gospodarskim rastom bio je Harrod-Domarov model koji je tvrdio da tržište ne može samostalno osigurati gospodarski rast te da se gospodarstvo neprestano nalazi izvan svoje putanje rasta i da ga je potrebno državnim intervencijama vraćati na pravi put. Ostali klasični ekonomisti kao što su Smith, Ricardo i Malthus implicitno su u svojim teorijama povezivali gospodarski rast s inovacijama, no tehnološki napredak se u njihovim teorijama nije uspio dovoljno detaljno objasniti te je pretpostavljeno kako je on egzogen, odnosno da se na njega ne može djelovati vanjskim silama. Robert Solow začetnik je neoklasičnog modela rasta gdje je skrenuo pozornost na tri važna elementa: tehnologiju, kapital i rast. Neoklasični ekonomisti koji su slijedili Solowa zastupaju mišljenje da su povećanje ponude radne snage te veća produktivnost rada i kapitala generatori povećanja stope gospodarskog rasta. No, kao i u klasičnoj teoriji rasta i neoklasična teorija smatra da je tehnologija egzogena te razlike u stopama rasta između zemalja pripisuje upravo egzogenoj tehnologiji.

Endogena teorija rasta započela je idejom Paula Romera te se također vezuje za Lucasa i Scotta. Njeni modeli po prvi puta zagovaraju tezu da je gospodarski rast rezultat djelovanja endogenih sila koje se nalaze unutar ekonomskog sustava. Također, bitna razlika u odnosu na klasične i neoklasične modele jest tehnološki napredak koji se smatra endogenim, odnosno smatra se da je tehnološki napredak rezultat ljudskog rada. Radi toga poduzeća su u mogućnosti stvarati monopolsku rentu i imati monopolsku moć. Ideje su prema Romeru glavni pokretači ekonomskog rasta jer vode prema većem nacionalnom proizvodu, većim investicijama i većoj akumulaciji kapitala, kako fizičkog tako i ljudskog.

Razvijanje novih ideja ili novog pristupa radu može se definirati kao proces inoviranja. Inovacije proizvoda stvaraju u potpunosti nove proizvode koji zadovoljavaju novonastale

potrebe kupaca, dok inovacije procesa poboljšavaju proizvodne procese što u konačnici stvara niže troškove, veću efikasnost i produktivnost proizvodnje. Resursi u procesu inovacija dobivaju novu vrijednost a ona postaje temeljem konkurentnosti čime se posredno djeluje na gospodarski rast. Inovacije se mogu vezati za velika tehnološka otkrića, ali također mogu biti i niz malih otkrića i poboljšanja, kao što je to definirao i sam Romer, koji kumulativno mogu dati značajniji rezultat od većih otkrića. Nadalje, bitna karakteristika tehnološkog znanja je da se ono ne iscrpljuje već se akumulira jer se novo otkriće može nadograđivati na prethodno.

Inovacije također mogu uzrokovati i prelijevanja iz područja gdje su nastala na ostala područja, no u tom slučaju javlja se dilema prilikom razvoja novih ideja. Prema endogenoj teoriji rasta, potrebno je širiti i dijeliti nove ideje i inovacije kako bi se zemlje u razvoju mogle razvijati, no sam razvoj novih ideja skup je i dugotrajan proces. Razvoj prve ideje iziskuje velika financijska sredstva i ljudske resurse, dok se njeno kopiranje i korištenje može vrlo jednostavno provesti uz niske troškove ili čak besplatno što se naziva fenomenom „slobodnih jahača“. Ideje se mogu patentirati što omogućuje inovatoru monopolsku rentu na neko vrijeme, no u tom slučaju se ne utječe na gospodarski rast ostalih koji od nove ideje mogu profitirati. Jedno od rješenja jesu subvencije sveučilištima i drugim institucijama za istraživanje i razvoj kojima se potiče na inoviranje te nakon nastale inovacije na njeno slobodno dijeljenje.

Inovacije su važan preduvjet gospodarskog rasta, no nemaju sve regije predispozicije za mogućnost inoviranja. Obrazovna dostignuća populacije važan su faktor koji utječe na proces inoviranja i njegovu implementaciju jer su ljudi s većim obrazovnim dostignućima skloniji inoviranju od onih s nižim obrazovnim dostignućima. Visoka razina zaposlenosti, odnosno niska razina nezaposlenosti također je jedan od preduvjeta koje regija mora ispuniti kako bi bila uspješna u inovacijskom procesu. Nadalje, regije koje se pretežno bave poljoprivrednim djelatnostima biti će manje sklone inoviranju od onih koje se bave uslužnim i proizvodnim djelatnostima. U ove druge spadaju i lučke regije budući da je za adekvatno poslovanje morskih luka potrebno imati kvalitetnu tehnologiju.

Europska unija potiče svoje zemlje članice na inoviranje te je razvila posebnu strategiju nazvanu Inovacijska unija. Cilj strategije je poticati zemlje članice da do 2020. godine ulažu 3% svoga bruto domaćeg proizvoda u istraživanje i razvoj, od čega se 1% očekuje da će doći iz javnog sektora, a 2% iz privatnog sektora. No, Europska unija ne može u potpunosti primorati članice na ulaganje u istraživanje i razvoj jer su ulaganja većinom vezana uz nacionalne politike pojedinih zemalja. Što se tiče morskih luka, Europska komisija je u sklopu programa Obzor

2020 pokrenula inicijativu pod nazivom „Luka budućnosti“ čiji je cilj poticanje inovacija u morskim lukama.

Analizom statističkih podataka o razinama ulaganja u istraživanje i razvoj država članica Europske unije došlo se do zaključka kako Švedska, Austrija, Danska i Njemačka imaju najveći postotak ulaganja u istraživanje i razvoj. Najmanji postotak ulaganja imaju Rumunjska, Malta, Latvija i Cipar. Ukoliko se promatra povećanje ulaganja u istraživanje i razvoj u desetogodišnjem razdoblju, Slovačka se nalazi na prvom mjestu. Ljudski resursi u znanosti i tehnologiji povezani su s inovacijama te se analizom statističkih podataka došlo do zaključka kako je najviše ljudskih resursa u znanosti i tehnologiji zaposleno u Švedskoj, Luksemburgu i Ujedinjenom Kraljevstvu. S druge strane, najmanje ih je zaposleno u Rumunjskoj, Italiji te Portugalu dok se najveće povećanje u desetogodišnjem razdoblju desilo u Portugalu što ukazuje da Portugal radi na povećanju zaposlenosti u znanstvenom i tehnološkom sektoru. Povezivanjem podataka o ulaganju u istraživanje i razvoj i zaposlenosti ljudskih resursa u znanosti i tehnologiji zaključilo se kako zemlje koje najviše ulažu u istraživanje i razvoj istovremeno imaju i visok postotak zaposlenosti u znanstvenom i tehnološkom sektoru.

Obrazovna dostignuća važna su za razvoj i implementaciju inovacija te za poticanje gospodarskog rasta. Teorijske analize potvrđuju komplementaran odnos između ljudskog kapitala i procesa istraživanja i razvoja. Ljudski kapital može se povećavati tokom čitavog životnog vijeka primjenom cjeloživotnog obrazovanja, no specifičnost je što se ljudski kapital ne može kupiti već je to proces u kojemu ljudi moraju surađivati učenjem, čime mu se pridaje velika vrijednost. Razvijenije regije imaju potrebu za obrazovanijim stanovništvom stoga je čest slučaj pojave odljeva mozgova iz manje razvijenih regija u razvijenije regije. Odljev mozgova negativan je za regije emigracije ali pozitivan za regije imigracije koji u kratkom roku dobivaju visokoobrazovano stanovništvo.

Obrazovanje stanovništva i povećanje ljudskog kapitala na individualnoj razini dovode do veće plaće i boljeg životnog standarda, dok na makroekonomskoj razini doprinose gospodarskom rastu. U Europskoj uniji najveći udio ljudi s visokim obrazovanjem imaju Irska, Finska i Ujedinjeno Kraljevstvo, dok najmanji udio imaju Rumunjska, Hrvatska i Slovačka. Pozitivna je činjenica što su sve zemlje članice tokom promatranog desetogodišnjeg razdoblja imale povećanje udjela visokoobrazovanih ljudi u ukupnoj populaciji. Analizirali su se Indeksi ljudskog razvoja zemalja Europske unije te se Irska smjestila na vrh ljestvice, dok se Rumunjska pozicionirala na dnu. U segmentima ulaganja u istraživanje i razvoj i ljudskog kapitala, zemlje

članice Europske unije imaju različite rezultate, no uočen je trend da ukoliko se jedna zemlja nalazi visoko na ljestvici po jednom pokazatelju, većinom je visoko pozicionirana i po ostalim pokazateljima i obrnuto.

Morske luke objekti su koji potpomažu u uspostavljanju ravnoteže između ponude i potražnje jer povezuju proizvode koji se proizvode na jednom kraju svijeta s potrošačima koji se nalaze na drugom kraju. Prema vrstama luke mogu biti teretne, putničke ili kombinirane, no najzastupljenije su teretne luke koje u najvećoj mjeri pridonose regionalnom gospodarskom rastu stvaranjem vrijednosti i novim radnim mjestima. Razlozi za poslovanjem morskih luka mogu se svrstati u tri glavne skupine: prvi razlog je spajanje različitih tipova prijevoza, drugi je prostorno rasprostranjena prometna potražnja, a treći privremeno skladištenje tereta. Subjekti koji posluju u luci i u njenoj okolini su lučki korisnici i pružatelji usluga. Sudionike u lučkom poslovanju čine lučka-prekrcajna poduzeća, brodari, brodski agenti, špediteri, kontrolne organizacije, cestovni i željeznički prijevoznici, tijela uprave te ostali sudionici koji svojim poslovanjem pridonose stvaranju vrijednosti te razvoju gospodarstva.

Poslovanje u morskim lukama kao i svako drugo poslovanje smatra se učinkovitim ukoliko se uz minimalne utroške resursa ostvari maksimalan poslovni rezultat. Nadalje, luka se smatra učinkovitom kada se ostvaruje maksimalan promet tereta ili putnika s obzirom na dostupne razine lučkih resursa. Promet tereta može obuhvatiti tone tereta ili kontejnerski promet dok lučki resursi obuhvaćaju ljudski rad, dizalice, vozila, skladišta, zgrade i prometnice. Mjerenje učinkovitosti luke može se provesti na više načina, no analiza prometa tereta je najčešći i najsveobuhvatniji način jer omogućuje usporedbu različitih luka i njihovih konkurentskih pozicija.

Europske luke važne su za europsko tržište jer više od polovice robe koja ulazi ili izlazi iz Europe putuje pomorskim putem. Uspostavljanje europskog pomorskog tržišta koje uključuje ekonomsku i političku integraciju imalo je pozitivan efekt na poslovanje morskih luka te povećanje njihove suradnje. No, i tehnološki napredak, globalizacija, logistika i kontejnerizacija pridonijele su poboljšanju suradnje morskih luka Europske unije. Europska komisija razvila je zajedničku prometnu politiku kojom nastoji unaprijediti i razviti europsku infrastrukturu koja uključuje morske luke. Izgradnja transeuropske mreže prometnica jedan je od ciljeva zajedničke prometne politike. Očekuje se da će integrirana mreža prometnica poboljšati suradnju između različitih luka te također povezati morske luke s drugim načinima prijevoza kako bi se omogućio brži i adekvatniji transport tereta. Nadalje, očekuje se

pojednostavljenje lučkih procesa s ciljem bržeg stvaranja nove vrijednosti. Europska unija u velikoj mjeri ulaže sredstva u infrastrukturu te se postavlja pitanje njene dugoročne isplativosti.

Većina korisnika luka su međunarodna poduzeća čime luke Europske unije djeluju na proces globalizacije. Više od dvije trećine pomorskog tereta koji se prevozio u 20 najvećih luka Europske unije stiglo je iz zemalja koje nisu članice Europske unije ili je bilo namijenjeno za njihova tržišta. Analizom statističkih podataka o prometu tereta u morskim lukama Europske unije, došlo se do zaključka kako su zemlje s najvećim prometom tereta Nizozemska, Španjolska te Ujedinjeno Kraljevstvo. Najmanje prometa tereta imale su Malta, Hrvatska i Slovenija. Izračunati verižni indeksi ukazuju da je najveće povećanje prometa tereta u 2017. godini u odnosu na 2008. godinu imala Poljska (59,88%), dok je najveće smanjenje prometa tereta imala Hrvatska (28,83%).

Analizom prometa tereta u regijama Europske unije u 2016. godini došlo se do zaključka kako nizozemska regija Zuid-Holland ima najveći promet tereta što je u skladu s podacima na razini cjelokupnih zemalja gdje Nizozemska ostvaruje najveći promet. Također se u navedenoj regiji nalazi i luka Rotterdam koja općenito ostvaruje najveći promet tereta u odnosu na ostale zemlje Europske unije. Njemačke regije Hessen, Darmstadt, Münster i Arnsberg ostvaruju najmanji promet tereta. Ukoliko se sagledaju pojedinačne luke Europske unije, nizozemska luka Rotterdam prednjači po prometu tereta s oko 11% ukupnog prometa tereta u Europskoj uniji. Prate je belgijska luka Antwerpen, njemačka luka Hamburg te nizozemska luka Amsterdam. Luke koje su najviše okrenute svjetskim tržištima, odnosno tržištima izvan Europske unije su luke London i Trst, dok su Constanta, Bremerhaven i Valencia luke u koje pristiže više od 50% tereta koji je namijenjen za tržišta unutar Europske unije.

Suvremeni trendovi u poslovanju morskih luka raznoliki su te ih je potrebno pratiti kako bi luke ostale konkurentne na tržištu. Neusklađenost između ponude i potražnje potiče razvoj sve većih kontejnerskih brodova kako bi u njih stalo što više tereta. Istovremeno, i luke se moraju prilagođavati novonastalom trendu te modificirati svoje prihvatne kapacitete za prihvaćanje velikih plovila. Industrije koje se bave proizvodnjom raznih proizvoda prilagođavaju se navedenom trendu kontejnerizacije te proizvode svoje proizvode u oblicima koji su pogodni za prijevoz u kontejnerima. Briga za okoliš i održivi razvoj, trend je koji se javlja u mnogim poslovnim procesima pa tako i u poslovanju morskih luka. Ulaže se u nove tehnologije koje smanjuju zagađenje okoliša, a njihovom primjenom luke istovremeno stvaraju pozitivnu sliku o svome poslovanju.

Budući trendovi koji se predviđaju u poslovanju morskih luka su primjena 5G mreže koja će omogućiti implementaciju potpune automatizacije i umjetne inteligencije. Predviđa se korištenje 5G mreže i u svakodnevnim operacijama luka gdje će omogućiti prijenos podataka između luka i logističkih poduzeća. Nadalje, omogućiti će primjenu koncepta Interneta stvari *(eng. Internet of Things – IoT)* koji može biti postavljen na lučku opremu te putem senzora prenositi podatke čime se omogućava bolje planiranje prometa i efikasnije poslovanje. Uz Internet stvari, postoji i koncept Interneta vozila *(eng. Internet of Vehicles – IoV)* gdje se senzori postavljaju na prijevozna sredstva povezana s lučkim poslovanjem i čime ih se može pratiti, planirati optimalne prijevozne rute i promet u luci te očekivani trošak. Autonomni brodovi trend su za koji se očekuje daljnje povećanje primjene kao i zapošljavanje sve većeg broja visokoobrazovanih osoba, posebice iz STEM područja. Javlja se potreba za suradnjom između luka i sveučilišta kako bi se lukama omogućio kadar koji im je potreban za poslovanje.

Razvojne mogućnosti poslovanja morskih luka mogu ići u više smjerova te su većinom usmjerene na već postojeća tržišta, povećanje korištenje ICT tehnologije u poslovanju te stvaranje unutarnjih plovnih puteva. Sinkromodalni prijevoz kod kojeg se paralelno koriste različiti načini prijevoza i rukovanja teretom na terminalima, ima veliku mogućnost napretka i primjene u budućnosti. Različiti načini prijevoza kao što su pomorski, cestovni i željeznički, u sinkromodalnom prijevozu trebaju surađivati te djelovati na koordinirani način čime se može postići veća brzina prijevoza tereta i manji troškovi čekanja i skladištenja.

Razvojne mogućnosti luka također mogu ići u smjeru primjene oblaka *(eng. cloud)* u poslovanju čime bi se omogućila veća povezanost luka i pripadajućih terminala. Tehnologija oblaka omogućila bi dijeljenje informacija u stvarnom vremenu te prikupljanje i obradu korisnih podataka. Nadalje, *blockchain* tehnologija mogla bi se sve više koristiti u poslovanju zbog velikog broja sudionika uključenih u poslovanje morskih luka. Predviđa se da bi se *blockchain* tehnologija mogla koristiti za pohranu i prijenos dokumentacije o teretu, za vidljivost informacija o procesima, za poboljšanje trgovinskog financiranja koje bi smanjilo vrijeme potrebno za komercijalna odobrenja te za automatiziranje operacija koristeći Internet stvari. Korištenje dronova u poslovanju morskih luka u segmentima kontrole emisije plinova već je zastupljeno u nekim lukama te se očekuje njegovo daljnje širenje. Dronovi omogućuju lakši i brži pristup brodovima te relativno brzu kontrolu. Također se mogu koristiti i u procesu logistike gdje se mogu obavljati manje logističke operacije isporuke paketa i za upravljanje skladištem.

Luka Rotterdam dobar je primjer implementacije inovacija i suvremene tehnologije u poslovanju. U luci se nalaze neka od najvećih međunarodnih poduzeća koja imaju izrazito visoke zahtjeve i stoga često vrše pritisak na luku Rotterdam za povećanjem izvrsnosti te primjenom novih tehnoloških rješenja. Određeni dijelovi luke Rotterdam u potpunosti su digitalizirani te fizičke osobe dizalicama i ostalom opremom upravljaju iz svojih ureda. Luka je u potpunosti usmjerena na digitalizaciju te potiče i ostale poslovne suradnike na isto. Prijevoz tereta u luci može se pratiti na Internetu što luku čini transparentnom u poslovanju. Terminali su izrazito dobro povezani cestom i željeznicom stoga omogućuju brzi prijevoz tereta i minimiziraju gubitka vremena. Sve navedeno rezultira visokim poslovnim rezultatom luke Rotterdam koji posljedično pozitivno djeluje na regionalno gospodarstvo.

Konkurentski položaj morske luke ogleda se u količini tereta koju morska luka prevozi, dok istovremeno morska luka stvara i konkurentsku prednost za regiju u kojoj se nalazi. Najbolji pokazatelji regionalne konkurentske prednosti nastale zbog postojanja morske luke jesu zaposlenost i direktna i indirektna dodana vrijednost. Porter je razvio odrednice međunarodne konkurentnosti koje se mogu primijeniti i na lučke regije. Ljudski resursi, infrastruktura kao što su sama luka, vezovi i prometnice, kapitalni resursi kao što su dizalice i mehanizacija te informacijske i komunikacijske tehnologije. mogu se smatrati faktorima proizvodnje u poslovanju morskih luka. Potražnja je u sektoru pomorstva usmjerena na međunarodna tržišta stoga se tržišna ravnoteža ostvaruje uvozom i izvozom različitih internacionalnih proizvoda. Pritisak je na morske luke da posao obave u što kraćem vremenu sa što manje troška čime se luke potiče na uvođenje novih tehnologija i inovacije. Država također može utjecati na odrednice međunarodne konkurentnosti uvođenjem politika, propisa, odlukama o ulaganju i slično te time poticati ili spriječiti razvoj regionalne konkurentnosti.

Velika razina konkurencije među morskim lukama često je prisutna čemu doprinosi mobilnost tereta i slobodan odabir luke. Poduzeća imaju vrlo malu lojalnost prema morskim lukama stoga lako prebacuju teret iz jedne luke u drugu čime se stvara visoka cjenovna elastičnost potražnje za uslugama morskih luka. S druge strane, luke mogu razviti suradnju s ostalim morskim lukama čime doprinose konkurentskom položaju vlastite regije. Ukoliko je luka bolje povezana s ostalim lukama, teže ju je zamijeniti za neku drugu luku. Luka povezivanjem može omogućiti pristup inovacijama iz nekog drugog područja ili korištenje tuđih ideja i znanja što pospješuje njen konkurentski položaj ali i konkurentski položaj pripadajuće regije.

Porezna konkurencija poseban je vid konkurencije koji se javlja kod poslovanja morskih luka. Pomorska država ili pomorska regija uvođenjem poreza mogu pozitivno ili negativno djelovati na poslovanje morskih luka. Značajke pomorske industrije jedinstvene su te omogućuju primjenu povoljnije porezne politike u odnosu na ostale industrije. Već prije spomenuto lako prebacivanje poslovanja iz jedne morske luke u drugu ide u prilog nižim porezima, odnosno korisnici će radije poslovati na području gdje su porezi niži. Radi toga zemlje uvode niz potpora za podršku pomorskoj industriji kao što je poseban sustav poreza na tonažu ili smanjene stope poreza na dohodak za pomorce, kako bi privukle pomorsko poslovanje.

Pomorsko tržište u prošlosti su karakterizirali niskokvalificirani poslovi koji su većinom tražili manualne radnike za prekrcaj tereta. Pojavom digitalizacije prekrcaj sredstava se automatizirao i mehanizirao te predstavlja tek mali dio lučkog zapošljavanja. U luci Rotterdam, primjerice, udio zaposlenih u prekrcaju i skladištenju iznosi tek 2% od ukupnog zapošljavanja. Na pomorskom tržištu sve je veća potražnja za visokoobrazovanim radnicima koji znaju rukovati novim tehnologijama i informacijsko komunikacijskim procesima. Navedeno implicira povećanje produktivnosti ali i smanjenje zaposlenosti na određenim radnim mjestima. No, kao i u svim sektorima, tako i u pomorskom sektoru, određena radna mjesta tokom godina zastarijevaju te se javljaju nova radna mjesta koja zahtijevaju povećane vještine rada i znatnu razinu ljudskog kapitala.

Globalizacija trgovine donijela je brojne koristi za poslovanje morskih luka. Budući da resursi i finalna dobra nisu uvijek na istim mjestima gdje se proizvode i troše, potrebne su prijevozne usluge, gdje je morsko brodarstvo velikim dijelom zastupljeno. Prijevoz tereta morem najjeftiniji je vid prijevoza koji može istovremeno primiti velike količine stoga je vrlo često korišten. Padom trgovinskih barijera proizvodnja se često selila u mjesta s jeftinijom radnom snagom te se javio fenomen *outsourcinga*. Lanci opskrbe zbog svega navedenoga imaju međunarodne karakteristike jer se nerijetko događa da se proizvodnja odvija na jednome kontinentu, a dorada i potrošnja na drugima. Lučka infrastruktura bitan je preduvjet za adekvatno poslovanje morskih luka, no ukoliko se sagledava utjecaj na regionalno gospodarstvo potrebno je u obzir uzeti i ostale pokretače gospodarskog rasta osim same infrastrukture. Europska unija stavlja veliki naglasak na ulaganje u prometnu infrastrukturu dok su ostali čimbenici djelomice zanemareni.

Uz brojne navedene pozitivne učinke poslovanja morskih luka, javljaju se i određeni negativni učinci. Morske luke svojim poslovanjem stvaraju negativne eksternalije jer vizualno uništavaju izgled lokacije, a istovremeno generiraju i veliku količinu cestovnog prometa koji stvara zagušenja u okolnim područjima. Česta negativna eksternalija je i buka u blizini morskih luka te narušen vizualni izgled okoline koji stvaraju skladišta. Zbog toga cijene nekretnina stanovnika okolnih područja mogu gubiti na vrijednosti te se oni sami mogu seliti dalje od morskih luka.

Negativni aspekti morskih luka mogu se sagledati i kroz zagađenje okoliša. Pri prijevozu brodova i utovaru i istovaru tereta javlja se onečišćenje zraka koje može imati kumulativan učinak za regionalnu okolinu stvarajući primjerice kisele kiše i druge negativne okolišne pojave. Onečišćenje mora može biti uzrokovano slučajnim curenjima ulja, goriva i nafte što može imati posljedice na zdravlje ljudi. Također vizualno oštećuje okolinu što je posebice negativno ako se radi o turističkoj destinaciji. Brodovi tokom plovidbe stvaraju raznoliki otpad koji se prema propisima skuplja i istovaruje na kopnu. No, u nekim slučajevima se otpad nelegalno deponira u more čime se šteti okolišu, ribama i morskim sisavcima. Luka u toku svoga poslovanja stvara buku koja se širi okolnim zrakom čime čini lokaciju nepoželjnom za boravak. Onečišćenje tla još je jedan primjer negativnih utjecaja poslovanja morskih luka na okoliš. Može se dogoditi slučajno ispuštanje nafte u tlo prilikom operacija na terminalima ili izlijevanje ulja i drugih tvari koje mogu uzrokovati raspadanje asfalta.

Utjecaj na smanjenje negativnih učinaka poslovanja morskih luka na okoliš moguć je kroz primjenu pravnih smjernica ali i implementacijom novih načina poslovanja. Međunarodna pomorska organizacija izdala je Međunarodnu konvenciju o sprječavanju onečišćenja s brodova (MARPOL) čiji je cilj sprječavanje i minimiziranje onečišćenja s brodova koja su nastala iz rutinskih ili slučajnih operacija. Pridržavanje pravila MARPOL konvencije obavezno je za sve sudionike u pomorskom poslovanju. S druge strane, morske luke mogu samostalno odlučiti o poboljšanju brige za okoliš promjenama postojećih načina upravljanja i planiranja. Primjer je uvođenje koncepta „zelene luke“ koji podrazumijeva usvajanje novog stila upravljanja čime se razvija lučka djelatnost u skladu s dobro definiranim ekološkim zahtjevima koji smanjuju negativne učinke lučkih aktivnosti. Uvođenjem novih koncepata, morske luke, ne samo da vode brigu o okolišu, već istovremeno pružaju i pozitivnu sliku o sebi što im stvara konkurentsku prednost.

Multiplikativni učinci morskih luka sastoje se od direktnih, indirektnih i induciranih učinaka. Direkti učinci ogledaju se u stvaranju dohotka, poslovne zarade i novih radnih mjesta u regiji kao posljedica poslovanja morskih luka. Indirektni učinci obuhvaćaju trošenje dohodaka zaposlenika u morskim lukama u drugim sektorima, na primjer, u restoranima ili trgovinama. Time se generira dodatna zarada od radne snage čime se potiče zapošljavanje u ostalim sektorima. Proces se može pratiti kroz drugi, treći i daljnje krugove potrošnje. Inducirani učinci ogledaju se u poboljšanoj prometnoj infrastrukturi regije koja je nastala zbog postojanja luke na tom području. Koristi od multiplikativnih učinaka mogu biti smanjene ukoliko se javi proces regionalnih curenja. Odnosno, proizvodni faktori mogu biti kupljeni izvan regije čime se gube izravne pogodnosti. Također, radna snaga može biti zaposlena iz vanjskih područja te ako se dohodci troše u drugim regijama, lučke regije gube koristi od multiplikacije.

Multiplikativni učinci morskih luka Europske unije izračunati su primjenom multiplikatora koji je u obzir uzeo bruto domaći proizvod te zaposlenost u pomorskom sektoru. Analizom se došlo do zaključka da za svaki milijun EUR kojom europska pomorska industrija pridonosi bruto domaćem proizvodu, stvara se još dodatnih 1,59 milijuna EUR drugdje u europskom gospodarstvu. Analogno tome, za svakog zaposlenog u pomorskoj industriji, stvara se novih 2,28 radnih mjesta drugdje u europskom gospodarstvu. Pomorska industrija Europske unije direktno doprinosi europskom bruto domaćem proizvodu s 54 milijarde EUR te stvara 640 000 direktnih radnih mjesta. Indirektan doprinos bruto domaćem proizvodu iznosi 57 milijardi EUR te 980 000 radnih mjesta, dok inducirani učinak iznosi 29 milijardi EUR u ukupnom bruto domaćem proizvodu te 477 000 radnih mjesta. Ukupan učinak na europsko gospodarstvo znatan je te je procijenjen na iznos od 140 milijardi EUR doprinosa bruto domaćem proizvodu te na 2 097 000 radnih mjesta.

Produktivnost pomorske industrije Europske unije nalazi se iznad europskog prosjeka te je procijenjena na 84 000 EUR. Produktivnost je manja u odnosu na sektore rudarstva i zračnog prijevoza ali je veća u odnosu na sektore zdravstva i proizvodnje. Visoka produktivnost pomorskog sektora označava visoki doprinos bruto domaćem proizvodu čime se pozitivno djeluje na životni standard Europske unije. Detaljnijom analizom direktno zaposlenih u pomorskoj industriji došlo se do zaključka kako je najveći udio zaposlenih u podsektoru prijevoza tereta, iza čega slijede prijevoz putnika, servis i usluge za podršku na moru te na posljednjem mjestu iznajmljivanje i leasing. Najviše direktno zaposlenih je u Ujedinjenom Kraljevstvu, Njemačkoj i Norveškoj. Poslovi na moru zastupljeniji su od poslova na kopnu u

omjeru 81%, naspram 19%. Prema geografskom obuhvatu Ujedinjeno Kraljevstvo, Njemačka i Norveška zapošljavaju najviše radnika na moru. Analizom podsektora u aspektu direktnog doprinosa bruto domaćem proizvodu došlo se do zaključka kako prijevoz tereta ima najveći doprinos s 30 milijardi EUR, a slijede ga podsektor prijevoza putnika, servis i usluge za podršku na moru te iznajmljivanje i leasing.

Primjenom dinamičke panel analize, točnije primjenom Generalizirane metode momenata i njenog procjenitelja u dva koraka mjerio se utjecaj morskih luka na regionalna gospodarstva. Uzorak istraživanja činili su sekundarni panel podaci za 107 lučkih regija u razdoblju od 2005. godine do 2015. godine prikupljeni s Eurostata. Pomorske regije su one regije NUTS 2 klasifikacije koje imaju kvantificiran promet tereta u morskim lukama. Zavisna varijabla koja je reprezentirala rast regionalnog gospodarstva bila je bruto domaći proizvod po glavi stanovnika, dok je glavnu nezavisnu varijablu činio promet tereta u morskim lukama. Za istraživanje učinka čimbenika endogene teorije rasta temeljene na istraživanju i razvoju, u regresijski model uključene su i varijable ljudski kapital te ulaganje u istraživanje i razvoj. Deskriptivom statistikom potvrdilo se predviđanje da postoje velike varijacije između razvijenosti regija kao i velike varijacije u prometu tereta između različitih regija.

Rezultati Generalizirane metode momenata i njenog procjenitelja u dva koraka ukazuju da morske luke imaju značajan utjecaj na gospodarski rast lučkih regija Europske unije. Na temelju prikazanih rezultata nameće se zaključak da postoji utjecaj prometa tereta na regionalni gospodarski rast. Također prema postavkama endogene teorije rasta temeljene na istraživanju i razvoju, stvaranje novih ideja je faktor koji dovodi do konstantnog rasta gospodarstva te se smatra kako gospodarstva koje stvaraju nove ideje neće doći do točke zasićenosti u kojoj se javlja stagnacija ili opadanje gospodarskog rasta. Ideje također vode ka izbjegavanju konvergencije te se pretpostavlja da gospodarstva mogu zauvijek rasti. Razvoj novih ideja u ekonometrijskoj analizi reprezentiran je ulaganjem u istraživanje i razvoj te se dokazala njegova pozitivna veza s gospodarskim rastom. Reakcijske sposobnosti regije na nova ulaganja i inovacije mogu se povezati s kvalitetnim ljudskim kapitalom. Uz inoviranje i razvijanje novih ideja potrebna je i apsorpcija novoproizvedenog znanja i njegova implementacija, stoga se u modelu testirao utjecaj ljudskog kapitala na gospodarski rast. Rezultati testiranja ukazuju na pozitivnu vezu između ljudskog kapitala i regionalnog gospodarskog rasta. Specifičnost ljudskog kapitala je da se ne može kupiti i ugraditi u proces već ljudi moraju samostalno

sudjelovati u njegovom razvoju što ljudski kapital čini vrlo vrijednim resursom regionalnih gospodarstava.

Dobiveni rezultati istraživanja nisu uspjeli dokazati postojanje odnosa između ulaganja u prometnu infrastrukturu i regionalnog gospodarskog rasta. Navedeno se može opravdati činjenicom da ukoliko postoji dobro gospodarstvo tada će postojati i kvalitetna prometna infrastruktura, a ne obrnuto da je kvalitetno gospodarstvo posljedica kvalitetne prometne infrastrukture. Također, efekti ulaganja u prometnu infrastrukturu mogu se vidjeti tek nakon određenog vremenskog odmaka. Iako Europska unija nastoji poticati razvitak ljudskog kapitala i što veće investiranje u istraživanje i razvoj, potrebno je primijetiti djelomičnu podcijenjenost navedenih čimbenika u odnosu na ulaganja u transportnu infrastrukturu. Prometna infrastruktura je u fokusu mnogih strategija Europske unije od kojih je glavna razvoj integrirane europske prometne mreže.

Rezultati ekonometrijske analize potvrdili su temeljnu hipotezu istraživanja te je testiranjem modela utvrđena veza između poslovanja morskih luka i regionalnog gospodarskog rasta. Prisutnost morske luke u regiji, ulaganje u istraživanje i razvoj i prisutnost kvalitetnog ljudskog kapitala izravno utječu na gospodarske aktivnosti i preduvjet su za postizanje visoke stope gospodarskog rasta u regiji. Stoga bi prioritet trebao biti usmjeren na poticanje obrazovanja i razvoja ljudskog kapitala, poticanje i financiranje inovacija te poticanje razvoja morskih luka.

LITERATURA

KNJIGE:

1. Bahtijarević Šiber, F. (1999) *Management ljudskih potencijala*. Zagreb: Golden marketing.
2. Baltagi, B. H. (2005) *Econometric Analysis of Panel Data*. Chichester: John Wiley & Sons.
3. Van den Bosch, F., Hollen, R., Volberda, H., Baaij, M. (2011) *The Strategic Value of the Port of Rotterdam for the International Competitiveness of the Netherlands: A First Exploration*. Rotterdam: Rotterdam School of Management (RSM), Erasmus University Rotterdam.
4. Domijan-Arneri, I. (2014) *Poslovanje u morskom brodarstvu*. Split: Redak.
5. Fujita, M., Krugman, P., Venables, A. J. (1999) *The Spatial Economy: Cities, Regions, and International Trade*. Cambridge: MIT Press.
6. Geerlings, H. (1998) *Meeting the Challenge of Sustainable Mobility*. Heidelberg i Berlin, Njemačka: Springer Verlag.
7. Geerlings, H., Kuipers, B., Zuidwijk, R. (ur.) (2018) *Ports and Networks, Strategies , Operations and Perspectives*. London i New York: Routledge, Taylor & Francis Group.
8. Grossman, G. M., Helpman, E. (1991) *Innovation and Growth in the Global Economy*. Cambridge: The MIT Press.
9. Haralambides, H. (ur.) (2015) *Port Management*. Basingstoke, Hampshire: Palgrave Macmillan.
10. Jugović, A. (2012) *Upravljanje morskom lukom*. Rijeka: Sveučilište u Rijeci, Pomorski fakultet Rijeka.
11. Karaman Aksentijević, N., Sundać, D., Biljan-August, M., Denona Bogović, N., Štambuk, A., Ježić, Z., Fatur Krmpotić, I., Kažović, D., Švast, N., Vučak, A., Čegar, S. (2012) *Ljudski potencijali i ekonomski razvoj*. N. Karaman Aksentijević (ur.). Rijeka: Ekonomski fakultet Sveučilišta u Rijeci.
12. Kesić, B. (2003) *Ekonomika luka*. Rijeka: Sveučilište u Rijeci, Pomorski fakultet Rijeka.
13. Kesić, B., Jugović, A. (2006) *Menadžment pomorskoputničkih luka*. Rijeka: Sveučilište u Rijeci, Pomorski fakultet, Liber d.o.o.
14. Lovrić, L. (2005) *Uvod u ekonometriju*. Rijeka: Ekonomski fakultet Sveučilišta u

Rijeci.
15. Morroni, M. (2006) *Knowledge, Scale and Transactions in the Theory of the Firm*. Cambridge: Cambridge University Press.
16. Porter, M. E. (1990) *The Competitive Advantage of Nations*. New York: The Free Press.
17. Schumpeter, J. (1942) *Capitalism, Socialism, and Democracy*. New York: Harper & Brothers.
18. Sundać, D., Škalamera-Alilović, D., Babić, M. (2016) *Poslovno okruženje i intelektualni kapital*. Rijeka: Ekonomski fakultet Sveučilišta u Rijeci.
19. Talley, W. K. (2009) *Port Economics*. London i New York: Routledge, Taylor & Francis Group.
20. Valdés, B. (1999) *Economic Growth: Theory, Empirics and Policy*. Cheltenham, Velika Britanija: Edward Elgar.
21. Wooldridge, J. M. (2015) *Introductory Econometrics A Modern Approach*. Boston: Cengage Learning.
22. Zelenika, R., Pavlić Skender, H. (2007) *Upravljanje logističkim mrežama*. Rijeka: Sveučilište u Rijeci, Ekonomski fakultet Rijeka.

POGLAVLJA U KNJIGAMA:

23. Van den Bosch, F. A. J., Hollen, R. M. A., Volberda, H. W. (2018) 'How Ports Create Strategic Value for their Country', u Geerlings, H., Kuipers, B., and Zuidwijk, R. (ur.) *Ports and Networks, Strategies , Operations and Perspectives.* London i New York: Taylor & Francis Group, pp. 38–53.
24. Ducruet, C. (2009) 'Port Regions and Globalization', u Notteboom, T. E., Ducruet, C., and de Langen, P. W. (ur.) *Ports in Proximity, Competition and Coordination among Adjacent Seaports*. Farnham i Burlington: Ashgate Publishing Company, pp. 41–53.
25. Geerlings, H., Wiegmans, B. (2018) 'Technological Innovations', u Geerlings, H., Kuipers, B., i Zuidwijk, R. (ur.) *Ports and Networks, Strategies , Operations and Perspectives*. London i New York: Taylor & Francis Group, pp. 332–347.
26. Haralambides, H. (2018) 'Port Management and Institutional Reform', u Geerlings, H., Kuipers, B. i Zuidwijk, R. (ur.) *Ports and Networks, Strategies , Operations and Perspectives*. London i New York: Taylor & Francis Group, pp. 67–89.
27. de Koning, J., Zandvliet, K., Gelderblom, A. (2018) 'The Labour Market of Port-

Cities', u Geerlings, H., Kuipers, B., and Zuidwijk, R. (ur.) *Ports and Networks, Strategies , Operations and Perspectives*. London i New York: Taylor & Francis Group, pp. 348–363.

28. de Langen, P. W. (2007) 'The Economic Performance of Seaport Regions', u Wang, J. J. (ur.) *Ports, Cities, and Global Supply Chains*. Aldershot: Ashgate Publishing Company.
29. de Langen, P. W., Nijdam, M. H. (2009) 'A Best Practice in Cross-border Port Cooperation: Copenhagen Malmö Port', u Notteboom, T. E., Ducruet, C. i de Langen, P. W. (ur.) *Ports in Proximity, Competition and Coordination among Adjacent Seaports*. Ashgate Publishing Company, pp. 163–174.
30. van der Lugt, L. (2018) 'Port Development Company, Role and Strategy', u Geerlings, H., Kuipers, B., and Zuidwijk, R. (ur.) *Ports and Networks, Strategies , Operations and Perspectives*. London i New York: Routledge, Taylor & Francis Group, pp. 54–66.
31. Nijdam, M., van der Horst, M. (2018) 'Port definition, concepts and the role of ports in supply chains', u Geerlings, H., Kuipers, B., and Zuidwijk, R. (ur.) *Ports and Networks, Strategies , Operations and Perspectives*. London i New York: Taylor & Francis Group, pp. 9–25.
32. Pallis, A. A., Verhoeven, P. (2009) 'Does the EU Port Policy Strategy Encompass "Proximity"?', u Notteboom, T. E., Ducruet, C., and de Langen, P. W. (ur.) *Ports in Proximity, Competition and Coordination among Adjacent Seaports*. Farnham i Burlington: Ashgate Publishing Company, pp. 99–112.
33. Zuidwijk, R. (2018) 'Ports and Global Supply Chains', u Geerlings, H., Kuipers, B., and Zuidwijk, R. (ur.) *Ports and Networks, Strategies , Operations and Perspectives*. London i New York: Taylor & Francis Group, pp. 26–37.

ČLANCI:

34. Aghion, P., Howitt, P. (1992) 'A Model of Growth Through Creative Destruction', *Society*, 60(2), pp. 323–351.
35. Arellano, M., Bond, S. (1991) 'Some Tests of Specification for Panel Data: Monte Carlo Evidence and an Application to Employment Equations', *Review of Economic Studies*, 58(2), pp. 277–297. doi: 10.2307/2297968.
36. Arellano, M., Bover, O. (1995) 'Another look at the instrumental variable estimation

of error-components models', *Journal of econometrics*, 68(1), pp. 29–51.

37. Arrow, K. J. (1962) 'The Economic Implications of Learning by Doing', *The Review of Economic Studies*, 29(3), pp. 155–173. Dostupno: http://www.jstor.org.ezproxy.unal.edu.co/stable/pdf/2295952.pdf.
38. Aschauer, D. A. (1989) 'Is public expenditure productive?', *Journal of Monetary Economics*. doi: 10.1016/0304-3932(89)90047-0.
39. Badurina, P., Cukrov, M., Dundović, Č. (2017) 'Contribution to the implementation of "Green Port" concept in Croatian seaports', *Pomorstvo : Scientific Journal of Maritime Research*, 31(1), pp. 10–17. doi: 10.31217/p.31.1.3.
40. Becker, G. S. (1962) 'Investment in Human Capital: A Theoretical Analysis', *Journal of Political Economy*, 70(5), pp. 9–49.
41. Bilbao-Osorio, B., Rodríguez-Pose, A. (2004) 'From R&D to Innovation and Economic Growth in the EU', *Growth and Change*, 35(4), pp. 434–455.
42. Blundell, R., Bond, S. (1998) 'Initial conditions and moment restrictions in dynamic panel data models', *Journal of Econometrics*, 87(1), pp. 115–143. doi: 10.1016/S0304-4076(98)00009-8.
43. Bottasso, A., Conti, M., Ferrari, C., Merk, O., Tei, A. (2013) 'The impact of port throughput on local employment: Evidence from a panel of European regions', *Transport Policy*. Elsevier, 27, pp. 32–38. doi: 10.1016/j.tranpol.2012.12.001.
44. Bottasso, A., Conti, M., Ferrari, C., Tei, A. (2014) 'Ports and regional development: A spatial analysis on a panel of European regions', *Transportation Research Part A: Policy and Practice*. Elsevier Ltd, 65, pp. 44–55. doi: 10.1016/j.tra.2014.04.006.
45. Bronzini, R., Piselli, P. (2009) 'Determinants of Long-Run Regional Productivity: The Role of R&D, Human Capital and Public Infrastructure', *Regional Science and Urban Economics*, 39(2), pp. 189–199. doi: 10.2139/ssrn.935010.
46. Campbell, D. (1994) 'Foreign Investment, Labour Immobility and the Quality of Employment', *International Labour Review*, 133(2), pp. 185–188.
47. Canning, D., Pedroni, P. (2008) 'Infrastructure, long-run economic growth and causality tests for cointegrated panels', *Manchester School*. doi: 10.1111/j.1467-9957.2008.01073.x.
48. Casaca, A. C. P., Marlow, P. B. (2007) 'The impact of the trans-European transport networks on the development of short sea shipping', *Maritime Economics and Logistics*, 9(4), pp. 302–323. doi: 10.1057/palgrave.mel.9100184.
49. Chadwin, M., Pope, J., Talley, W. K. (1990) *Costing Terminal Operations and*

Measuring Capacity, Ocean Container Transportation: An Operational Perspective. New York: Taylor & Francis Group.

50. Cheung, S. M. S., Yip, T. L. (2011) 'Port City Factors and Port Production':, *Transportation Journal*, 50(2), pp. 162–175. doi: 10.5325/transportationj.50.2.0162.
51. Cohen, J., Monaco, K. (2008) 'Ports and highways infrastructure: An analysis of intra- and interstate spillovers', *International Regional Science Review*, 31(3), pp. 257–274. doi: 10.1177/0160017608318946.
52. Condeço-Melhorado, A., Gutiérrez, J., García-Palomares, J. C. (2011) 'Spatial impacts of road pricing: Accessibility, regional spillovers and territorial cohesion', *Transportation Research Part A: Policy and Practice*, 45(3), pp. 185–203. doi: 10.1016/j.tra.2010.12.003.
53. Crescenzi, R. (2005) 'Innovation and Regional Growth in the Enlarged Europe: The Role of Local Innovative Capabilities, Peripherality, and Education', *Growth and Change*, 36(4), pp. 471–507. doi: 10.1111/j.1468-2257.2005.00291.x.
54. Crescenzi, R., Rodríguez-Pose, A. (2012) 'Infrastructure and regional growth in the European Union', *Papers in Regional Science*, 91(3), pp. 487–513. doi: 10.1111/j.1435-5957.2012.00439.x.
55. Deng, T., Shao, S., Yang, L., Zhang, X. (2014) 'Has the transport-led economic growth effect reached a peak in China? A panel threshold regression approach', *Transportation*, 41(3), pp. 567–587. doi: 10.1007/s11116-013-9503-4.
56. Devarajan, S., Swaroop, V., Zou, H. (1996) 'Shantayanan Devarajan, Vinaya Swaroop*, Heng-fu Zou', *Journal Monetary Economics*, 37, p. 313 344.
57. Dubravčić, D. (2007) 'O ljudskom kapitalu - kritičke bilješke', *Privredna kretanja i ekonomska politika*, 17(111), pp. 28–49.
58. Ferrari, C., Percoco, M., Tedeschi, A. (2010) 'Ports and local development: Evidence from Italy', *International Journal of Transport Economics*, 37(1), pp. 9–30. doi: 10.2307/42747893.
59. Fleming, D. K., Baird, A. J. (1999) 'Some Reflections on Port Competition in the United States and Europe', *Maritime Policy and Manageme*, 26(4), pp. 383–394.
60. Fujita, M. and Mori, T. (1996) 'The role of ports in the making of major cities ':, *Journal of Development Economics*, 49, pp. 93–120.
61. Gripaios, P., Gripaios, R. (1995) 'The Impact of a Port on its Local Economy: the Case of Plymouth', *Maritime Policy & Management*, 22(1), pp. 13–23.
62. Grobar, L. M. (2008) 'The economic status of areas surrounding major U.S. container

ports: Evidence and policy issues', *Growth and Change*, 39(3), pp. 497–516. doi: 10.1111/j.1468-2257.2008.00435.x.

63. Grossman, G. M., Helpman, E. (1990) 'Trade, Innovation, and Growth', *American Economic Review*, 80(2), pp. 86–91.
64. Hesse, M. (2006) 'Global Chain, Local Pain: Regional Implications of Global Distribution Networks in the German North Range', *Growth and Change*, 37(4), pp. 570–596.
65. Hong, J., Chu, Z., Wang, Q. (2011) 'Transport infrastructure and regional economic growth: Evidence from China', *Transportation*, 38(5), pp. 737–752. doi: 10.1007/s11116-011-9349-6.
66. Hoyle, B. S. (1989) 'The Port-City Interface: Trends, Problems and Examples', 20(4), pp. 429–435.
67. Hsiao, C. (2007) 'Panel data analysis-advantages and challenges', *Test*, 16(1), pp. 1–22. doi: 10.1007/s11749-007-0046-x.
68. Jouili, T. A. (2016) 'The Role of Seaports in the Process of Economic Growth', *Developing Country Studies*, 6(2), pp. 64–69.
69. Karaman Aksentijević, N., Ježić, Z. (2009) 'Human Resources Development and Research Capacity and their Impact on Economic Growth', *Zbornik radova Ekonomskog fakulteta u Rijeci : časopis za ekonomsku teoriju i praksu*, 27(2), pp. 263–291.
70. de Langen, P. W., Pallis, A. A. (2006) 'Analysis of the Benefits of Intra-Port Competition', *International Journal of Transport Economics*, 33(1), pp. 69–85.
71. Lucas Jr., R. E. (1988) 'On the Mechanics of Economic Development', *Journal of Monetary Economics*, 22(1), pp. 3–42. doi: Doi 10.1016/0304-3932(88)90168-7.
72. Lucas Jr., R. E. (1993) 'Making a Miracle', *Econometrica*, 61(2), pp. 251–272.
73. Marlow, P. B., Paixão Casaca, A. C. (2003) 'Measuring Lean Ports' Performance', *International Journal of Transport Management*, 1(4), pp. 189–202.
74. Mccalla, R. J., Slack, B., Comtois, C. (2004) 'Dealing With Globalisation at the Regional and Local Levels: The Case of Contemporary Containerization', *The Canadian Geographer*, 48(4), pp. 473–487.
75. Mervar, A. (1999) 'Pregled modela i metoda istraživanja gospodarskog rasta', *Privredna kretanja i ekonomska politika*, 9(73), pp. 20–61.
76. Mervar, A. (2003) 'Esej o novijim doprinosima teoriji ekonomskog rasta', *Ekonomski pregled*, 54(3–4), pp. 369–392.

77. Milanović, B. (2013) ‘Global Income Inequality by the Numbers: In History and Now,’, *Global Policy,* 4(2), pp. 198-208.
78. Musso, E., Benacchio, M., Ferrari, C. (2000) ‘Ports and Employment in Port Cities’, *Maritime Economics & Logistics,* 2(4), pp. 83-311
79. Ng, A. K. Y., Chen, S., Cahoon, S., Brooks, B., Yang, Z. (2013) ‘Climate change and the adaptation strategies of ports: The Australian experiences’, *Research in Transportation Business and Management*, 8, pp. 186–194.
80. Niebuhr, A. (2006) ‘Market access and regional disparities: New economic geography in Europe’, *Annals of Regional Science*. doi: 10.1007/s00168-005-0047-1.
81. Nketiah-Amponsah, E. (2009) ‘Public spending and economic growth: Evidence from Ghana (1970-2004)’, *Development Southern Africa,* 26(3), pp. 477–497. doi: 10.1080/03768350903086846.
82. Park, J. S., Seo, Y. J. (2016) ‘The impact of seaports on the regional economies in South Korea: Panel evidence from the augmented Solow model’, *Transportation Research Part E: Logistics and Transportation Review*. Elsevier Ltd, 85, pp. 107–119. doi: 10.1016/j.tre.2015.11.009.
83. Pavlic, B., Cepak, F., Sucic, B., Peckaj, M., Kandus, B. (2014) ‘Sustainable Port Infrastructure, Practical Implementation of the Green Port Concept’, *Thermal Science*, 18(3), pp. 935–948. doi: 10.2289/TSCI1403935P.
84. Perić Hadžić, A., Župarić, L., Đeverlija, S. (2016) ‘Analysis of the multiplicative effects of the Port of Rijeka’, *Pomorstvo,* 30(2), pp. 113–119. doi: 10.31217/p.30.2.3.
85. Porter, M. E. (2003) ‘The economic performance of regions’, *Regional Studies*, 37(6–7), pp. 549–578. doi: 10.4324/9780203607046.
86. Rodríguez-Pose, A. (1999) ‘Innovation Prone and Innovation Averse Societies: Economic Performance in Europe’, *Growth and Change*, 30(1), pp. 75–105. doi: 10.1111/0017-4815.00105.
87. Romer, P. M. (1986) ‘Increasing Returns and Long-Run Growth’, *Journal of Political Economy*, 94(5), pp. 1002–1037. doi: 10.1086/261420.
88. Romer, P. M. (1990) ‘Endogenous technological change’, *Journal of Political Economy*, 98(5), pp. 71–102. doi: 10.1093/acprof:osobl/9780199663897.003.0004.
89. Romer, P. M. (1992) ‘Two Strategies for Economic Development: Using Ideas and Producing Ideas’, *The World Bank Economic Review,* 6(1), pp. 63–91. doi: 10.1093/wber/6.suppl_1.63.
90. Romer, P. M. (1993) ‘Idea gaps and object gaps in economic development’, *Journal of*

Monetary Economics, 32(3), pp. 543–573. doi: 10.1016/0304-3932(93)90029-F.

91. Roodman, D. (2009) 'How to do xtabond2: An introduction to difference and system GMM in Stata', *The Stata Journal*, 9(1), pp. 86–136. doi: 10.2139/ssrn.2145803.
92. Schultz, T. W. (1961) 'Investment in Human Capital', *The American Economic Review*, 51(1), pp. 1–17.
93. Shan, J., Yu, M., Lee, C. Y. (2014) 'An empirical investigation of the seaport's economic impact: Evidence from major ports in China', *Transportation Research Part E: Logistics and Transportation Review*. Elsevier Ltd, 69, pp. 41–53. doi: 10.1016/j.tre.2014.05.010.
94. Slack, B. (1999) 'Satellite Terminals: A Local Solution to Hub Congestion?', *Journal of Transport Geography*, 7(4), pp. 241–46.
95. Solow, R. (1956) 'A Contribution to the Theory of Economic Growth', *The Quarterly Journal of Economics*, 70(1), pp. 65–94. doi: 10.2307/1884513.
96. Song, L., van Geenhuizen, M. (2014) 'Port infrastructure investment and regional economic growth in China: Panel evidence in port regions and provinces', *Transport Policy*. Elsevier, 36, pp. 173–183. doi: 10.1016/j.tranpol.2014.08.003.
97. Tsekeris, T., Tsekeris, C. (2011) 'Demand Forecasting in Transport: Overview and Modeling Advances', *Economic Research-Ekonomska Istraživanja*, 24(1), pp. 82–94. doi: 10.1080/1331677x.2011.11517446.
98. Vlahinić Lenz, N., Pavlić Skender, H., Mirković, P. A. (2018) 'The macroeconomic effects of transport infrastructure on economic growth: the case of Central and Eastern E.U. member states', *Economic Research-Ekonomska Istrazivanja*. Routledge, 31(1), pp. 1953–1964. doi: 10.1080/1331677X.2018.1523740.
99. Xia, J., Wang, K., Wang, S. (2019) 'Drone scheduling to monitor vessels in emission control areas', *Transportation Research Part B*. Elsevier Ltd, 119, pp. 174–196. doi: 10.1016/j.trb.2018.10.011.
100. Yoo, S. H. (2006) 'Seaport infrastructure investment and economic growth in Korea', *International Journal of Critical Infrastructures*, 2(1), pp. 1–9. doi: 10.1016/j.jconrel.2006.01.021.
101. Yu, N., de Jong, M., Storm, S., Mi, J. (2012) 'Transport Infrastructure, Spatial Clusters and Regional Economic Growth in China', *Transport Reviews*, 32(1), pp. 3–28. doi: 10.1080/01441647.2011.603104.
102. Zhao, Q., Xu, H., Wall, R. S., Stavropoulos, S. (2017) 'Building a bridge between port and city: Improving the urban competitiveness of port cities', *Journal of*

Transport Geography. Elsevier Ltd, 59, pp. 120–133. doi: 10.1016/j.jtrangeo.2017.01.014.

PUBLIKACIJE:

103. European Commission (2013) *Innovation Union, A pocket guide on a Europe 2020 initiative*. Luxembourg: Publications Office of the European Union. doi: 10.2777/59336.

104. Eurostat (2012) 'Focus on Coastal Regions', u *Eurostat Regional Yearbook 2012*. Luxembourg: Publications Office of the European Union, pp. 177–192.

105. Eurostat (2017) *Eurostat Regional Yearbook 2017*. Luxembourg: Publications Office of the European Union. doi: 10.2785/257716.

106. Eurostat (2018) *Eurostat Regional Yearbook 2018*. Luxembourg: Publications Office of the European Union. doi: 10.1029/93WR00758.

107. Francisconi, M. (2017) *An explorative study on blockchain technology in application to port logistics, Magistarski rad*. Delft University of Technology; Delft, Netherlands. Dostupno: https://repository.tudelft.nl/islandora/object/uuid%3Ab1de98dd-f1a7-456a-b8cb-4d87dc2c4f9f.

108. Inoue, S. (2010) *Challenges of the World's Ports in the Globalization Era, The 5th Young Leaders Training & Research Program*. Ulaanbaatar, Mongolia. Dostupno: https://www.neaef.org/public/neaef/files/documents/publications_pdf/young_leaders/5th/Inoue%20Satoshi%201.pdf

109. Oxford Economics (2014) *The economic value of the EU shipping industry*. Dostupno: http://www.ecsa.eu/images/Studies/150220 European Shipping Update.pdf.

110. Oxford Economics (2017a) *The Economic Impact of the Croatian Shipping Industry*. London.

111. Oxford Economics (2017b) *The Economic Value of the EU Shipping Industry 2017 update*.

112. Pannekoek, M. (2019) *Data as Fuel for the Digital Port*. Port of Rotterdam

113. Scott, M. F. (1991) *A New View of Economic Growth - Four Lectures, World Bank Discussion Papers*. Washington D.C.: The World Bank.

KONFERENCIJSKA PRIOPĆENJA:

114. Corbett, J. J., Winebrake, J. (2008) 'The Impacts of Globalisation on International Maritime Transport Activity', u *Global Forum on Transport and Environment in a Globalising World*. Guadalajara, Mexico.

115. Trozzi, C., Vaccaro, R. (2000) 'Environmental Impact of Port Activities', in *Second International Conference PORTS 2000 Marittime Engineering and Ports*. Barcelona, Spain. doi: 10.2495/PORTS000131.

116. Verhoeven, P. (2008) 'European Ports Policy: Meeting Contemporary Governance Challenges', in *International Conference of the International Association of Maritime Economists*. Dalian, China.

117. Vleugels, R. L. M. (1969) 'The Economic Impact of Ports on the Regions They Serve and the Role of Industrial Development', in *6th Biennial Conference of the International Association of Ports and Harbors*. Melbourne, Australia.

INTERNET IZVORI:

118. Baum, C. F. (2014) *Dynamic Panel Data Estimators*. Dostupno: http://fmwww.bc.edu/EC-C/S2014/823/EC823.S2014.nn05.slides.pdf.

119. Buck, R. (2018) *Trade Globalisation or Investment Regionalisation? The Impact on European Seaports, ESPO Conference*. Dostupno: https://www.espo.be/media/31-05%201130%20Rene%20Buck.pdf

120. Capterra (2018) *Drones in Logistics: A How-To Guide for Beginners*. Dostupno: https://blog.capterra.com/drones-in-logistics-how-to-guide/.

121. Control Tower (2018) *Evolution of Synchromodal Transport to Synchro-logistics*. Dostupno: https://133627blog.wordpress.com/2016/11/10/evolution-of-synchromodal-transport-to-synchro-logistics/.

122. Cosco Shipping Ports Limited (2019) *Total Throughput, Connecting The World, Financial Report 2018.* Dostupno: http://doc.irasia.com/listco/hk/coscoship/interim/2018/intrep.pdf.

123. Deloitte (2015) *Global Trends to 2030 Impact on Ports Industry*. Dostupno: https://www2.deloitte.com/content/dam/Deloitte/cn/Documents/energy-resources/deloitte-cn-er-global-trends-to-2030-en-170104.pdf.

124. DP World (2019) *DP World Handles 71 million TEU and Reports 2.9%*

Volume Growth in 2018. Dostupno: https://www.dpworld.com/en/media/media-centre/2018-Q4-Throughput.

125. Dutch Maritime Research Institute Netherlands (MARIN) (2019) *Research and Development of our Knowledge Base*. Dostupno: https://www.marin.nl/research#enablings.

126. EspoN, E. S. P. O. N. – (2009) *Accessibility Project Reports*. Dostupno: www.espon.eu.

127. European Commission (2015) *Maritime Ports*, *Eurostat*. Dostupno: https://ec.europa.eu/transport/modes/maritime/ports/ports_en.

128. European Commission (2016) *Maritime transport of freight by NUTS 2 regions - map*, *Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/mapToolClosed.do?tab=map&init=1&plugin=1&language=en&pcode=tgs00076&toolbox=types.

129. European Commission (2017a) *Investment in Human Capital - Assessing the Efficiency of Public Spending on Education.* Dostupno: https://www.consilium.europa.eu/media/31409/investment-in-human-capital_eurogroup_31102017_ares.pdf.

130. European Commission (2017b) *Top 20 ports - gross weight of goods handled in each port, by direction*, *Eurostat*. Dostupno: http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=mar_mg_aa_pwhd&lang=en.

131. European Commission (2018a) *Exports of goods and services in % of GDP*, *Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tet00003&plugin=1.

132. European Commission (2018b) *Government expenditure on transport*, *Eurostat*. Dostupno: https://ec.europa.eu/eurostat/en/web/products-eurostat-news/-/DDN-20180904-1.

133. European Commission (2018c) *Gross domestic expenditure on R&D (GERD)*, *Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/refreshTableAction.do?tab=table&plugin=1&pcode=t2020_20&language=en.

134. European Commission (2018d) *Human resources in science and technology (HRST)*, *Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tsc

00025&plugin=1.

135. European Commission (2018e) *Intramural R&D expenditure (GERD) by NUTS 2 regions, Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/table.do?tab=table&plugin=1&language=en&pcode=tgs00042.

136. European Commission (2018f) *Maritime transport of freight by NUTS 2 regions, Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/table.do?tab=table&plugin=1&language=en&pcode=tgs00076.

137. European Commission (2018g) *NUTS - Nomenclature of territorial units for statistics, Eurostat*. Dostupno: https://ec.europa.eu/eurostat/web/nuts/background.

138. European Commission (2018h) *Population change by NUTS 2 region, Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/refreshTableAction.do?tab=table&plugin=1&pcode=tgs00099&language=en.

139. European Commission (2018i) *Regional gross domestic product (PPS per inhabitant) by NUTS 2 regions, Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tgs00005&plugin=1.

140. European Commission (2018j) *Tertiary educational attainment, age group 25-64 by sex and NUTS 2 regions, Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tgs00109&plugin=1.

141. European Commission (2018k) *Tertiary educational attainment by sex, Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=sdg_04_20&plugin=1.

142. European Commission (2018l) *Unemployment rate by NUTS 2 regions, Eurostat*. Dostupno: https://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tgs00010&plugin=1.

143. European Commission (2019) *Country level - gross weight of goods handled in all ports, Eurostat*. Dostupno: http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=mar_mg_aa_cwh&lang=en.

144. European Union (2019) *Research & innovation*. Dostupno: https://europa.eu/european-union/topics/research-innovation_en.
145. Hutchison Ports (2019) *Our Annual Throughput*. Dostupno: https://hutchisonports.com/en/about-us/throughput/.
146. International Maritime Organization (2019a) *International Convention for the Prevention of Pollution from Ships (MARPOL)*. Dostupno: http://www.imo.org/en/About/Conventions/ListOfConventions/Pages/International-Convention-for-the-Prevention-of-Pollution-from-Ships-(MARPOL).aspx.
147. International Maritime Organization (2019b) *MARPOL Annex I – Prevention of Pollution by Oil*. Dostupno: http://www.imo.org/en/OurWork/Environment/PollutionPrevention/OilPollution/Pages/Default.aspx.
148. International Maritime Organization (2019c) *Prevention of Pollution by Garbage from Ships*. Dostupno: http://www.imo.org/en/OurWork/Environment/PollutionPrevention/Garbage/Pages/Default.aspx.
149. Lloyd's List (2019) *Top 10 box port operators 2018*. Dostupno: https://lloydslist.maritimeintelligence.informa.com/LL1125032/Top-10-box-port-operators-2018.
150. Ministarstvo mora prometa i infrastrukture (2019) *Instrument za povezivanje Europe – CEF*. Dostupno: http://promet-eufondovi.hr/poslovanje/instrument-za-povezivanje-europe-cef/.
151. Port of Rotterdam (2018a) *New standard in container terminals and services*. Dostupno: https://www.portofrotterdam.com/en/business-opportunities/smartest-port/cases/new-standard-in-container-terminals-and-services.
152. Port of Rotterdam (2018b) *Port Digitisation, a Rotterdam specialty*. Dostupno: https://www.portofrotterdam.com/en/port-forward/about-us.
153. Port of Rotterdam (2018c) *Step by step towards a digital port*. Dostupno: https://www.portofrotterdam.com/en/port-forward/step-by-step-towards-a-digital-port.
154. Port Technology (2018) *Ports in the Cloud: The Next Step in Automation?* Dostupno: https://www.porttechnology.org/news/ports_in_the_cloud_the_next_step_in_automation.
155. PSA International (2019) *Statistics*. Dostupno: https://www.globalpsa.com/.

156. Riley, G. (2019) *Understanding The Solow Economic Growth Model*. Dostupno: https://www.tutor2u.net/economics/reference/economic-growth-neo-classical-growth-the-solow-model.

157. Safety4Sea (2018) *6 global trends in the container shipping industry*. Dostupno: https://safety4sea.com/6-global-trends-in-the-container-shipping-industry/

158. The Geography of Transport Systems (2017) *The Port as a Funnel to Economic Development*. Dostupno: https://transportgeography.org/?page_id=9445.

159. The Motorways of the Sea Digital Multichannel Platform (2019) *Insight: Four Trends of ports to watch in 2019*. Dostupno: https://www.onthemosway.eu/insight-four-trends-of-ports-to-watch-in-2019/?cn-reloaded=1.

160. United Nations Development Programme (2018) *Human Development Index (HDI), Human Development Reports*. Dostupno: http://hdr.undp.org/en/content/human-development-index-hdi.

OSTALI IZVORI:

161. Škrabić Perić, B. (2018) 'Ekonometrijske metode u financijama, panel analiza'. Predavanje u sklopu Poslijediplomskog specijalističkog studija 'Financije'.

POPIS TABLICA

Tablica 1. Ulaganja u istraživanje i razvoj u zemljama Europske unije (% od BDP-a) 32
Tablica 2. Ljudski resursi u znanosti i tehnologiji u zemljama Europske unije (% aktivnog stanovništva)..... 34
Tablica 3. Udio ljudi s visokim obrazovanjem u ukupnoj populaciji (%) 40
Tablica 4. Indeks ljudskog razvoja u zemljama Europske unije od 2008. do 2017. godine ... 42
Tablica 5. Promet tereta u morskim lukama u zemljama Europske unije (u tisućama tona) .. 67
Tablica 6. Interni i eksterni izazovi u morskim lukama koje nameće globalizacija..... 97
Tablica 7. Popis i objašnjenje varijabli 126
Tablica 8. Deskriptivna statistika varijabli..... 127
Tablica 9. Koeficijenti korelacije 129
Tablica 10. Rezultati testiranja modela 132

POPIS GRAFIKONA

Grafikon 1. Usporedba BDP-a s prosječnim ulaganjem u istraživanje i razvoj u Europskoj uniji 31
Grafikon 2. Proizvodna funkcija luke 55
Grafikon 3. Top 20 morskih luka u Europskoj uniji po prometu tereta u 2017. godini (u tisućama tona) 70
Grafikon 4. Produktivnost u Europskoj uniji – usporedba pomorske industrije s ostalim sektorima 111
Grafikon 5. Direktno zaposleni radnici u pomorskoj industriji prema podsektoru 112
Grafikon 6. Direktno zaposleni radnici u pomorskoj industriji prema mjestu rada 113
Grafikon 7. Direktan doprinos pomorske industrije BDP-u Europske unije prema podsektoru (u milijardama EUR) 114

POPIS SHEMA

Shema 1. Romerov model zasnovan na istraživanju i razvoju 25
Shema 2. Piramida ekonomskih razvojnih faza..... 27
Shema 3. Podjela tereta u teretnim lukama 47
Shema 4. Sudionici u lučkom poslovanju 49
Shema 5. Interakcija lučkih korisnika i pružatelja usluga 52
Shema 6. Rezultati ulaganja u Transeuropsku mrežu prometnica (TEN-T) 64
Shema 7. Trendovi u poslovanju morskih luka 73
Shema 8. Prikaz sinkromodalnog prijevoza 78
Shema 9. Razvoj interakcije morskih luka i okolnog područja 87
Shema 10. Odrednice međunarodne konkurentnosti lučke regije 89
Shema 11. Kružnice ekonomskog utjecaja..... 105
Shema 12. Multiplikativni učinci poslovanja morskih luka 106
Shema 13. Multiplikativni učinci pomorske industrije u Europskoj uniji u 2015. godini 110

POPIS ZEMLJOVIDA

Zemljovid 1. Prometni koridori Transeuropske mreže prometnica (TEN-T) 63
Zemljovid 2. Promet tereta u regijama Europske unije u 2016. godini (u tisućama tona)..... 69
Zemljovid 3. Regije Europske unije uključene u istraživanje..... 124

LONG ABSTRACT

Seaports are an important participant in domestic and international trade since much of the world's trade is carried out by sea. They are the starting point for each freight or passenger transportation. Together with its port region and surroundings, the port makes a logistics center that facilitates the functioning of the global market. Traditionally, seaports are considered as strategic economic good capable of linking global and local markets that favor the globalization process. At the same time, seaports are an important factor of regional economies since they reduce transportation costs, increase regional employment and attract and create other port activities. Seaports are contributing to their international competitive position and also to the international competitive position of the region or country in which they are located. The competitive position of the seaport is reflected in the amount of freight transported while the competitive position of the region is defined through employment and value creation.

Production and consumption of many products is taking place in different parts of the world and the role of seaports is their connection, thus generating global supply chains. They are nodes in the global logistics network that connect sea transport and regions. Sea-going operations in most cases involve international business that creates competition between seaports in different countries. Customers, if they are not happy with a business at a particular seaport, can easily switch their business to another seaport, which encourages seaports to be additionally excellent and provide good service.

Seaport operations are important for society in general as they create new jobs and contribute to the growth of gross domestic product of cities and regions in which they are located. Apart from creating direct positive effects on the economy, seaports also create both indirect and induced effects. The indirect effects of port operations arise when initial earnings from labor, business and tax revenues are subsequently consumed or partially spent in the region, thus generating new jobs and additional business earnings. The induced effects result from improving the infrastructure and quality of services in the transport system of the region due to the existence of a port. Participants in seaport business are diverse and have direct or indirect benefits from port operations; however, it is generally important for the economy that the seaports create value and new jobs. Port operations in one region can also create the overflow effects on other regions.

The topic that deals with impact of seaports on the local or regional economy was covered by many authors and the relationships was proven in most cases. However, only a few authors used economic theories as a framework for their research. In the context of the above-mentioned research problem, a scientific **research problem** has been defined: although the influence of seaports on the local and regional economy was the subject of many authors, in most cases they did not use economic theories as the basis for their research. Therefore, in dissertation the endogenous growth theory based on research and development (R&D) will be used as a theoretical framework. The model that will be able to determine economic impact of seaports on regional economy will be proposed.

Furthermore, the main focus of many previous researches was impact of transport infrastructure on economic growth while the other drivers of economic growth were neglected. Therefore, in the doctoral dissertation special attention will be paid to investments in R&D and human capital as the main drivers of the regional economy, together with seaports. At the same time, investments in R&D and human capital are important factors for the seaport business as well. If ports want to remain competitive on the market, they must follow and implement new technological achievements that will enable them to make faster and cheaper freight transshipments and have a high-quality human capital that will know how to use the new technology. **The aim of the research** is to sum up and expand the knowledge on the impact of seaports on regional economies and to highlight the importance of other factors affecting the regional economy that are, at the same time, important for the successful port operations.

In accordance with the defined research problem and the aim of research, a **basic scientific hypothesis** was defined:

Using the scientifically based knowledge about factors influencing regional economic growth, it is possible to propose a new model for assessing the impact of seaports on the economy of the port regions and to provide a better understanding of the importance of seaports in the overall economy.

The following auxiliary hypotheses are defined from the basic hypothesis:

AH1. It is possible to analyze how the efficiency of port operations affects the growth of the region using quantitative methods.

AH2. There is a positive relationship between human capital and regional economic growth.

AH3. Investments in human capital and research and development have a greater impact on the growth of the regional economy than investment in transport infrastructure.

AH4. Trade openness positively affects the regional economic growth of the port regions.

The endogenous growth theory was used as the theoretical framework of research. The theory advocates that changes in individual economic policy variables will permanently affect long-term economic growth rates. The main motive behind the research of long-term growth is to find out why some countries are richer and some are poorer. In general, very small changes in the long-term economic growth rate can cause significant differences in the people's standards of living and it is important to find out what stimulated economic growth. Models of endogenous growth can be classified into three main groups: in one group capital accumulation is a key driver of economic growth (AK models) and it is considered that economies that want to achieve economic growth need to increase the amount of their physical and human capital. In the second group of models, externalities promote growth advocating the accumulation of capital that leads to economic growth as well. The third group of models state that economic growth originates from technological changes resulting from investment in R&D; therefore, the economic growth is a result of human activity.

Newer growth models imply that national policies have an impact on the level and efficiency of accumulation of production factors and thus on equilibrium growth rates, giving a major role to national policies in determining long-term economic growth. Models reject the assumptions about declining yields and convergence which is the basis of the neoclassical models and consider that convergence does not have to happen at all, i.e., rich countries can permanently improve their living standards, while poor countries may forever remain poorly developed. The question is whether economic growth is a result of luck or thoughtful decisions and the selection of different policies. Empirical data is in favor of the other thesis, i.e. that economic growth can be influenced by the selection of optimal policies.

The endogenous growth theory began with the idea of Paul Romer and is also linked to Lucas and Scott. For the first time it advocates the thesis that economic growth is the result of the action of endogenous forces within the economic system. Also, the important difference in regard to classical and neoclassical models is technological progress that is considered endogenous. It is considered that technological advances are result of human labor. For this reason, companies are able to create a monopoly rent and have monopoly power. According to Romer ideas are the main drivers of economic growth because they lead to a greater national product, greater investment and greater accumulation of capital, both physical and human.

Innovations can be defined as developing new ideas or new approaches and can be classified into two types: process innovations and product innovations. Process innovations improve manufacturing processes resulting in lower costs of production. Product innovations are related to the development of new products that meet customer needs. Through innovation process resources gain new features and innovations generate new activities as well as new value creation. This process transforms knowledge into a new value that becomes source of competitiveness on dynamic markets.

Technology improves rapidly and becomes a fundamental catalyst for economic growth. The regions with the highest technological capacity create greater economic benefits associated with changes in production methods and market demand. Therefore, it is considered that the regions that are intensively investing in the development of technologies will grow faster than other regions, not only because of high technology yields, but also because of the effects of multipliers that are created by new innovations. Technological knowledge is not exhausted after use; it is accumulated because it is based on existing knowledge. It also causes overflowing form areas where it was created to other areas.

The European Union (EU) encourages its member states to innovate and has developed a special strategy called the Innovation Union. The aim of the strategy is to encourage member states to invest 3% of their gross domestic product in research and development by 2020, of which 1% is expected to come from the public sector and 2% from the private sector. However, the EU cannot fully compel member states to invest in R&D because investments are mostly related to the national policies of individual countries. As far as seaports are concerned, the European Commission launched an initiative under the program Horizon 2020 called "The Port of the Future" which aims to encourage innovations in seaports.

By analyzing statistical data on investment in R&D of EU member states, the conclusion was made that Sweden, Austria, Denmark and Germany have the highest percenatage of R&D investments. The lowest percentage of investments have Romania, Malta, Latvia and Cyprus. Slovakia has the largest increase in investments in R&D over the ten-year period. Human resources in science and technology are linked to innovations and by analyzing statistical data it is concluded that the most human resources in science and technology are employed in Sweden, Luxembourg and the United Kingdom. On the other hand, they are least employed in Romania, Italy and Portugal while the largest increase in the ten-year period occurred in Portugal, which indicates that Portugal is working on incensement of employment in the scientific and technological sectors. By comparing data from investment in R&D with employment of human resources in science and technology it was concluded that the countries that invest most in R&D at the same time have a high percentage of employment in the scientific and technological sectors.

Literature dealing with economic growth within endogenous growth theory considers human capital, together with the development of new ideas, to be the primary source of economic growth. It is claimed that the level of education promotes growth, as it increases the ability to adapt and apply existing technologies or create new technologies. Theoretical analysis emphasized the strategic complementarity between human capital and research and development activities. Investments in R&D and human capital are considered to be interdependent, complementary and they jointly determine the balance of growth.

Human capital in the segment of innovation and use of new business solutions plays an important role and can become a major factor in increasing competitiveness. New technology needs to be developed and then implemented making it a long-lasting process that is only possible with qualified and educated workforce. The level of education promotes growth by increasing the ability to adapt and apply existing technology or create new technologies. Furthermore, the ability of the region to turn investment in R&D into economic growth depends on the application of human knowledge and the range of socio-economic conditions of the region. Social conditions determine the acceptance of new ideas and technologies. Areas without adequate social abilities to absorb new ideas and to convert them into useful knowledge will not be able to take advantage of innovation investments.

Recently, the term "digital economy" has often been mentioned and is often connected to seaport operations as well. Transition to the digital economy requires specific knowledge and skills. To enable port development engineers to develop and apply the new technology adequately it is necessary to have a qualified workforce who will accept, implement and use the new technology. Employees in advanced and digitalized ports, such as Rotterdam, have to understand the role of data, understand information technology and be able to manage applications. Fundamental competencies that are required in these scenarios are data science, data modeling, forecasting and data analysis. All of the mention competencies require highly educated personnel.

Educational achievements are important for the development and implementation of innovation and for stimulating economic growth. Theoretical analysis confirms the complementary relationship between human capital and the process of R&D. Human capital can be increased throughout life through lifelong learning; however, the specificity is that human capital cannot be bought. It is a process in which people have to cooperate by learning and thus human capital has great value. Developed regions have need for more educated population; therefore, brain drain is a common case where people emigrate from less developed regions to more developed ones. The brain drain is negative for the emigration regions but positive for the immigration regions which receive highly educated population in short time.

Education and increased human capital for individuals lead to higher wages and better living standards. On macroeconomic level they contribute to economic growth. In the EU, the largest share of people with higher education have Ireland, Finland and the United Kingdom, while Romania, Croatia and Slovakia have the smallest share. All member states have increased the share of highly educated people in the total population during the observed ten-year period which is a positive founding. The EU's Human Development Indices were analyzed and Ireland ranked the top of the chart, while Romania was positioned at the bottom. In the R&D and human capital investment segments, the EU member states have different results, but the trend is that if one country is high on the scale for one indicator, it is mostly highly positioned for other indicators as well and vice versa.

Seaports are the starting and finishing point for freight transportation or passengers' transportation by sea. Transportation by sea has two major advantages, and they are the following: it can receive large amounts of freight and is relatively inexpensive. For those reasons most of the world's trade takes place by sea. Seaports connect global and local markets

and are considered to be the logistics centers in which the relevant region is included as well. Freight ports are more frequent than passengers' ports; therefore, the emphasis in this research is on freight ports. As society, economics and technology develop, many of the world's seaports are improving their business in accordance with the changes and that is one of the sources of port competitive advantages. Other than connecting maritime and land transport, seaports have the ability to develop industry within their space, which reduces costs because freight does not have to be transported to industrial complexes. Various participants in the port business are directly or indirectly benefiting from its business, but for the economy it is important that the seaport creates value and new jobs.

European ports are important for the European market because more than half of the goods entering or leaving Europe are transported by sea. The establishment of a European maritime market that includes economic and political integration has had a positive effect on the operations of the ports and increasing their cooperation. Technological advances, globalization, logistics and containerization have contributed to improving the co-operation of European Union ports as well. The European Commission has developed a common transport policy that seeks to improve and develop a European infrastructure involving seaports. The construction of a Trans-European Transport Network (TEN-T) is one of the goals of the common transport policy. The integrated transportation network is expected to enhance cooperation between different ports and link seaports with other modes of transportation to enable faster and more adequate transportation of freight. Furthermore, it is expected to simplify port operations which will lead to new value creation. The EU invests largely in infrastructure resources and this raises the question about its long-term profitability.

Most port users are international companies that bring EU ports closer to the globalization process. More than two-thirds of the maritime freight that was transported in the 20 largest ports of the EU came from countries that are not members of the EU. By analyzing statistical data on freight traffic at EU seaports, it was concluded that the countries with the largest freight traffic are the Netherlands, Spain and the United Kingdom. The lowest freight traffic occurred in Malta, Croatia and Slovenia. The calculated indices indicate that the largest incensement in freight traffic happened in Poland in 2017 compared with 2008 (59.88%), while Croatia had the smallest incensement in freight traffic (28.83%).

By analyzing the freight traffic in the EU's port regions in 2016, it was concluded that the Dutch Zuid-Holland region has the largest freight traffic. This is in line with data provided at the macroeconomic level where the Netherlands has the largest traffic. Port of Rotterdam is part of above mentioned region and it generates the largest freight traffic compared to other EU countries. The German regions of Hessen, Darmstadt, Münster and Arnsberg have the smallest freight traffic. From the perspective of individual ports, port of Rotterdam is predominant in freight traffic with about 11% of total freight traffic in the EU. Second best seaport is the Belgian port of Antwerp, third best is the German port of Hamburg and the fourth is the Dutch port of Amsterdam. Ports that operate with most of the freight coming outside of EU are the ports of London and Trieste, while Constanta, Bremerhaven and Valencia are ports that have more than 50% of freight intended for markets within the EU.

The mismatch between supply and demand is fueling the development of larger container ships that can carry larger amounts of freight. At the same time, ports must adapt to the new trends and modify their capacities for large vessels. The industries involved in the production of various products adapt to the above-mentioned containerization trend and make their products in forms that are suitable for transportation in containers. Care for the environment and sustainable development is a trend that occurs in many business processes as well as in the operations of seaports. Seaports might invest in new technologies that reduce environmental pollution while at the same time they create positive image about their business which can serve as their competitive advantage.

Seaport operations are dynamic, prone to changes and follow-up on new trends associated with investing in new technologies and innovations. Seaport users no longer only require freight transportation; it is also necessary to handle data in most effective way and to apply modern technology. Seaports are adapting to different trends in business such as containerization, the implementation of multimodal traffic, capacity incensement, 5G network application and application of Internet of Things (IoT). Internet of Things is a concept where transfer data sensors can be set up on seaport's equipment which can allow better traffic planning and better business efficiency. Along with Internet of Things there is concept Internet of Vehicles (IoV) where sensors are placed on port vehicles that can be tracked and used for planning optimal transport routes. Autonomous ships are trend that is expected to be more present. Moreover, more frequent employment of highly educated people is expected, especially from the STEM

area. There is a need for cooperation between the ports and the universities in order to provide the ports with the staff required for business.

As in any other business, in seaport operations is important to keep up with trends and apply new solutions and new technologies. The application of new technologies and their development contribute to a quality transport system which is an essential factor in the development of the economy. Globalization and economic growth have positive effects on the environment, generating higher levels of revenue, thus gaining importance to traffic.

The development capabilities of seaports can go in multiple directions and are mostly directed at existing markets, increasing the use of ICT technology in business and creating inland waterways. Synchromodal transport, which uses a variety of transport and handling modes at terminal in parallel, has great potential for future advancement and application. In synchromodal transport different modes of transport, such as maritime, road and rail, should co-operate and act in a coordinated manner to achieve higher speeds of freight transportation, less waiting in line and fewer storage costs.

Seaport development capabilities can also go in the direction of cloud application in business which can enable greater connectivity of the ports and the associated terminals. Cloud technology would allow real-time sharing of information as well as collection and processing of useful data. Furthermore, blockchain technology could be increasingly used in business because of the large number of participants involved in marine operations. It is anticipated that blockchain technology could be used to store and transfer load documentation, to enhance visibility of process information, to improve trade finance that would reduce the time needed for commercial approvals and to automate operations using Internet of Things. The use of drones in the operations of seaports in the segments of gas emission control has already been tested in some seaports and is expected to be further expanded. Drones allow easier and faster access to ships and relatively fast control. They can also be used in the logistics process where smaller package delivery operations and warehouse management can be performed.

The port of Rotterdam is a good example of implementation of innovations and modern technology in business. Rotterdam has some of the largest international companies in their port area that have extremely high demands and therefore often put pressure on Rotterdam to increase excellence and apply new technology solutions. Certain parts of the port of Rotterdam are fully digitized; therefore, workers can operate cranes and other equipment from their offices.

The port is entirely focused on digitization and encourages other business associates to do the same. Port's freight transport can be tracked on the Internet which encourages transparency. Terminals are extremely well connected by road and rail; therefore, they allow for fast freight transportation and minimize the loss of time. Port of Rotterdam is the world's first seaport to use Automated Guided Vehicles (AGV) and the first with automated terminals. Terminal operations in Rotterdam are happening 24 hours a day, 7 days a week, and are equipped with latest, efficient and sustainable equipment. Moreover, the terminals are directly linked to rail, road and inland waterways for quick connections with the rest of the Europe. All of this results in high handling capacity and impressive level of productivity. Rotterdam Port Authority has invested 200 million euros in widening one of the port basins so that the port of Rotterdam can receive largest vessels and is prepared for a future generation of container carriers. All mentioned above results in the high performance of port of Rotterdam which has a positive impact on the regional economy as well.

The economic value of seaports consists of a direct impact on the creation of value and creation of new jobs, as well as indirect and induced impacts arising from the existence of a seaport on a specific area. Seaports enhance the competitiveness of the regions, but at the same time because of the nature of their work, it is very easy to switch business from one port to another. For this reason, seaports must constantly work to improve their competitiveness and strive to provide quality services that will meet the needs of the market. A high level of competition between seaports is often present which contributes to the mobility of freight and the free choice of ports. Enterprises have very low loyalty to seaports and therefore easily transfer freight from one port to another, creating a high price elasticity of demand for seaport services. On the other hand, ports can develop cooperation with other seaports, thus contributing to the competitive position of their own region. If the seaport is better connected to other seaports, it is more difficult to replace it with another one. Port connectivity can allow access to innovations from another area or the use of other ideas and knowledge that enhances its competitive position but also the competitive position of its region.

Tax competition is a special aspect of competition that occurs in the operations of the seaports. The maritime country or the maritime region may positively or negatively affect the seaports' business processes by introducing taxes. The features of the maritime industry are unique and allow the use of more favorable tax policies than other industries. The easy transfer of business from one port to another is in favor of lower taxes, i.e. users will prefer to operate in the area

where the taxes are lower. For this reason, countries are introducing a number of tax supports to boost the maritime industry, such as a special tonnage tax system or a reduced income tax rate for sailors.

The maritime labor market has changed its demands from the majority of low-skilled workers to the higher educated workers. The increasingly common use of technology and information communication systems is also in favor of highly educated people specializing in these areas. The labor market in the port regions has certain characteristics that differentiate them from other regions. Seaports perform specific activities such as loading and unloading of freight, therefore requiring specific workforce. Furthermore, ports attract other economic activities, such as the steel industry, which further encourages other economic activities such as service activities. Therefore, ports may have direct and indirect effects on employment in the region in which they are located. Traditionally, sea-related activities mostly required low-skilled workforce and high level of education wasn't frequently required. However, the emergence of new technologies and automation and the ever more frequent use of the IT sector in administrative work requires a different structure of employees with higher education.

The impacts of seaport operations on the regional economy are mostly positive; however, seaports generate certain negative impacts as well. They create negative externalities because they visually destroy the location's appearance. At the same time they generate a large amount of road traffic that creates congestions in the surrounding areas. A common negative externality is the noise in the vicinity of the seaports and the unsightly visual appearance of the warehouses. Because of this, the real estate prices in the surrounding areas may lose their value and residents might move further from the seaports.

The negative effects of seaport are also connected to effects on environmental pollution, i.e. pollution of air, sea and soil, waste generation and noise generation. The environmental pollution is attempted to limit, control and minimize with the legal frameworks and recommendations. The MARPOL Convention seeks to limit and reduce environmental pollution through its technical annexes. Compliance to MARPOL Convention annexes is compulsory for all participants in maritime sector. On the other hand, seaports can independently decide on improving environmental concerns with introducing changes in existing management and planning. An example is the introduction of the concept of "green port" which implies adopting a new management style, thus developing seaport activities in accordance with well-defined ecological requirements that reduce the negative effects. By

introducing new concepts, seaports, not only take care of the environment, but at the same time provide a positive image of themselves on market which can lead to their competitive advantage.

The importance of seaports can also be seen from the aspect of creating multiplier effects on the associated regional economy. Port operations do not only stimulate the development of the maritime industry but also foster the development of other related and unrelated industries. Seaport activities encourage ports to buy production factors from affiliated companies while at the same time workers in the maritime sector spend their wages on goods and services in the wider economy, thus expanding beyond the port sector itself. Multiplying effects of seaports consist of direct, indirect and induced effects. Direct effects are reflected in income generation, business earnings, and job creation in the region as a result of seaports. Indirect effects include spending seaport's employee's incomes in other sectors, for example, in restaurants or shops in region. This generates additional earnings from workforce, which promotes employment in other sectors. The process can be traced through the second, third and subsequent spending circles. Induced effects are reflected in the improvement of regional transport infrastructure due to the existence of a seaport in that area. The benefits of multiplier effects can be reduced if the process of regional leakage occurs. That is, production factors can be purchased outside the region, thus losing direct benefits. Furthermore, the workforce can be employed from outside areas and if income is spent in other regions, the port regions lose the benefits of multiplication.

The multiplier effects of EU's seaport have been calculated by applying a multiplier that takes into account gross domestic product and employment in the maritime sector. The analysis concludes that for every million euros that the European maritime industry will contribute to the gross domestic product, another 1.59 million euros in the European economy is created. Similarly, for every employee in the maritime industry, new 2.28 jobs are created elsewhere in the European economy. The EU's maritime industry directly contributes to the European gross domestic product with 54 billion euros and creates 640,000 direct jobs. The indirect contribution to gross domestic product amounts to 57 billion euros and 980,000 jobs, while the induced contribution amounts to 29 billion euros in the total gross domestic product and 477,000 jobs. The overall impact on the European economy is considerable and is estimated at 140 billion euros in gross domestic product contribution and 2,097,000 created jobs.

Research about the effects of seaports on regional economies was carried out by a linear panel data analysis. Panel data analysis is a method that is increasingly used in economic research since it can test more complex econometric models and allows for greater data coverage.

Using the dynamic panel data analysis, more precisely by applying the two-step Generalized Method of Moment (GMM), the impact of seaports on regional economies was measured. Data used in research were secondary panel data for 107 port regions in the period from 2005 to 2015 collected from Eurostat. Maritime regions are NUTS 2 classified regions which have quantified freight traffic in seaports. The dependent variable representing the growth of the regional economy was the gross domestic product per capita, while the main independent variable was the freight traffic in seaports. To explore the effect of endogenous growth theory based on R&D, the regression model also included variables human capital and investment in R&D.

The results of the GMM analysis indicate that the seaports have a significant impact on the economic growth of the port regions of the EU. Result indicates that if freight traffic is increased by 10%, the regional gross domestic product per capita will increase by 0.0541% on average. Based on the results presented, it is concluded that there is an impact of freight traffic on regional economic growth which is in line with theoretical assumptions and confirms the auxiliary hypothesis AH1 *(it is possible to analyze how the efficiency of port operations affects the growth of the region using quantitative methods).*

According to the endogenous growth theory based on R&D, creating new ideas is a factor that leads to constant growth of the economy. It is considered that economies that create new ideas will not reach the point of saturation in which stagnation or decline in economic growth occurs. Ideas also lead to avoidance of convergence where it is assumed that the economies that are growing can grow forever. The development of new ideas in the econometric analysis was represented by investment in R&D. Its positive relationship with economic growth was indicated. The region's responsiveness to new investments in R&D and innovation can be linked to good human capital. Innovation and development of new ideas also require the absorption of new knowledge and its implementation; therefore, the econometric model tested the impact of human capital on economic growth. Results of the econometric analysis indicate a positive relationship between human capital and regional economic growth. All mentioned above confirms as confirming the auxiliary hypothesis AH2 *(there is a positive relationship between human capital and regional economic growth).*

The results of econometric analysis fail to identify solid evidence on the relationship between transport infrastructure and economic growth at the regional level. One way of interpreting the results can be that the presence of a good infrastructure level is the result of a successful economy, not its cause. That is, a good transport infrastructure can be a factor that follows the process of regional growth, and it is not its driver. Consideration should also be given to the time lag after which investments in transport infrastructure are beginning to have an impact on the growth of the economy. Hence, the auxiliary hypothesis AH3 *(investments in human capital and research and development have a greater impact on the growth of the regional economy than investment in transport infrastructure)* can be partially confirmed. Results show that human capital has a positive impact on the growth of regional economy as well as investment in R&D; however, the results did not identify evidence of impact of transport infrastructure on economic growth. Auxiliary hypothesis AH4 *(trade openness positively affects the regional economic growth of the port regions)* was also confirmed by testing the model and proved that trade openness is an important factor for the operation of sea ports, since a large part of international trade takes place in seaports.

The above mentioned model and its results confirmed the main hypothesis of the research: *Using the scientifically based knowledge about factors influencing regional economic growth, it is possible to propose a new model for assessing the impact of seaports on the economy of the port regions and to provide a better understanding of the importance of seaports in the overall economy.*

As already mentioned, model testing could not identify the impact of investment in transport infrastructure on the regional economy leading to the need for consideration of certain EU policies which largely invest in transport infrastructure. The most important project is the construction of Trans-European Transport Network (TEN-T). According to the research results, the regional economic growth of the port regions is linked to a combination of investment in R&D, human capital and seaport operations. However, elements such as investment in R&D and development of human capital are often underestimated opposed to investment in transport infrastructure. This occurs not only in the EU but in most of the world. Guidelines for resource redistribution could go in favor of investment in human capital development and investment in R&D as they have been shown to be significant economic growth factors that could ultimately lead to better return of public resources.

Guidelines for further research could be focused not only on the model testing on new sets of data, but also on the introduction of new unincorporated variables affecting economic growth that simultaneously improve the operation of seaports. Recommendations for further research may also go in the direction of grouping port regions according to macroeconomic indicators, comparison of the impact of seaports on developed and less developed regions and their analysis. The grouping of data can also be carried out according to the principle of older and newer EU member states whose results can give an insight into the state of development of seaports and regional economies. Data can also be grouped according to geographic positions of the region where a single set of data would form regions that have access to the Mediterranean Sea and another group of data would form regions that have access to the Atlantic Ocean. This would give more detailed information about the impact of geographic position on the efficiency of seaport operations and the efficiency and development of the port regions themselves.

PRILOZI

Prilog 1. Popis regija korištenih u istraživanju i njihovih kratica

Reg ID	Kratica	Naziv	Zemlja
1	BE21	Prov. Antwerpen	Belgija
2	BE23	Prov. Oost-Vlaanderen	Belgija
3	BE25	Prov. West-Vlaanderen	Belgija
4	BG33	Severoiztochen	Bugarska
5	BG34	Yugoiztochen	Bugarska
6	DK01	Hovedstaden	Danska
7	DK02	Sjælland	Danska
8	DK03	Syddanmark	Danska
9	DK04	Midtjylland	Danska
10	DK05	Nordjylland	Danska
11	DE50	Bremen	Njemačka
12	DE60	Hamburg	Njemačka
13	DE80	Mecklenburg-Vorpommern	Njemačka
14	DE93	Lüneburg	Njemačka
15	DE94	Weser-Ems	Njemačka
16	DEA1	Düsseldorf	Njemačka
17	DEF0	Schleswig-Holstein	Njemačka
18	EE00	Eesti	Estonija
19	IE01	Border, Midland and Western	Irska
20	IE02	Southern and Eastern	Irska
21	ES11	Galicia	Španjolska
22	ES12	Principado de Asturias	Španjolska
23	ES13	Cantabria	Španjolska
24	ES21	País Vasco	Španjolska
25	ES51	Cataluña	Španjolska
26	ES52	Comunidad Valenciana	Španjolska
27	ES53	Illes Balears	Španjolska
28	ES61	Andalucía	Španjolska
29	ES62	Región de Murcia	Španjolska
30	ES63	Ciudad Autónoma de Ceuta (ES)	Španjolska
31	ES64	Ciudad Autónoma de Melilla (ES)	Španjolska
32	ES70	Canarias (ES)	Španjolska
33	FR23	Haute-Normandie	Francuska
34	FR25	Basse-Normandie	Francuska
35	FR30	Nord - Pas-de-Calais	Francuska
36	FR51	Pays de la Loire	Francuska
37	FR52	Bretagne	Francuska

38	FR53	Poitou-Charentes	Francuska
39	FR61	Aquitaine	Francuska
40	FR81	Languedoc-Roussillon	Francuska
41	FR82	Provence-Alpes-Côte d'Azur	Francuska
42	FR83	Corse	Francuska
43	HR03	Jadranska Hrvatska	Hrvatska
44	ITC3	Liguria	Italija
45	ITH3	Veneto	Italija
46	ITH4	Friuli-Venezia Giulia	Italija
47	ITH5	Emilia-Romagna	Italija
48	ITI1	Toscana	Italija
49	ITI3	Marche	Italija
50	ITI4	Lazio	Italija
51	ITF1	Abruzzo	Italija
52	ITF3	Campania	Italija
53	ITF4	Puglia	Italija
54	ITF6	Calabria	Italija
55	ITG1	Sicilia	Italija
56	ITG2	Sardegna	Italija
57	CY00	Kypros	Cipar
58	LV00	Latvija	Latvija
59	LT00	Lietuva	Litva
60	MT00	Malta	Malta
61	NL11	Groningen	Nizozemska
62	NL12	Friesland (NL)	Nizozemska
63	NL32	Noord-Holland	Nizozemska
64	NL33	Zuid-Holland	Nizozemska
65	NL34	Zeeland	Nizozemska
66	NL41	Noord-Brabant	Nizozemska
67	PL42	Zachodniopomorskie	Poljska
68	PL63	Pomorskie	Poljska
69	PT11	Norte	Portugal
70	PT16	Centro (PT)	Portugal
71	PT17	Área Metropolitana de Lisboa	Portugal
72	PT18	Alentejo	Portugal
73	PT20	Região Autónoma dos Açores (PT)	Portugal
74	PT30	Região Autónoma da Madeira (PT)	Portugal
75	RO22	Sud-Est	Rumunjska
76	FI19	Länsi-Suomi	Finska
77	FI1D	Pohjois- ja Itä-Suomi	Finska
78	SE11	Stockholm	Švedska
79	SE12	Östra Mellansverige	Švedska
80	SE21	Småland med öarna	Švedska

81	SE22	Sydsverige	Švedska
82	SE23	Västsverige	Švedska
83	SE31	Norra Mellansverige	Švedska
84	SE32	Mellersta Norrland	Švedska
85	SE33	Övre Norrland	Švedska
86	UKC1	Tees Valley and Durham	UK
87	UKC2	Northumberland and Tyne and Wear	UK
88	UKD3	Greater Manchester	UK
89	UKD4	Lancashire	UK
90	UKE1	East Yorkshire and Northern Lincolnshire	UK
91	UKF3	Lincolnshire	UK
92	UKH1	East Anglia	UK
93	UKH3	Essex	UK
94	UKJ2	Surrey, East and West Sussex	UK
95	UKJ3	Hampshire and Isle of Wight	UK
96	UKJ4	Kent	UK
97	UKK1	Gloucestershire, Wiltshire and Bristol/Bath area	UK
98	UKK2	Dorset and Somerset	UK
99	UKK3	Cornwall and Isles of Scilly	UK
100	UKK4	Devon	UK
101	UKL1	West Wales and The Valleys	UK
102	UKL2	East Wales	UK
103	UKM2	Eastern Scotland	UK
104	UKM3	South Western Scotland	UK
105	UKM5	North Eastern Scotland	UK
106	UKM6	Highlands and Islands	UK
107	UKN0	Northern Ireland (UK)	UK

Prilog 2. Podaci za varijable korišteni u panel analizi

Region ID	Region	Year	GDPpc	*ln* GDPpc	Freight	*ln* Freight	RD	HC	Unempl	Pop	Open	Transport
1	BE21	2005	33900,00	10,43	145817,00	11,89		29,60	6,20	6,90	16,19	0,56
1	BE21	2006	34700,00	10,45	151705,00	11,93	2,18	31,70	5,70	7,10	16,48	0,30
1	BE21	2007	36100,00	10,49	165512,00	12,02	2,12	30,60	5,00	8,90	16,96	0,29
1	BE21	2008	35800,00	10,49	171237,00	12,05	2,16	32,20	4,60	9,00	17,78	0,30
1	BE21	2009	33700,00	10,43	142116,00	11,86	2,19	32,00	5,70	7,90	14,99	0,31
1	BE21	2010	35900,00	10,49	160016,00	11,98	2,44	35,20	6,00	11,30	16,61	0,30
1	BE21	2011	36600,00	10,51	168547,00	12,03	2,64	33,50	5,70	10,00	18,03	0,31
1	BE21	2012	37800,00	10,54	164547,00	12,01	2,65	35,30	5,30	6,30	18,28	0,31
1	BE21	2013	37700,00	10,54	171984,00	12,06	2,69	35,40	6,20	3,90	18,09	0,31
1	BE21	2014	38900,00	10,57	180401,00	12,10	3,00	38,10	6,10	5,70	18,42	0,30
1	BE21	2015	40400,00	10,61	190107,00	12,16	3,16	37,60	6,10	6,50	18,00	0,29
2	BE23	2005	24900,00	10,12	22127,00	10,00		30,10	4,90	6,80	11,89	0,41
2	BE23	2006	25900,00	10,16	24106,00	10,09	1,81	30,60	4,50	6,30	12,30	0,22
2	BE23	2007	27200,00	10,21	24986,00	10,13	1,86	31,30	4,80	7,30	12,78	0,22
2	BE23	2008	26800,00	10,20	26912,00	10,20	2,01	31,50	3,60	8,40	13,31	0,23
2	BE23	2009	26200,00	10,17	20579,00	9,93	2,04	33,80	4,20	8,40	11,65	0,24
2	BE23	2010	27700,00	10,23	27572,00	10,22	2,17	34,70	5,20	9,40	12,82	0,23
2	BE23	2011	28400,00	10,25	27409,00	10,22	2,25	35,10	3,80	6,60	13,99	0,24
2	BE23	2012	29200,00	10,28	25972,00	10,16	2,56	34,90	4,10	4,60	14,12	0,24
2	BE23	2013	29300,00	10,29	25924,00	10,16	2,69	37,30	4,00	5,00	14,06	0,24
2	BE23	2014	30000,00	10,31	28788,00	10,27	2,50	36,70	4,30	5,40	14,21	0,23
2	BE23	2015	31500,00	10,36	26143,00	10,17	2,52	37,50	4,40	6,80	14,04	0,23
3	BE25	2005	26300,00	10,18	36063,00	10,49		28,00	4,70	2,90	12,56	0,44
3	BE25	2006	27700,00	10,23	40562,00	10,61	0,98	28,10	4,20	3,50	13,16	0,24

3	BE25	2007	29100,00	10,28	42924,00	10,67	1,01	28,50	3,00	4,00	13,67	0,24
3	BE25	2008	28400,00	10,25	43128,00	10,67	1,00	29,90	2,70	4,20	14,10	0,24
3	BE25	2009	27300,00	10,21	39269,00	10,58	0,98	29,50	4,30	3,50	12,14	0,25
3	BE25	2010	29000,00	10,28	38771,00	10,57	0,96	30,20	3,80	4,80	13,42	0,24
3	BE25	2011	29700,00	10,30	35029,00	10,46	1,05	31,60	3,20	5,00	14,63	0,25
3	BE25	2012	30800,00	10,34	31974,00	10,37	1,37	32,10	3,90	3,20	14,89	0,25
3	BE25	2013	31000,00	10,34	28802,00	10,27	1,37	32,80	3,90	1,50	14,87	0,26
3	BE25	2014	32300,00	10,38	28170,00	10,25	1,05	33,00	4,20	2,60	15,30	0,25
3	BE25	2015	33200,00	10,41	24931,00	10,12	1,13	32,80	4,20	2,90	14,79	0,24
4	BG33	2005	7500,00	8,92	10250,00	9,24	0,20	19,20	12,10	-5,30	15,57	0,37
4	BG33	2006	8200,00	9,01	9962,00	9,21	0,25	20,00	11,00	-5,20	17,81	0,40
4	BG33	2007	9100,00	9,12	8954,00	9,10	0,19	20,30	10,80	-5,10	19,66	0,53
4	BG33	2008	9800,00	9,19	10638,00	9,27	0,21	20,50	8,60	-5,20	20,02	0,55
4	BG33	2009	8900,00	9,09	8556,00	9,05	0,28	21,20	10,40	-4,20	14,36	0,29
4	BG33	2010	9200,00	9,13	10125,00	9,22	0,21	21,50	14,60	-5,80	15,69	0,52
4	BG33	2011	9600,00	9,17	11665,00	9,36	0,21	22,30	15,40	-4,50	18,09	0,48
4	BG33	2012	10200,00	9,23	11144,00	9,32	0,22	22,50	18,20	-4,70	19,49	0,53
4	BG33	2013	10100,00	9,22	12990,00	9,47	0,33	25,20	16,80	-3,10	20,16	0,50
4	BG33	2014	10800,00	9,29	11577,00	9,36	0,36	27,00	12,60	-4,80	20,68	0,51
4	BG33	2015	11200,00	9,32	11090,00	9,31	0,37	25,40	10,30	-5,80	19,92	0,58
5	BG34	2005	8100,00	9,00	14591,00	9,59	0,08	17,80	8,30	-8,10	16,82	0,40
5	BG34	2006	8200,00	9,01	17551,00	9,77	0,14	17,60	8,10	-7,80	17,81	0,40
5	BG34	2007	8600,00	9,06	15946,00	9,68	0,15	17,70	6,50	-7,50	18,58	0,50
5	BG34	2008	9300,00	9,14	15932,00	9,68	0,17	17,30	5,80	-7,10	19,00	0,52
5	BG34	2009	8900,00	9,09	13337,00	9,50	0,17	16,90	6,60	-6,50	14,36	0,29
5	BG34	2010	9200,00	9,13	12822,00	9,46	0,21	17,40	10,50	-7,90	15,69	0,52
5	BG34	2011	9500,00	9,16	13520,00	9,51	0,14	19,10	11,50	-5,30	17,90	0,47

5	BG34	2012	10200,00	9,23	14868,00	9,61	0,15	19,60	11,90	-4,50	19,49	0,53
5	BG34	2013	10300,00	9,24	15851,00	9,67	0,16	20,50	13,00	-4,00	20,55	0,51
5	BG34	2014	10900,00	9,30	15658,00	9,66	0,26	20,90	11,90	-4,90	20,87	0,51
5	BG34	2015	11300,00	9,33	16076,00	9,69	0,34	21,90	10,40	-5,60	20,10	0,58
6	DK01	2005	36200,00	10,50	14204,00	9,56					24,50	0,47
6	DK01	2006	37000,00	10,52	14620,00	9,59					25,53	0,45
6	DK01	2007	38500,00	10,56	15369,00	9,64	5,12	40,90	4,30	5,50	26,17	0,42
6	DK01	2008	39500,00	10,58	15292,00	9,64	5,21	41,00	3,70	10,00	27,90	0,43
6	DK01	2009	37700,00	10,54	12379,00	9,42	5,30	41,40	6,20	10,80	23,91	0,48
6	DK01	2010	41500,00	10,63	12484,00	9,43	4,86	43,10	7,90	11,30	25,97	0,58
6	DK01	2011	41100,00	10,62	13276,00	9,49	4,96	45,40	8,10	8,90	27,27	0,54
6	DK01	2012	42000,00	10,65	12794,00	9,46	4,98	46,20	8,20	10,10	28,08	0,60
6	DK01	2013	43100,00	10,67	13341,00	9,50	4,73	47,00	7,40	10,00	28,29	0,58
6	DK01	2014	44700,00	10,71	13969,00	9,54	4,64	48,10	7,10	10,60	28,41	0,61
6	DK01	2015	47100,00	10,76	14819,00	9,60	4,59	48,50	6,70	11,80	29,07	0,61
7	DK02	2005	20600,00	9,93	21141,00	9,96					13,94	0,27
7	DK02	2006	22000,00	10,00	23332,00	10,06					15,18	0,27
7	DK02	2007	22500,00	10,02	23234,00	10,05	1,21	26,40	3,60	4,00	15,30	0,24
7	DK02	2008	21900,00	9,99	22291,00	10,01	1,27	26,90	3,40	2,20	15,47	0,24
7	DK02	2009	20900,00	9,95	19775,00	9,89	1,33	27,30	5,30	-0,80	13,26	0,27
7	DK02	2010	22500,00	10,02	20091,00	9,91	1,42	26,80	6,80	-1,00	14,08	0,31
7	DK02	2011	22700,00	10,03	19407,00	9,87	1,34	27,30	7,20	-2,30	15,06	0,30
7	DK02	2012	23200,00	10,05	19216,00	9,86	1,25	27,70	6,40	-1,90	15,51	0,33
7	DK02	2013	23200,00	10,05	20049,00	9,91	1,19	28,80	6,80	0,40	15,23	0,31
7	DK02	2014	24000,00	10,09	21105,00	9,96	1,15	29,00	6,30	4,60	15,25	0,33
7	DK02	2015	25200,00	10,13	28675,00	10,26	1,03	29,80	5,90	8,50	15,55	0,33
8	DK03	2005	25000,00	10,13	30083,00	10,31					16,92	0,32

8	DK03	2006	27200,00	10,21	31951,00	10,37					18,77	0,33
8	DK03	2007	28800,00	10,27	32287,00	10,38	0,84	25,50	3,50	4,10	19,58	0,31
8	DK03	2008	29200,00	10,28	30687,00	10,33	1,40	25,40	3,30	4,20	20,63	0,31
8	DK03	2009	27700,00	10,23	27367,00	10,22	1,96	26,00	6,00	0,50	17,57	0,35
8	DK03	2010	29400,00	10,29	24296,00	10,10	1,52	27,50	7,60	0,30	18,39	0,41
8	DK03	2011	30300,00	10,32	27992,00	10,24	1,49	27,50	7,70	0,60	20,10	0,40
8	DK03	2012	30400,00	10,32	24719,00	10,12	1,62	29,20	7,90	0,10	20,33	0,43
8	DK03	2013	31100,00	10,34	24980,00	10,13	1,75	28,60	7,20	0,90	20,41	0,42
8	DK03	2014	31700,00	10,36	21057,00	9,95	1,78	29,80	6,70	2,70	20,15	0,43
8	DK03	2015	33200,00	10,41	20063,00	9,91	1,88	30,70	6,10	5,00	20,49	0,43
9	DK04	2005	26000,00	10,17	13152,00	9,48					17,60	0,33
9	DK04	2006	28400,00	10,25	14558,00	9,59					19,60	0,34
9	DK04	2007	29500,00	10,29	14887,00	9,61	1,77	28,80	3,30	7,80	20,05	0,32
9	DK04	2008	29800,00	10,30	17000,00	9,74	2,15	29,80	3,20	8,60	21,05	0,32
9	DK04	2009	28500,00	10,26	13361,00	9,50	2,52	31,10	5,80	5,00	18,08	0,36
9	DK04	2010	29300,00	10,29	13211,00	9,49	2,49	31,60	7,20	5,60	18,33	0,41
9	DK04	2011	30400,00	10,32	13903,00	9,54	2,63	30,10	6,70	4,50	20,17	0,40
9	DK04	2012	30200,00	10,32	12718,00	9,45	2,68	31,30	6,80	4,60	20,19	0,43
9	DK04	2013	30600,00	10,33	12391,00	9,42	2,71	33,50	6,50	3,90	20,08	0,41
9	DK04	2014	31000,00	10,34	11543,00	9,35	2,45	33,30	6,10	4,10	19,70	0,42
9	DK04	2015	32800,00	10,40	11657,00	9,36	2,53	34,60	5,60	8,20	20,24	0,43
10	DK05	2005	24300,00	10,10	9372,00	9,15					16,45	0,31
10	DK05	2006	26500,00	10,18	10250,00	9,24					18,29	0,32
10	DK05	2007	27900,00	10,24	9670,00	9,18	1,21	23,50	4,40	3,20	18,97	0,30
10	DK05	2008	28000,00	10,24	9326,00	9,14	1,23	25,30	3,70	2,90	19,78	0,30
10	DK05	2009	26700,00	10,19	7566,00	8,93	1,25	29,20	6,90	-1,50	16,94	0,34
10	DK05	2010	27700,00	10,23	7534,00	8,93	1,24	28,10	7,40	0,30	17,33	0,39

10	DK05	2011	28100,00	10,24	7933,00	8,98	1,35	28,10	8,00	0,30	18,64	0,37
10	DK05	2012	28600,00	10,26	7917,00	8,98	1,40	29,40	7,90	0,50	19,12	0,41
10	DK05	2013	29000,00	10,28	7712,00	8,95	1,41	27,80	6,40	1,40	19,03	0,39
10	DK05	2014	29500,00	10,29	8264,00	9,02	1,50	27,30	6,40	2,70	18,75	0,40
10	DK05	2015	30300,00	10,32	8743,00	9,08	1,50	29,30	6,30	4,90	18,70	0,40
11	DE50	2005	37200,00	10,52	46655,00	10,75	2,13	21,50	16,70	0,40	2,60	0,06
11	DE50	2006	39100,00	10,57	55636,00	10,93	2,14	22,70	14,40	0,80	2,86	0,06
11	DE50	2007	40900,00	10,62	59262,00	10,99	2,14	22,00	11,90	-1,40	2,91	0,06
11	DE50	2008	40700,00	10,61	63501,00	11,06	2,38	24,10	9,60	-1,80	2,95	0,05
11	DE50	2009	36100,00	10,49	53941,00	10,90	2,62	23,80	9,10	-0,20	2,44	0,06
11	DE50	2010	38900,00	10,57	59107,00	10,99	2,67	25,80	7,90	-1,50	2,76	0,06
11	DE50	2011	40600,00	10,61	68782,00	11,14	2,71	28,50	7,70	1,10	2,92	0,06
11	DE50	2012	42400,00	10,65	71820,00	11,18	2,71	27,20	6,60	4,00	3,02	0,06
11	DE50	2013	42400,00	10,65	67059,00	11,11	2,70	26,50	7,00	4,00	2,96	0,06
11	DE50	2014	43800,00	10,69	66442,00	11,10	2,72	26,50	6,60	6,80	2,92	0,05
11	DE50	2015	45800,00	10,73	62465,00	11,04	2,73	26,20	5,60	14,40	2,99	0,05
12	DE60	2005	50900,00	10,84	108253,00	11,59	1,76	25,40	10,50	5,10	3,55	0,08
12	DE60	2006	51600,00	10,85	115529,00	11,66	1,78	26,50	9,90	6,00	3,78	0,08
12	DE60	2007	53600,00	10,89	118190,00	11,68	1,80	26,50	9,00	9,30	3,82	0,07
12	DE60	2008	53900,00	10,89	118915,00	11,69	1,95	27,60	7,10	0,80	3,91	0,07
12	DE60	2009	50600,00	10,83	94762,00	11,46	2,10	29,50	7,20	1,20	3,42	0,08
12	DE60	2010	52800,00	10,87	104520,00	11,56	2,14	30,40	7,00	6,90	3,75	0,08
12	DE60	2011	53600,00	10,89	114370,00	11,65	2,18	32,20	5,30	7,30	3,85	0,08
12	DE60	2012	54500,00	10,91	113531,00	11,64	2,22	31,20	5,30	9,30	3,88	0,07
12	DE60	2013	55800,00	10,93	120568,00	11,70	2,26	31,60	4,70	6,90	3,89	0,07
12	DE60	2014	57500,00	10,96	126004,00	11,74	2,24	33,60	5,00	9,40	3,84	0,07
12	DE60	2015	59500,00	10,99	120172,00	11,70	2,21	34,90	4,30	13,90	3,89	0,07

13	DE80	2005	17700,00	9,78	23520,00	10,07	1,45	26,70	21,40	-7,20	1,24	0,03
13	DE80	2006	18400,00	9,82	25567,00	10,15	1,41	26,10	19,20	-7,90	1,35	0,03
13	DE80	2007	19800,00	9,89	25995,00	10,17	1,36	25,00	17,50	-8,30	1,41	0,03
13	DE80	2008	20100,00	9,91	27250,00	10,21	1,59	26,60	14,70	-9,20	1,46	0,03
13	DE80	2009	19600,00	9,88	22680,00	10,03	1,81	26,50	13,90	-7,90	1,32	0,03
13	DE80	2010	20500,00	9,93	25618,00	10,15	1,93	27,10	12,30	-5,40	1,46	0,03
13	DE80	2011	21500,00	9,98	24342,00	10,10	2,04	27,40	10,10	-4,90	1,55	0,03
13	DE80	2012	21800,00	9,99	22529,00	10,02	1,93	26,70	10,80	-4,10	1,55	0,03
13	DE80	2013	22300,00	10,01	24834,00	10,12	1,82	26,30	10,00	-2,40	1,56	0,03
13	DE80	2014	23000,00	10,04	25564,00	10,15	1,85	24,10	9,60	1,60	1,54	0,03
13	DE80	2015	24000,00	10,09	26513,00	10,19	1,88	25,50	7,80	8,20	1,57	0,03
14	DE93	2005	18800,00	9,84	6817,00	8,83	0,82	17,90	9,70	0,70	1,31	0,03
14	DE93	2006	19600,00	9,88	6679,00	8,81	0,84	18,20	9,00	-0,70	1,43	0,03
14	DE93	2007	20700,00	9,94	7487,00	8,92	0,86	18,00	7,40	-1,10	1,47	0,03
14	DE93	2008	20900,00	9,95	7529,00	8,93	0,90	19,10	6,30	-2,60	1,51	0,03
14	DE93	2009	20000,00	9,90	6440,00	8,77	0,94	20,30	5,40	-1,80	1,35	0,03
14	DE93	2010	21000,00	9,95	7331,00	8,90	0,95	21,30	5,70	-0,80	1,49	0,03
14	DE93	2011	22200,00	10,01	8373,00	9,03	0,96	22,90	5,30	-1,70	1,60	0,03
14	DE93	2012	23000,00	10,04	8413,00	9,04	1,01	22,80	4,40	0,10	1,64	0,03
14	DE93	2013	23000,00	10,04	7842,00	8,97	1,06	23,20	4,30	1,70	1,60	0,03
14	DE93	2014	23600,00	10,07	8127,00	9,00	1,03	21,60	4,00	4,50	1,58	0,03
14	DE93	2015	24400,00	10,10	8010,00	8,99	1,00	23,00	3,50	13,20	1,59	0,03
15	DE94	2005	23400,00	10,06	58892,00	10,98	0,55	17,60	10,20	1,20	1,63	0,04
15	DE94	2006	24700,00	10,11	56467,00	10,94	0,55	18,50	9,30	0,90	1,81	0,04
15	DE94	2007	26300,00	10,18	56400,00	10,94	0,54	18,50	7,10	1,10	1,87	0,04
15	DE94	2008	26800,00	10,20	54670,00	10,91	0,56	19,70	6,20	-1,10	1,94	0,04
15	DE94	2009	25200,00	10,13	46360,00	10,74	0,57	21,00	5,90	-0,70	1,70	0,04

15	DE94	2010	27100,00	10,21	37444,00	10,53	0,65	20,30	5,90	0,80	1,92	0,04
15	DE94	2011	28600,00	10,26	37925,00	10,54	0,73	21,30	4,20	1,00	2,06	0,04
15	DE94	2012	29100,00	10,28	39869,00	10,59	0,76	22,20	4,30	1,80	2,07	0,04
15	DE94	2013	28900,00	10,27	38366,00	10,55	0,78	22,30	4,00	1,70	2,02	0,04
15	DE94	2014	29900,00	10,31	38365,00	10,55	0,86	20,60	4,10	5,90	2,00	0,04
15	DE94	2015	31100,00	10,34	41320,00	10,63	0,94	20,80	3,90	14,30	2,03	0,04
16	DEA1	2005	30700,00	10,33	1673,00	7,42	1,66	20,30	10,60	-2,10	2,14	0,05
16	DEA1	2006	31500,00	10,36	1618,00	7,39	1,66	19,10	9,80	-1,80	2,31	0,05
16	DEA1	2007	34100,00	10,44	2060,00	7,63	1,65	20,50	8,60	-1,70	2,43	0,05
16	DEA1	2008	35000,00	10,46	2074,00	7,64	1,77	21,90	7,40	-3,30	2,54	0,05
16	DEA1	2009	32600,00	10,39	1059,00	6,97	1,89	23,10	7,70	-3,50	2,20	0,05
16	DEA1	2010	33700,00	10,43	1414,00	7,25	1,85	23,00	7,60	-2,10	2,39	0,05
16	DEA1	2011	35100,00	10,47	847,00	6,74	1,81	24,20	6,70	-0,80	2,52	0,05
16	DEA1	2012	35900,00	10,49	908,00	6,81	1,73	24,90	6,50	0,80	2,56	0,05
16	DEA1	2013	36100,00	10,49	1263,00	7,14	1,64	24,60	6,30	1,50	2,52	0,05
16	DEA1	2014	37600,00	10,53	1306,00	7,17	1,69	23,80	6,30	3,80	2,51	0,04
16	DEA1	2015	38400,00	10,56	1440,00	7,27	1,73	24,80	5,90	12,70	2,51	0,04
17	DEF0	2005	23600,00	10,07	33122,00	10,41	1,14	20,90	10,30	1,50	1,65	0,04
17	DEF0	2006	24400,00	10,10	35149,00	10,47	1,16	20,30	9,10	0,50	1,79	0,04
17	DEF0	2007	25200,00	10,13	39988,00	10,60	1,18	20,20	8,00	1,10	1,79	0,03
17	DEF0	2008	25500,00	10,15	41195,00	10,63	1,23	22,40	6,80	-1,10	1,85	0,03
17	DEF0	2009	24200,00	10,09	33977,00	10,43	1,27	22,80	7,30	-0,80	1,63	0,04
17	DEF0	2010	25100,00	10,13	33113,00	10,41	1,34	22,80	6,60	0,80	1,78	0,04
17	DEF0	2011	26100,00	10,17	34148,00	10,44	1,40	24,40	5,80	0,80	1,88	0,04
17	DEF0	2012	27200,00	10,21	34765,00	10,46	1,44	24,90	5,00	1,50	1,94	0,04
17	DEF0	2013	27200,00	10,21	35644,00	10,48	1,48	24,80	4,90	3,40	1,90	0,04
17	DEF0	2014	28100,00	10,24	36216,00	10,50	1,49	23,40	4,60	5,30	1,88	0,03

17	DEF0	2015	29100,00	10,28	34771,00	10,46	1,49	23,80	4,20	9,80	1,90	0,03
18	EE00	2005	14000,00	9,55	45040,00	10,72	0,92	33,20	8,00	-6,00	136,92	2,60
18	EE00	2006	15900,00	9,67	47184,00	10,76	1,12	33,20	5,90	-5,80	137,12	2,80
18	EE00	2007	18100,00	9,80	41458,00	10,63	1,07	33,30	4,60	-3,30	135,27	2,50
18	EE00	2008	17900,00	9,79	32813,00	10,40	1,26	34,20	5,50	-2,00	137,52	2,80
18	EE00	2009	15600,00	9,66	34410,00	10,45	1,40	36,10	13,50	-1,80	116,65	2,70
18	EE00	2010	16500,00	9,71	43599,00	10,68	1,58	35,50	16,70	-2,70	143,80	2,80
18	EE00	2011	18500,00	9,83	45624,00	10,73	2,31	36,90	12,30	-3,30	167,35	2,80
18	EE00	2012	19600,00	9,88	40342,00	10,61	2,12	37,60	10,00	-3,80	170,43	2,80
18	EE00	2013	20100,00	9,91	39298,00	10,58	1,72	37,40	8,60	-3,30	165,79	3,00
18	EE00	2014	20900,00	9,95	39930,00	10,59	1,45	37,60	7,40	-1,90	160,05	3,00
18	EE00	2015	21600,00	9,98	31374,00	10,35	1,49	38,10	6,20	0,80	150,68	3,30
19	IE01	2005	23900,00	10,08	1402,00	7,25	1,39	23,70	4,40	24,10	57,07	0,73
19	IE01	2006	26100,00	10,17	2225,00	7,71	1,23	26,10	4,70	30,20	58,77	0,86
19	IE01	2007	26600,00	10,19	1980,00	7,59	1,17	27,00	5,40	26,30	58,67	0,92
19	IE01	2008	24000,00	10,09	1502,00	7,31	1,27	29,80	7,90	20,50	60,91	1,14
19	IE01	2009	21500,00	9,98	1224,00	7,11	1,58	31,30	14,10	9,50	65,48	0,98
19	IE01	2010	21700,00	9,99	1170,00	7,06	1,63	33,50	15,20	8,30	69,79	1,69
19	IE01	2011	23200,00	10,05	1043,00	6,95	1,58	33,60	16,70	3,40	70,96	0,79
19	IE01	2012	23200,00	10,05	1505,00	7,32	1,64	33,90	17,30	4,10	70,83	0,59
19	IE01	2013	21600,00	9,98	1662,00	7,42	1,69	35,90	15,00	0,50	65,48	0,52
19	IE01	2014	22100,00	10,00	1799,00	7,49		34,80	13,10	2,00	68,09	0,51
19	IE01	2015			1789,00	7,49		36,70	11,20	7,60		
20	IE02	2005	38200,00	10,55	44467,00	10,70	1,15	31,70	4,30	22,90	91,21	1,17
20	IE02	2006	40500,00	10,61	45976,00	10,74	1,19	33,30	4,30	31,10	91,19	1,34
20	IE02	2007	42900,00	10,67	46877,00	10,76	1,25	34,80	4,80	26,90	94,62	1,48
20	IE02	2008	38900,00	10,57	44998,00	10,71	1,41	36,30	6,40	11,80	98,72	1,86

20	IE02	2009	35300,00	10,47	39138,00	10,57	1,62	37,50	12,10	5,00	107,52	1,62
20	IE02	2010	37200,00	10,52	42296,00	10,65	1,59	39,00	14,30	3,40	119,64	2,91
20	IE02	2011	38400,00	10,56	42388,00	10,65	1,53	39,80	14,90	4,30	117,45	1,31
20	IE02	2012	39500,00	10,58	43328,00	10,68	1,52	41,70	14,80	4,60	120,60	1,01
20	IE02	2013	40500,00	10,61	43477,00	10,68	1,50	43,40	13,30	8,10	122,77	0,98
20	IE02	2014	43300,00	10,68	43473,00	10,68		43,10	11,40	10,90	133,41	0,99
20	IE02	2015			46757,00	10,75		44,90	9,50	11,30		
21	ES11	2005	19500,00	9,88	30725,00	10,33	0,84	27,20	9,90	3,50	2,44	0,10
21	ES11	2006	21400,00	9,97	30432,00	10,32	0,86	28,30	8,30	4,00	2,54	0,10
21	ES11	2007	23000,00	10,04	32097,00	10,38	0,99	28,60	7,60	5,00	2,67	0,11
21	ES11	2008	23100,00	10,05	31533,00	10,36	1,00	29,30	8,60	4,60	2,64	0,11
21	ES11	2009	21700,00	9,99	28995,00	10,27	0,92	29,70	12,40	1,80	2,22	0,12
21	ES11	2010	21700,00	9,99	28206,00	10,25	0,93	30,10	15,30	0,30	2,52	0,13
21	ES11	2011	21300,00	9,97	29178,00	10,28	0,94	31,00	17,30	-0,50	2,78	0,11
21	ES11	2012	21200,00	9,96	32368,00	10,38	0,90	31,30	20,50	-3,60	2,87	0,08
21	ES11	2013	21200,00	9,96	29792,00	10,30	0,87	32,10	22,00	-5,40	2,95	0,08
21	ES11	2014	21800,00	9,99	30590,00	10,33	0,89	33,40	21,70	-4,60	3,04	0,08
21	ES11	2015	22900,00	10,04	33127,00	10,41	0,89	35,20	19,30	-5,30	3,08	0,08
22	ES12	2005	20700,00	9,94	26518,00	10,19	0,69	29,80	10,00	0,70	2,59	0,10
22	ES12	2006	22900,00	10,04	26160,00	10,17	0,87	28,70	9,20	1,70	2,71	0,11
22	ES12	2007	24500,00	10,11	26043,00	10,17	0,91	29,00	8,40	5,40	2,85	0,11
22	ES12	2008	24300,00	10,10	24071,00	10,09	0,96	30,60	8,50	4,80	2,78	0,12
22	ES12	2009	22400,00	10,02	18397,00	9,82	1,00	32,10	13,40	0,80	2,30	0,12
22	ES12	2010	22400,00	10,02	20047,00	9,91	1,04	32,80	15,90	-1,10	2,60	0,13
22	ES12	2011	22100,00	10,00	19446,00	9,88	0,97	35,10	17,80	-1,50	2,89	0,11
22	ES12	2012	21700,00	9,99	21507,00	9,98	0,91	35,90	21,80	-6,10	2,94	0,08
22	ES12	2013	21200,00	9,96	21437,00	9,97	0,89	37,70	24,10	-8,30	2,95	0,08

22	ES12	2014	21600,00	9,98	23106,00	10,05	0,83	38,70	21,10	-8,60	3,01	0,08
22	ES12	2015	22800,00	10,03	26165,00	10,17	0,75	39,60	19,10	-8,60	3,07	0,08
23	ES13	2005	22100,00	10,00	6637,00	8,80	0,46	30,60	8,50	11,40	2,76	0,11
23	ES13	2006	23800,00	10,08	5769,00	8,66	0,82	30,60	6,50	12,70	2,82	0,11
23	ES13	2007	25200,00	10,13	6083,00	8,71	0,91	32,30	6,00	15,80	2,93	0,12
23	ES13	2008	24900,00	10,12	5264,00	8,57	1,06	33,40	7,20	12,70	2,85	0,12
23	ES13	2009	23100,00	10,05	4243,00	8,35	1,16	33,80	12,00	6,60	2,37	0,13
23	ES13	2010	22900,00	10,04	4592,00	8,43	1,23	35,70	13,70	4,00	2,66	0,13
23	ES13	2011	22500,00	10,02	4752,00	8,47	1,13	35,20	15,30	2,60	2,94	0,12
23	ES13	2012	22300,00	10,01	4803,00	8,48	1,04	36,10	17,80	-4,00	3,02	0,09
23	ES13	2013	21700,00	9,99	4671,00	8,45	0,94	37,20	20,40	-4,00	3,02	0,08
23	ES13	2014	22600,00	10,03	5007,00	8,52	0,85	37,40	19,40	-4,00	3,15	0,08
23	ES13	2015	23400,00	10,06	5299,00	8,58	0,84	38,10	17,60	-4,90	3,15	0,08
24	ES21	2005	29300,00	10,29	36939,00	10,52	1,47	40,80	7,40	5,90	3,67	0,15
24	ES21	2006	32100,00	10,38	41056,00	10,62	1,57	41,80	7,20	7,00	3,80	0,15
24	ES21	2007	34000,00	10,43	41807,00	10,64	1,87	42,40	6,20	7,80	3,95	0,16
24	ES21	2008	34000,00	10,43	41264,00	10,63	1,99	41,70	6,60	6,80	3,89	0,17
24	ES21	2009	31600,00	10,36	33851,00	10,43	2,07	43,30	11,30	2,50	3,24	0,17
24	ES21	2010	31700,00	10,36	36130,00	10,49	1,99	43,70	10,70	1,70	3,69	0,18
24	ES21	2011	31500,00	10,36	33554,00	10,42	2,14	44,50	12,40	0,70	4,12	0,16
24	ES21	2012	31800,00	10,37	30451,00	10,32	2,24	46,00	15,60	-3,50	4,31	0,12
24	ES21	2013	31400,00	10,35	31289,00	10,35	2,12	46,80	16,60	-4,50	4,38	0,11
24	ES21	2014	32700,00	10,40	32917,00	10,40	2,04	47,00	16,30	-1,00	4,56	0,12
24	ES21	2015	34400,00	10,45	34787,00	10,46	1,91	47,80	14,80	-0,50	4,63	0,12
25	ES51	2005	27800,00	10,23	67283,00	11,12	1,32	30,00	6,90	20,20	3,48	0,14
25	ES51	2006	30100,00	10,31	68974,00	11,14	1,38	29,80	6,50	19,90	3,57	0,14
25	ES51	2007	31600,00	10,36	76423,00	11,24	1,43	29,20	6,50	22,10	3,67	0,15

25	ES51	2008	30800,00	10,34	73558,00	11,21	1,57	29,90	8,90	15,70	3,52	0,15
25	ES51	2009	28700,00	10,26	68677,00	11,14	1,63	30,60	16,20	4,90	2,94	0,16
25	ES51	2010	28600,00	10,26	66774,00	11,11	1,59	31,40	17,70	4,00	3,33	0,17
25	ES51	2011	28200,00	10,25	67203,00	11,12	1,55	32,20	19,20	2,90	3,68	0,15
25	ES51	2012	28300,00	10,25	66789,00	11,11	1,53	32,80	22,50	-4,50	3,83	0,11
25	ES51	2013	28200,00	10,25	62033,00	11,04	1,53	34,80	23,10	-8,70	3,93	0,10
25	ES51	2014	29400,00	10,29	72405,00	11,19	1,49	37,00	20,30	-2,60	4,10	0,10
25	ES51	2015	30900,00	10,34	72081,00	11,19	1,52	37,50	18,60	1,50	4,15	0,11
26	ES52	2005	21600,00	9,98	51843,00	10,86	0,96	26,10	8,90	24,60	2,70	0,11
26	ES52	2006	23300,00	10,06	57064,00	10,95	0,93	26,50	8,30	25,40	2,76	0,11
26	ES52	2007	24300,00	10,10	61948,00	11,03	0,93	26,30	8,70	26,00	2,82	0,11
26	ES52	2008	23800,00	10,08	65896,00	11,10	1,03	26,60	12,00	10,70	2,72	0,12
26	ES52	2009	21800,00	9,99	61388,00	11,02	1,09	26,70	20,80	1,70	2,23	0,12
26	ES52	2010	21600,00	9,98	67073,00	11,11	1,06	28,40	22,90	1,90	2,51	0,12
26	ES52	2011	21300,00	9,97	68872,00	11,14	1,04	29,80	24,00	2,10	2,78	0,11
26	ES52	2012	21000,00	9,95	68559,00	11,14	1,05	30,10	27,20	-4,50	2,84	0,08
26	ES52	2013	20900,00	9,95	68853,00	11,14	1,05	30,80	28,00	-6,20	2,91	0,08
26	ES52	2014	21800,00	9,99	72257,00	11,19	1,04	32,00	25,80	-3,40	3,04	0,08
26	ES52	2015	23000,00	10,04	76548,00	11,25	1,00	32,50	22,80	-1,50	3,09	0,08
27	ES53	2005	26100,00	10,17	12756,00	9,45	0,27	20,80	7,20	31,60	3,27	0,13
27	ES53	2006	27800,00	10,23	13066,00	9,48	0,29	23,10	6,40	35,30	3,29	0,13
27	ES53	2007	28700,00	10,26	9071,00	9,11	0,33	21,20	7,20	36,80	3,33	0,13
27	ES53	2008	28000,00	10,24	8198,00	9,01	0,36	20,80	10,20	25,80	3,20	0,14
27	ES53	2009	25700,00	10,15	7279,00	8,89	0,38	22,10	17,90	12,50	2,63	0,14
27	ES53	2010	25300,00	10,14	6961,00	8,85	0,42	22,60	20,10	7,30	2,94	0,15
27	ES53	2011	25100,00	10,13	6682,00	8,81	0,37	23,70	21,90	8,30	3,28	0,13
27	ES53	2012	25200,00	10,13	6871,00	8,84	0,35	24,80	23,20	8,50	3,41	0,10

27	ES53	2013	24900,00	10,12	6656,00	8,80	0,34	26,80	22,30	5,10	3,47	0,09
27	ES53	2014	26000,00	10,17	7179,00	8,88	0,32	27,90	20,00	8,10	3,62	0,09
27	ES53	2015	27000,00	10,20	7510,00	8,92	0,33	27,20	17,30	9,30	3,63	0,10
28	ES61	2005	18300,00	9,81	95155,00	11,46	0,81	23,00	13,80	17,30	2,29	0,09
28	ES61	2006	19700,00	9,89	100523,00	11,52	0,87	23,20	12,60	15,20	2,33	0,09
28	ES61	2007	20800,00	9,94	103219,00	11,54	0,99	24,10	12,80	16,40	2,42	0,10
28	ES61	2008	20300,00	9,92	97360,00	11,49	1,01	24,70	17,70	11,60	2,32	0,10
28	ES61	2009	18800,00	9,84	83105,00	11,33	1,08	25,20	25,20	7,60	1,93	0,10
28	ES61	2010	18500,00	9,83	88707,00	11,39	1,18	25,70	27,80	6,80	2,15	0,11
28	ES61	2011	18300,00	9,81	110518,00	11,61	1,14	25,80	30,10	5,50	2,39	0,09
28	ES61	2012	18100,00	9,80	119718,00	11,69	1,06	26,50	34,40	1,80	2,45	0,07
28	ES61	2013	17800,00	9,79	110190,00	11,61	1,07	27,30	36,20	-0,50	2,48	0,06
28	ES61	2014	18300,00	9,81	120378,00	11,70	1,06	27,60	34,80	1,30	2,55	0,06
28	ES61	2015	19200,00	9,86	125905,00	11,74	1,03	28,30	31,50	0,50	2,58	0,07
29	ES62	2005	19700,00	9,89	29405,00	10,29	0,71	22,90	8,00	28,20	2,46	0,10
29	ES62	2006	21300,00	9,97	28285,00	10,25	0,74	23,30	7,90	25,30	2,52	0,10
29	ES62	2007	22400,00	10,02	26576,00	10,19	0,88	23,70	7,50	24,10	2,60	0,10
29	ES62	2008	22200,00	10,01	27918,00	10,24	0,84	24,90	12,40	15,50	2,54	0,11
29	ES62	2009	20300,00	9,92	22329,00	10,01	0,87	24,40	20,30	8,10	2,08	0,11
29	ES62	2010	20200,00	9,91	20958,00	9,95	0,92	24,40	22,90	3,80	2,35	0,12
29	ES62	2011	19700,00	9,89	24560,00	10,11	0,86	25,30	25,00	2,00	2,57	0,10
29	ES62	2012	19800,00	9,89	31924,00	10,37	0,86	26,30	27,60	0,00	2,68	0,08
29	ES62	2013	19700,00	9,89	31026,00	10,34	0,85	28,20	29,00	-0,10	2,75	0,07
29	ES62	2014	20100,00	9,91	33994,00	10,43	0,88	27,10	26,60	1,30	2,80	0,07
29	ES62	2015	21000,00	9,95	34092,00	10,44	0,89	27,90	24,60	1,80	2,82	0,08
30	ES63	2005	20300,00	9,92	1533,00	7,33	0,11	22,90	19,40	11,50	2,54	0,10
30	ES63	2006	21900,00	9,99	1919,00	7,56	0,16	17,70	21,50	18,40	2,59	0,10

30	ES63	2007	22900,00	10,04	1544,00	7,34	0,14	16,60	21,00	14,60	2,66	0,11
30	ES63	2008	22600,00	10,03	1634,00	7,40	0,15	21,50	17,40	22,00	2,59	0,11
30	ES63	2009	21300,00	9,97	1668,00	7,42	0,16	23,20	18,50	30,30	2,18	0,12
30	ES63	2010	20700,00	9,94	1454,00	7,28	0,09	20,70	23,90	28,90	2,41	0,12
30	ES63	2011	20200,00	9,91	1545,00	7,34	0,08	18,90	27,70	26,90	2,64	0,10
30	ES63	2012	19800,00	9,89	1554,00	7,35	0,07	22,00	37,00	8,20	2,68	0,08
30	ES63	2013	20100,00	9,91	1351,00	7,21	0,06	23,00	34,80	1,60	2,80	0,07
30	ES63	2014	20200,00	9,91	1217,00	7,10	0,07	22,50	31,90	0,20	2,81	0,07
30	ES63	2015	21100,00	9,96	1074,00	6,98	0,06	28,10	27,60	-0,50	2,84	0,08
31	ES64	2005	20100,00	9,91	802,00	6,69	0,17	28,10	14,30	33,30	2,51	0,10
31	ES64	2006	21400,00	9,97	522,00	6,26	0,23	27,80	13,60	27,30	2,54	0,10
31	ES64	2007	21800,00	9,99	512,00	6,24	0,29	22,80	18,20	32,50	2,53	0,10
31	ES64	2008	21300,00	9,97	482,00	6,18	0,28	24,00	20,00	29,30	2,44	0,10
31	ES64	2009	20000,00	9,90	528,00	6,27	0,28	26,60	23,50	35,90	2,05	0,11
31	ES64	2010	19400,00	9,87	528,00	6,27	0,15	22,90	22,80	36,40	2,26	0,11
31	ES64	2011	18800,00	9,84	555,00	6,32	0,13	27,10	22,40	36,40	2,46	0,10
31	ES64	2012	18100,00	9,80	604,00	6,40	0,14	24,80	26,90	22,10	2,45	0,07
31	ES64	2013	18200,00	9,81	588,00	6,38	0,13	26,20	32,50	3,00	2,54	0,07
31	ES64	2014	18500,00	9,83	593,00	6,39	0,13	28,80	28,40	8,30	2,58	0,07
31	ES64	2015	19100,00	9,86	601,00	6,40	0,07	28,00	34,00	2,30	2,57	0,07
32	ES70	2005	21600,00	9,98	31474,00	10,36	0,58	24,50	11,70	24,80	2,70	0,11
32	ES70	2006	22900,00	10,04	31974,00	10,37	0,65	23,70	11,60	24,20	2,71	0,11
32	ES70	2007	23800,00	10,08	33185,00	10,41	0,64	24,60	10,50	23,30	2,76	0,11
32	ES70	2008	23100,00	10,05	33740,00	10,43	0,63	23,10	17,20	16,70	2,64	0,11
32	ES70	2009	21200,00	9,96	28161,00	10,25	0,59	23,60	26,00	9,70	2,17	0,12
32	ES70	2010	21100,00	9,96	27712,00	10,23	0,62	23,90	28,60	9,60	2,45	0,12
32	ES70	2011	20900,00	9,95	30173,00	10,31	0,59	24,10	29,30	10,20	2,73	0,11

32	ES70	2012	20700,00	9,94	29816,00	10,30	0,53	26,00	32,60	9,20	2,80	0,08
32	ES70	2013	20400,00	9,92	25707,00	10,15	0,51	27,30	33,70	4,60	2,84	0,07
32	ES70	2014	20800,00	9,94	24409,00	10,10	0,49	27,00	32,40	5,30	2,90	0,07
32	ES70	2015	21500,00	9,98	25570,00	10,15	0,49	26,60	29,10	4,30	2,89	0,08
33	FR23	2005	23500,00	10,06	93392,00	11,44	1,44	18,40	7,70	2,40	2,17	0,08
33	FR23	2006	24100,00	10,09	94568,00	11,46	1,33	18,50	8,80	3,10	2,23	0,08
33	FR23	2007	25500,00	10,15	97431,00	11,49	1,33	20,00	8,60	4,90	2,28	0,08
33	FR23	2008	24200,00	10,09	99350,00	11,51	1,37	19,00	8,40	4,00	2,26	0,07
33	FR23	2009	22900,00	10,04	94027,00	11,45	1,42	19,20	10,00	2,20	1,97	0,07
33	FR23	2010	23800,00	10,08	93282,00	11,44	1,39	21,80	9,70	1,30	2,16	0,07
33	FR23	2011	24700,00	10,11	89208,00	11,40	1,27	23,70	8,90	3,30	2,33	0,08
33	FR23	2012	24800,00	10,12	80881,00	11,30	1,35	26,00	10,90	2,20	2,36	0,08
33	FR23	2013	25300,00	10,14	87631,00	11,38	1,43	25,20	11,60	3,60	2,37	0,08
33	FR23	2014	25600,00	10,15	84110,00	11,34		24,70	11,90	1,80	2,38	0,08
33	FR23	2015	26400,00	10,18	86565,00	11,37		27,70	10,60	1,60	2,41	0,07
34	FR25	2005	21900,00	9,99	3839,00	8,25		20,60	7,70	3,00	2,02	0,07
34	FR25	2006	22600,00	10,03	3906,00	8,27	0,97	21,50	7,20	3,20	2,09	0,07
34	FR25	2007	23400,00	10,06	4006,00	8,30	1,02	22,10	5,60	4,10	2,09	0,07
34	FR25	2008	22500,00	10,02	3601,00	8,19	1,09	24,60	6,30	2,40	2,10	0,07
34	FR25	2009	21500,00	9,98	2955,00	7,99	1,04	25,00	6,90	1,80	1,85	0,07
34	FR25	2010	22200,00	10,01	3438,00	8,14	1,17	24,70	8,20	1,50	2,01	0,07
34	FR25	2011	23000,00	10,04	3215,00	8,08	1,24	24,70	9,20	1,00	2,17	0,07
34	FR25	2012	22800,00	10,03	2818,00	7,94	1,30	25,30	8,80	1,00	2,17	0,07
34	FR25	2013	23300,00	10,06	3032,00	8,02	1,27	25,80	9,10	0,50	2,18	0,08
34	FR25	2014	23500,00	10,06	2652,00	7,88		24,40	8,20	0,10	2,19	0,07
34	FR25	2015	24400,00	10,10	2820,00	7,94		26,80	8,20	-0,50	2,23	0,07
35	FR30	2005	20900,00	9,95	66686,00	11,11	0,65	19,70	12,80	0,80	1,93	0,07

35	FR30	2006	21900,00	9,99	70253,00	11,16	0,65	20,90	12,00	0,80	2,03	0,07
35	FR30	2007	22900,00	10,04	69910,00	11,15	0,63	22,20	11,30	0,70	2,05	0,07
35	FR30	2008	22700,00	10,03	69145,00	11,14	0,75	22,80	11,00	2,20	2,12	0,07
35	FR30	2009	21600,00	9,98	56836,00	10,95	0,79	24,40	13,10	1,20	1,86	0,07
35	FR30	2010	22100,00	10,00	55138,00	10,92	0,88	26,00	12,50	1,00	2,01	0,07
35	FR30	2011	23000,00	10,04	59553,00	10,99	0,81	25,40	12,30	2,20	2,17	0,07
35	FR30	2012	22800,00	10,03	57155,00	10,95	0,89	26,10	13,10	2,50	2,17	0,07
35	FR30	2013	23400,00	10,06	56366,00	10,94	0,91	27,60	14,70	3,80	2,19	0,08
35	FR30	2014	23900,00	10,08	59824,00	11,00		29,00	13,80	0,40	2,22	0,07
35	FR30	2015	24900,00	10,12	56908,00	10,95		27,80	14,00	1,30	2,28	0,07
36	FR51	2005	23700,00	10,07	34015,00	10,43	0,89	21,80	7,20	10,20	2,19	0,08
36	FR51	2006	24300,00	10,10	33863,00	10,43	0,92	22,40	6,90	9,30	2,25	0,08
36	FR51	2007	25400,00	10,14	33299,00	10,41	0,90	22,40	5,90	7,90	2,27	0,08
36	FR51	2008	25000,00	10,13	32918,00	10,40	0,96	22,60	6,10	8,20	2,34	0,08
36	FR51	2009	23600,00	10,07	29297,00	10,29	1,19	26,40	7,60	9,10	2,03	0,08
36	FR51	2010	24100,00	10,09	30582,00	10,33	1,16	26,40	8,50	8,30	2,19	0,08
36	FR51	2011	25300,00	10,14	30943,00	10,34	1,12	27,10	8,50	8,70	2,38	0,08
36	FR51	2012	25300,00	10,14	30196,00	10,32	1,22	27,50	8,40	7,70	2,41	0,08
36	FR51	2013	25800,00	10,16	27561,00	10,22	1,23	28,20	8,80	8,20	2,42	0,08
36	FR51	2014	26300,00	10,18	26809,00	10,20		30,40	8,60	7,50	2,45	0,08
36	FR51	2015	27400,00	10,22	25807,00	10,16		32,30	9,10	6,50	2,50	0,08
37	FR52	2005	23300,00	10,06	6595,00	8,79	1,50	27,10	6,70	9,10	2,15	0,08
37	FR52	2006	24100,00	10,09	6613,00	8,80	1,49	27,70	7,30	8,30	2,23	0,08
37	FR52	2007	24700,00	10,11	7236,00	8,89	1,59	30,20	6,70	9,40	2,21	0,07
37	FR52	2008	23500,00	10,06	7341,00	8,90	1,70	27,80	5,20	8,00	2,20	0,07
37	FR52	2009	22200,00	10,01	6634,00	8,80	1,81	27,90	5,60	7,50	1,91	0,07
37	FR52	2010	22700,00	10,03	7227,00	8,89	1,88	27,90	6,80	5,80	2,06	0,07

37	FR52	2011	23600,00	10,07	11379,00	9,34	1,88	30,00	7,10	6,00	2,22	0,07
37	FR52	2012	23700,00	10,07	6646,00	8,80	1,99	31,90	8,00	6,70	2,25	0,07
37	FR52	2013	24200,00	10,09	8219,00	9,01	2,01	33,30	8,00	5,50	2,27	0,08
37	FR52	2014	24800,00	10,12	8376,00	9,03		33,60	7,40	5,30	2,31	0,08
37	FR52	2015	25900,00	10,16	6475,00	8,78		32,80	7,80	4,70	2,37	0,07
38	FR53	2005	21700,00	9,99	6881,00	8,84	0,78	19,70	8,40	7,50	2,01	0,07
38	FR53	2006	22300,00	10,01	7275,00	8,89	0,80	21,90	7,70	9,00	2,06	0,07
38	FR53	2007	23400,00	10,06	6496,00	8,78	0,74	19,10	6,50	7,40	2,09	0,07
38	FR53	2008	22000,00	10,00	7845,00	8,97	0,80	19,90	7,00	4,50	2,06	0,07
38	FR53	2009	21200,00	9,96	7499,00	8,92	0,88	20,90	8,40	5,50	1,82	0,07
38	FR53	2010	21900,00	9,99	8418,00	9,04	0,89	23,00	7,70	4,20	1,99	0,07
38	FR53	2011	22800,00	10,03	8701,00	9,07	0,82	21,80	8,10	3,50	2,15	0,07
38	FR53	2012	23100,00	10,05	8632,00	9,06	0,88	22,80	8,30	3,20	2,20	0,07
38	FR53	2013	23500,00	10,06	9698,00	9,18	0,93	23,20	9,90	4,40	2,20	0,08
38	FR53	2014	24000,00	10,09	10139,00	9,22		26,00	10,90	2,90	2,23	0,07
38	FR53	2015	25200,00	10,13	10519,00	9,26		26,50	9,70	2,40	2,30	0,07
39	FR61	2005	23500,00	10,06	12459,00	9,43	1,38	21,80	7,30	10,20	2,17	0,08
39	FR61	2006	24500,00	10,11	11583,00	9,36	1,19	22,70	7,50	9,90	2,27	0,08
39	FR61	2007	25400,00	10,14	12580,00	9,44	1,18	23,70	6,90	8,40	2,27	0,08
39	FR61	2008	24200,00	10,09	12652,00	9,45	1,31	24,30	7,10	8,90	2,26	0,07
39	FR61	2009	23400,00	10,06	12953,00	9,47	1,51	27,00	8,30	8,10	2,01	0,08
39	FR61	2010	24200,00	10,09	12857,00	9,46	1,53	29,00	8,10	6,70	2,20	0,08
39	FR61	2011	25200,00	10,13	12008,00	9,39	1,46	26,80	9,00	9,70	2,37	0,08
39	FR61	2012	25200,00	10,13	11362,00	9,34	1,57	27,40	9,40	9,40	2,40	0,08
39	FR61	2013	25300,00	10,14	11640,00	9,36	1,60	29,00	8,90	7,90	2,37	0,08
39	FR61	2014	25600,00	10,15	11004,00	9,31		32,70	9,00	8,10	2,38	0,08
39	FR61	2015	26600,00	10,19	10565,00	9,27		33,40	9,80	7,60	2,43	0,07

40	FR81	2005	20300,00	9,92	6031,00	8,70	2,25	23,50	11,50	14,50	1,88	0,07
40	FR81	2006	21100,00	9,96	5590,00	8,63	2,46	23,30	10,90	10,50	1,95	0,07
40	FR81	2007	21900,00	9,99	5144,00	8,55	2,48	26,20	10,10	8,10	1,96	0,07
40	FR81	2008	21500,00	9,98	4876,00	8,49	2,50	26,60	9,40	11,20	2,01	0,07
40	FR81	2009	20800,00	9,94	4731,00	8,46	2,73	26,00	13,30	9,70	1,79	0,07
40	FR81	2010	21200,00	9,96	5350,00	8,58	2,52	25,20	13,70	12,70	1,92	0,07
40	FR81	2011	21800,00	9,99	5603,00	8,63	2,24	26,10	11,90	11,30	2,05	0,07
40	FR81	2012	21700,00	9,99	5390,00	8,59	2,31	26,70	15,00	10,80	2,06	0,07
40	FR81	2013	21700,00	9,99	5249,00	8,57	2,39	29,00	12,90	8,00	2,03	0,07
40	FR81	2014	22100,00	10,00	4913,00	8,50		31,40	12,30	9,60	2,06	0,07
40	FR81	2015	22800,00	10,03	5125,00	8,54		31,40	12,90	8,80	2,08	0,06
41	FR82	2005	24800,00	10,12	93308,00	11,44	1,79	23,70	10,10	9,70	2,29	0,08
41	FR82	2006	25700,00	10,15	96512,00	11,48	1,74	24,10	11,00	10,10	2,38	0,08
41	FR82	2007	26400,00	10,18	92561,00	11,44	1,88	24,40	9,00	3,90	2,36	0,08
41	FR82	2008	25500,00	10,15	93086,00	11,44	1,91	25,20	7,80	1,30	2,38	0,08
41	FR82	2009	24700,00	10,11	80887,00	11,30	2,01	26,60	9,20	2,10	2,12	0,08
41	FR82	2010	26100,00	10,17	82675,00	11,32	2,04	27,50	9,70	3,40	2,37	0,08
41	FR82	2011	26600,00	10,19	85292,00	11,35	2,00	30,20	9,70	4,00	2,51	0,08
41	FR82	2012	27200,00	10,21	82805,00	11,32	2,23	31,10	9,60	3,70	2,59	0,08
41	FR82	2013	27300,00	10,21	77243,00	11,25	2,49	33,20	10,90	6,00	2,56	0,09
41	FR82	2014	27600,00	10,23	75564,00	11,23		34,90	10,10	4,50	2,57	0,08
41	FR82	2015	28500,00	10,26	78648,00	11,27		35,60	11,00	3,70	2,61	0,08
42	FR83	2005	20100,00	9,91			0,22	12,20	10,20	17,20	1,86	0,07
42	FR83	2006	21100,00	9,96	2100,00	7,65	0,21	26,70	10,70	17,20	1,95	0,07
42	FR83	2007	21600,00	9,98	3188,00	8,07	0,24	18,20	11,10	12,50	1,93	0,07
42	FR83	2008	21900,00	9,99	4127,00	8,33	0,23	11,50	7,90	8,90	2,05	0,07
42	FR83	2009	22000,00	10,00	4351,00	8,38	0,29	14,40		13,10	1,89	0,07

42	FR83	2010	22700,00	10,03	2423,00	7,79	0,30	17,60	6,00	15,40	2,06	0,07
42	FR83	2011	23400,00	10,06	1717,00	7,45	0,36	18,00		5,60	2,21	0,07
42	FR83	2012	23400,00	10,06	1544,00	7,34	0,29	23,10	7,90	12,40	2,23	0,07
42	FR83	2013	23800,00	10,08	2184,00	7,69	0,29	23,10	12,30	12,40	2,23	0,08
42	FR83	2014	24100,00	10,09	2151,00	7,67		24,10	9,90	9,70	2,24	0,07
42	FR83	2015	24500,00	10,11	2252,00	7,72		31,50	8,50	9,10	2,24	0,07
43	HR03	2005	12900,00	9,46	19816,00	9,89				4,90	42,10	2,03
43	HR03	2006	14000,00	9,55	18588,00	9,83				5,10	42,17	1,96
43	HR03	2007	15800,00	9,67	23739,00	10,07		17,20	9,20	3,60	42,35	2,38
43	HR03	2008	16000,00	9,68	24351,00	10,10	0,27	17,80	8,70	2,10	41,58	2,30
43	HR03	2009	14700,00	9,60	19102,00	9,86	0,27	19,20	9,60	0,70	35,37	2,24
43	HR03	2010	14500,00	9,58	19033,00	9,85	0,24	21,10	11,10	-1,80	36,68	1,60
43	HR03	2011	14900,00	9,61	16485,00	9,71	0,31	19,80	13,30	-2,00	39,09	1,45
43	HR03	2012	15300,00	9,64	14839,00	9,61	0,30	20,30	14,80	-2,00	39,99	1,50
43	HR03	2013	15300,00	9,64	14591,00	9,59	0,42	21,20	15,00	-1,30	41,30	1,55
43	HR03	2014	15600,00	9,66	13977,00	9,55	0,37	22,30	17,20	-2,60	43,20	1,32
43	HR03	2015	16000,00	9,68	15287,00	9,63	0,34	24,60	16,80	-5,70	45,39	1,02
44	ITC3	2005	27800,00	10,23	70532,00	11,16	1,11	14,50	5,80	-0,70	2,62	0,11
44	ITC3	2006	29000,00	10,28	74856,00	11,22	1,08	14,60	4,80	-1,00	2,81	0,15
44	ITC3	2007	31000,00	10,34	80871,00	11,30	1,05	16,10	4,80	0,50	2,97	0,11
44	ITC3	2008	31300,00	10,35	79719,00	11,29	1,09	17,60	5,40	2,50	2,99	0,11
44	ITC3	2009	29100,00	10,28	73170,00	11,20	1,26	18,60	5,80	-0,50	2,46	0,12
44	ITC3	2010	29000,00	10,28	70226,00	11,16	1,37	18,40	6,60	-1,50	2,77	0,11
44	ITC3	2011	29700,00	10,30	71850,00	11,18	1,34	17,90	6,40	-4,30	2,95	0,11
44	ITC3	2012	29700,00	10,30	69359,00	11,15	1,35	18,80	8,10	-1,40	2,97	0,10
44	ITC3	2013	29000,00	10,28	66540,00	11,11	1,32	20,00	9,80	17,00	2,94	0,10
44	ITC3	2014	29700,00	10,30	66330,00	11,10	1,37	19,30	10,80	-5,50	3,00	0,09

44	ITC3	2015	31000,00	10,34	67949,00	11,13	1,45	19,70	9,20	-7,70	3,07	0,09
45	ITH3	2005	28800,00	10,27	33082,00	10,41	0,57	11,20	4,20	6,90	2,71	0,11
45	ITH3	2006	30000,00	10,31	34886,00	10,46	0,71	11,40	4,10	5,70	2,90	0,16
45	ITH3	2007	31300,00	10,35	34933,00	10,46	0,84	12,20	3,40	11,40	3,00	0,11
45	ITH3	2008	30800,00	10,34	32985,00	10,40	1,03	13,00	3,40	9,20	2,94	0,11
45	ITH3	2009	28800,00	10,27	30423,00	10,32	1,08	13,10	4,70	3,00	2,44	0,12
45	ITH3	2010	29400,00	10,29	34382,00	10,45	1,04	13,90	5,70	2,10	2,81	0,11
45	ITH3	2011	30300,00	10,32	34705,00	10,45	1,03	14,10	4,90	0,40	3,01	0,11
45	ITH3	2012	30200,00	10,32	30786,00	10,33	1,06	13,80	6,40	5,80	3,02	0,10
45	ITH3	2013	29800,00	10,30	29438,00	10,29	1,12	14,90	7,60	9,20	3,02	0,10
45	ITH3	2014	30300,00	10,32	22046,00	10,00	1,07	15,40	7,50	0,20	3,06	0,09
45	ITH3	2015	31600,00	10,36	26809,00	10,20	1,11	15,90	7,10	-2,50	3,12	0,09
46	ITH4	2005	27400,00	10,22	48703,00	10,79	1,14	12,00	4,20	1,90	2,58	0,10
46	ITH4	2006	28900,00	10,27	50366,00	10,83	1,26	13,30	3,50	3,40	2,80	0,15
46	ITH4	2007	30400,00	10,32	45815,00	10,73	1,37	13,50	3,40	7,20	2,91	0,11
46	ITH4	2008	29700,00	10,30	43549,00	10,68	1,34	13,50	4,30	5,80	2,83	0,10
46	ITH4	2009	27400,00	10,22	47076,00	10,76	1,51	13,10	5,20	0,10	2,32	0,12
46	ITH4	2010	28400,00	10,25	44545,00	10,70	1,45	13,60	5,70	-0,60	2,71	0,10
46	ITH4	2011	29100,00	10,28	46378,00	10,74	1,48	13,50	5,20	-2,50	2,89	0,10
46	ITH4	2012	28700,00	10,26	47197,00	10,76	1,48	17,10	6,70	3,30	2,87	0,09
46	ITH4	2013	28500,00	10,26	51096,00	10,84	1,50	17,30	7,70	6,10	2,89	0,09
46	ITH4	2014	28800,00	10,27	52697,00	10,87	1,54	17,20	8,00	-1,80	2,91	0,09
46	ITH4	2015	29900,00	10,31	54636,00	10,91	1,59	17,60	8,00	-4,80	2,96	0,09
47	ITH5	2005	30500,00	10,33	24253,00	10,10	1,14	13,40	3,90	7,10	2,87	0,12
47	ITH5	2006	32200,00	10,38	27639,00	10,23	1,29	14,20	3,40	6,80	3,12	0,17
47	ITH5	2007	33900,00	10,43	27008,00	10,20	1,43	14,80	2,80	11,30	3,25	0,12
47	ITH5	2008	33700,00	10,43	30075,00	10,31	1,26	15,90	3,20	12,80	3,21	0,12

47	ITH5	2009	30900,00	10,34	23848,00	10,08	1,37	16,40	4,70	6,90	2,62	0,13
47	ITH5	2010	31500,00	10,36	22186,00	10,01	1,44	16,10	5,60	5,70	3,01	0,11
47	ITH5	2011	32700,00	10,40	22281,00	10,01	1,42	17,30	5,20	2,30	3,25	0,12
47	ITH5	2012	32700,00	10,40	22402,00	10,02	1,61	17,90	7,00	8,30	3,27	0,10
47	ITH5	2013	32300,00	10,38	22522,00	10,02	1,64	17,80	8,40	15,60	3,27	0,11
47	ITH5	2014	33000,00	10,40	24183,00	10,09	1,70	18,70	8,30	0,90	3,34	0,10
47	ITH5	2015	34500,00	10,45	25288,00	10,14	1,79	20,30	7,70	-0,50	3,41	0,10
48	ITI1	2005	26700,00	10,19	34845,00	10,46	1,08	13,50	5,40	3,60	2,52	0,10
48	ITI1	2006	28100,00	10,24	36935,00	10,52	1,04	14,70	4,80	3,30	2,72	0,15
48	ITI1	2007	29400,00	10,29	41864,00	10,64	1,00	14,70	4,40	9,20	2,82	0,11
48	ITI1	2008	29200,00	10,28	39400,00	10,58	1,11	15,50	5,00	7,20	2,79	0,10
48	ITI1	2009	27800,00	10,23	32859,00	10,40	1,22	14,90	5,80	4,40	2,35	0,12
48	ITI1	2010	28000,00	10,24	33475,00	10,42	1,21	15,30	6,00	3,20	2,67	0,10
48	ITI1	2011	28700,00	10,26	31399,00	10,35	1,19	16,20	6,30	-0,30	2,85	0,10
48	ITI1	2012	29000,00	10,28	30770,00	10,33	1,26	16,90	7,80	6,80	2,90	0,09
48	ITI1	2013	28300,00	10,25	31750,00	10,37	1,28	17,00	8,70	15,50	2,87	0,09
48	ITI1	2014	28900,00	10,27	29871,00	10,30	1,30	17,40	10,10	0,60	2,92	0,09
48	ITI1	2015	30200,00	10,32	33712,00	10,43	1,31	19,30	9,20	-2,20	2,99	0,09
49	ITI3	2005	24800,00	10,12	9224,00	9,13	0,56	14,30	4,90	5,40	2,34	0,09
49	ITI3	2006	26300,00	10,18	9147,00	9,12	0,61	15,30	4,60	3,70	2,55	0,14
49	ITI3	2007	27600,00	10,23	10573,00	9,27	0,66	13,90	4,10	10,90	2,64	0,10
49	ITI3	2008	26900,00	10,20	11004,00	9,31	0,74	13,80	4,70	9,90	2,57	0,09
49	ITI3	2009	25500,00	10,15	10213,00	9,23	0,71	15,30	6,60	2,60	2,16	0,11
49	ITI3	2010	25500,00	10,15	9934,00	9,20	0,76	16,10	5,70	1,10	2,44	0,09
49	ITI3	2011	26000,00	10,17	9241,00	9,13	0,75	15,40	6,80	-0,80	2,58	0,09
49	ITI3	2012	25800,00	10,16	8316,00	9,03	0,81	16,80	9,10	2,90	2,58	0,08
49	ITI3	2013	25100,00	10,13	7197,00	8,88	0,82	18,30	10,90	5,20	2,54	0,08

49	ITI3	2014	25900,00	10,16	9234,00	9,13	0,86	18,60	10,10	-1,50	2,62	0,08
49	ITI3	2015	26900,00	10,20	9633,00	9,17	0,84	18,50	9,90	-4,60	2,66	0,08
50	ITI4	2005	32300,00	10,38	15204,00	9,63	1,64	16,50	7,70	5,60	3,04	0,12
50	ITI4	2006	33600,00	10,42	15192,00	9,63	1,57	16,90	7,50	5,90	3,25	0,18
50	ITI4	2007	35100,00	10,47	16021,00	9,68	1,50	18,20	6,40	12,20	3,36	0,13
50	ITI4	2008	34400,00	10,45	14802,00	9,60	1,63	19,50	7,50	11,00	3,28	0,12
50	ITI4	2009	32800,00	10,40	12609,00	9,44	1,65	19,10	8,40	7,60	2,78	0,14
50	ITI4	2010	32900,00	10,40	13264,00	9,49	1,62	19,30	9,20	7,10	3,14	0,12
50	ITI4	2011	33400,00	10,42	14813,00	9,60	1,53	19,50	8,70	3,40	3,32	0,12
50	ITI4	2012	32400,00	10,39	17765,00	9,78	1,61	20,40	10,60	10,40	3,24	0,10
50	ITI4	2013	31000,00	10,34	15500,00	9,65	1,66	21,00	12,00	54,80	3,14	0,10
50	ITI4	2014	30900,00	10,34	14189,00	9,56	1,63	23,30	12,50	3,70	3,12	0,10
50	ITI4	2015	31800,00	10,37	14987,00	9,61	1,60	23,30	11,80	-0,70	3,14	0,09
51	ITF1	2005	21200,00	9,96	1348,00	7,21	0,97	14,70	7,90	3,00	2,00	0,08
51	ITF1	2006	22400,00	10,02	1518,00	7,33	0,97	14,60	6,60	1,30	2,17	0,12
51	ITF1	2007	23500,00	10,06	1340,00	7,20	0,96	14,30	6,20	9,70	2,25	0,09
51	ITF1	2008	23600,00	10,07	1155,00	7,05	0,85	16,00	6,60	6,20	2,25	0,08
51	ITF1	2009	22200,00	10,01	1008,00	6,92	0,90	16,10	8,00	1,30	1,88	0,09
51	ITF1	2010	22800,00	10,03	1130,00	7,03	0,87	16,40	8,70	-0,40	2,18	0,08
51	ITF1	2011	23800,00	10,08	1403,00	7,25	0,81	17,40	8,60	-0,70	2,36	0,09
51	ITF1	2012	24100,00	10,09	1382,00	7,23	0,81	17,50	10,80	4,70	2,41	0,08
51	ITF1	2013	23400,00	10,06	1342,00	7,20	0,87	17,50	11,30	16,20	2,37	0,08
51	ITF1	2014	23600,00	10,07	1131,00	7,03	0,96	16,50	12,60	-1,80	2,39	0,07
51	ITF1	2015	25200,00	10,13	1173,00	7,07	0,92	17,00	12,60	-3,80	2,49	0,07
52	ITF3	2005	16900,00	9,74	15820,00	9,67	1,04	11,00	14,90	-0,30	1,59	0,06
52	ITF3	2006	17700,00	9,78	16540,00	9,71	1,10	11,20	12,80	-0,60	1,71	0,09
52	ITF3	2007	18500,00	9,83	18916,00	9,85	1,16	11,30	11,20	2,20	1,77	0,07

52	ITF3	2008	18400,00	9,82	15701,00	9,66	1,23	11,90	12,50	0,00	1,75	0,06
52	ITF3	2009	17500,00	9,77	15331,00	9,64	1,19	12,60	12,90	1,40	1,48	0,07
52	ITF3	2010	17300,00	9,76	19772,00	9,89	1,14	12,90	13,90	1,30	1,65	0,06
52	ITF3	2011	17300,00	9,76	19382,00	9,87	1,13	12,50	15,40	-0,20	1,72	0,06
52	ITF3	2012	17400,00	9,76	18258,00	9,81	1,23	13,80	19,20	0,90	1,74	0,06
52	ITF3	2013	16900,00	9,74	19252,00	9,87	1,31	14,30	21,50	17,20	1,71	0,06
52	ITF3	2014	17000,00	9,74	20083,00	9,91	1,27	14,30	21,70	-1,40	1,72	0,05
52	ITF3	2015	17600,00	9,78	23590,00	10,07	1,28	14,90	19,80	-1,80	1,74	0,05
53	ITF4	2005	16300,00	9,70	62619,00	11,04	0,64	9,40	14,60	0,10	1,54	0,06
53	ITF4	2006	17200,00	9,75	66265,00	11,10	0,70	10,50	12,60	-0,30	1,66	0,09
53	ITF4	2007	17800,00	9,79	65730,00	11,09	0,76	11,20	11,10	2,10	1,71	0,06
53	ITF4	2008	17400,00	9,76	65358,00	11,09	0,76	11,90	11,60	0,80	1,66	0,06
53	ITF4	2009	16600,00	9,72	51460,00	10,85	0,78	11,20	12,60	1,00	1,41	0,07
53	ITF4	2010	16900,00	9,74	49918,00	10,82	0,76	11,60	13,50	1,40	1,61	0,06
53	ITF4	2011	17300,00	9,76	57088,00	10,95	0,70	11,60	13,20	-0,90	1,72	0,06
53	ITF4	2012	17700,00	9,78	50047,00	10,82	0,76	12,40	15,70	0,20	1,77	0,06
53	ITF4	2013	17100,00	9,75	37684,00	10,54	0,83	13,20	19,70	9,70	1,73	0,06
53	ITF4	2014	17300,00	9,76	35627,00	10,48	0,99	14,00	21,50	0,00	1,75	0,05
53	ITF4	2015	18100,00	9,80	32855,00	10,40	0,99	13,30	19,70	-3,20	1,79	0,05
54	ITF6	2005	15700,00	9,66	30765,00	10,33	0,38	11,90	14,20	-5,60	1,48	0,06
54	ITF6	2006	16500,00	9,71	29776,00	10,30	0,42	12,30	12,80	-5,50	1,60	0,09
54	ITF6	2007	17100,00	9,75	31690,00	10,36	0,46	13,50	11,10	3,30	1,64	0,06
54	ITF6	2008	17200,00	9,75	31527,00	10,36	0,45	13,70	12,00	-1,70	1,64	0,06
54	ITF6	2009	16500,00	9,71	34394,00	10,45	0,46	14,00	11,30	-2,30	1,40	0,07
54	ITF6	2010	16500,00	9,71	43337,00	10,68	0,46	13,80	11,90	-1,80	1,58	0,06
54	ITF6	2011	16800,00	9,73	34608,00	10,45	0,45	13,70	12,70	-2,30	1,67	0,06
54	ITF6	2012	16800,00	9,73	33560,00	10,42	0,52	14,30	19,40	-0,10	1,68	0,05

54	ITF6	2013	16200,00	9,69	33913,00	10,43	0,54	14,00	22,30	11,30	1,64	0,05
54	ITF6	2014	16200,00	9,69	33408,00	10,42	0,79	15,20	23,40	-2,00	1,64	0,05
54	ITF6	2015	17100,00	9,75	31875,00	10,37	0,70	15,70	22,90	-3,10	1,69	0,05
55	ITG1	2005	16900,00	9,74	92545,00	11,44	0,74	10,30	16,10	0,10	1,59	0,06
55	ITG1	2006	17700,00	9,78	82177,00	11,32	0,76	10,90	13,40	-0,20	1,71	0,09
55	ITG1	2007	18300,00	9,81	87941,00	11,38	0,77	11,50	12,90	2,70	1,75	0,07
55	ITG1	2008	18300,00	9,81	82157,00	11,32	0,82	11,90	13,70	1,80	1,75	0,06
55	ITG1	2009	17400,00	9,76	69214,00	11,14	0,82	12,50	13,80	1,40	1,47	0,07
55	ITG1	2010	17400,00	9,76	84703,00	11,35	0,78	12,40	14,60	1,60	1,66	0,06
55	ITG1	2011	17400,00	9,76	84619,00	11,35	0,80	12,10	14,30	-1,20	1,73	0,06
55	ITG1	2012	17500,00	9,77	79053,00	11,28	0,85	13,00	18,40	0,00	1,75	0,06
55	ITG1	2013	17000,00	9,74	74214,00	11,21	0,90	13,40	21,00	18,80	1,72	0,06
55	ITG1	2014	16600,00	9,72	69762,00	11,15	1,07	13,30	22,20	-0,60	1,68	0,05
55	ITG1	2015	17600,00	9,78	64080,00	11,07	0,99	13,20	21,40	-3,50	1,74	0,05
56	ITG2	2005	18600,00	9,83	49609,00	10,81	0,58	9,40	12,80	0,80	1,75	0,07
56	ITG2	2006	19600,00	9,88	54703,00	10,91	0,59	10,40	10,70	1,00	1,90	0,10
56	ITG2	2007	20400,00	9,92	56834,00	10,95	0,60	11,00	9,80	2,50	1,95	0,07
56	ITG2	2008	20700,00	9,94	61163,00	11,02	0,58	11,20	12,20	1,70	1,97	0,07
56	ITG2	2009	19700,00	9,89	51157,00	10,84	0,66	11,80	13,20	-0,80	1,67	0,08
56	ITG2	2010	19800,00	9,89	50522,00	10,83	0,68	12,40	14,00	0,20	1,89	0,07
56	ITG2	2011	20000,00	9,90	54134,00	10,90	0,79	13,00	13,50	-2,30	1,99	0,07
56	ITG2	2012	20300,00	9,92	52133,00	10,86	0,73	14,00	15,40	1,50	2,03	0,07
56	ITG2	2013	19500,00	9,88	50468,00	10,83	0,77	14,00	17,50	14,20	1,98	0,06
56	ITG2	2014	19500,00	9,88	45685,00	10,73	0,77	13,10	18,60	-0,30	1,97	0,06
56	ITG2	2015	20100,00	9,91	49439,00	10,81	0,85	14,70	17,40	-3,10	1,99	0,06
57	CY00	2005	23600,00	10,07	7287,00	8,89	0,37	28,80	5,30	14,80	111,92	1,10
57	CY00	2006	24800,00	10,12	7635,00	8,94	0,38	30,50	4,50	18,50	109,81	1,10

57	CY00	2007	27100,00	10,21	7473,00	8,92	0,40	33,10	3,90	24,00	111,28	0,80
57	CY00	2008	27500,00	10,22	7934,00	8,98	0,39	34,50	3,70	26,20	112,95	0,80
57	CY00	2009	25800,00	10,16	6770,00	8,82	0,44	34,10	5,40	27,50	102,80	0,80
57	CY00	2010	25400,00	10,14	6954,00	8,85	0,45	35,70	6,30	24,80	107,69	1,10
57	CY00	2011	25000,00	10,13	6564,00	8,79	0,46	37,70	7,90	26,20	108,79	1,00
57	CY00	2012	24100,00	10,09	6237,00	8,74	0,44	39,30	11,80	4,50	108,37	0,90
57	CY00	2013	22500,00	10,02	7172,00	8,88	0,48	39,30	15,90	-9,10	115,47	0,80
57	CY00	2014	22400,00	10,02	7186,00	8,88	0,51	40,30	16,10	-12,90	122,06	0,60
57	CY00	2015	23500,00	10,06	7422,00	8,91	0,48	40,50	14,90	1,50	128,25	0,60
58	LV00	2005	11800,00	9,38	58396,00	10,98	0,53	20,30	10,00	-9,80	100,83	2,80
58	LV00	2006	13000,00	9,47	55700,00	10,93	0,65	20,90	7,00	-8,60	100,62	2,90
58	LV00	2007	14900,00	9,61	59492,00	10,99	0,55	22,20	6,10	-7,70	95,92	2,90
58	LV00	2008	15300,00	9,64	59956,00	11,00	0,58	24,80	7,70	-13,30	92,00	3,30
58	LV00	2009	12800,00	9,46	58569,00	10,98	0,45	25,80	17,50	-19,80	86,83	3,70
58	LV00	2010	13400,00	9,50	57060,00	10,95	0,61	26,90	19,50	-21,90	108,79	3,50
58	LV00	2011	14900,00	9,61	65394,00	11,09	0,70	27,70	16,20	-14,50	120,61	3,70
58	LV00	2012	16000,00	9,68	70990,00	11,17	0,66	29,20	15,00	-10,30	127,07	2,90
58	LV00	2013	16600,00	9,72	65513,00	11,09	0,61	31,00	11,90	-11,10	124,16	2,90
58	LV00	2014	17500,00	9,77	70015,00	11,16	0,69	30,20	10,80	-7,70	122,93	2,70
58	LV00	2015	18600,00	9,83	66149,00	11,10	0,63	31,60	9,90	-8,70	121,32	2,30
59	LT00	2005	12300,00	9,42	26146,00	10,17	0,75	26,50	8,30	-19,70	114,92	2,00
59	LT00	2006	13600,00	9,52	27235,00	10,21	0,79	26,10	5,80	-12,20	121,50	2,10
59	LT00	2007	15700,00	9,66	29253,00	10,28	0,80	28,20	4,20	-11,60	113,84	1,80
59	LT00	2008	16400,00	9,71	36379,00	10,50	0,79	30,20	5,80	-9,00	125,85	2,40
59	LT00	2009	13800,00	9,53	34344,00	10,44	0,83	30,80	13,80	-13,20	105,56	2,00
59	LT00	2010	15400,00	9,64	37869,00	10,54	0,78	32,40	17,80	-28,90	132,56	2,00
59	LT00	2011	17200,00	9,75	42661,00	10,66	0,90	33,50	15,40	-16,20	152,54	1,50

59	LT00	2012	18600,00	9,83	41033,00	10,62	0,89	34,10	13,40	-10,60	162,39	1,30
59	LT00	2013	19600,00	9,88	39757,00	10,59	0,95	35,20	11,80	-9,60	166,87	1,40
59	LT00	2014	20700,00	9,94	41105,00	10,62	1,03	36,70	10,70	-7,60	160,13	1,20
59	LT00	2015	21600,00	9,98	43128,00	10,67	1,04	38,70	9,10	-11,30	152,15	1,50
60	MT00	2005	18900,00	9,85	3503,00	8,16	0,53	11,50	6,90	5,80	211,19	1,90
60	MT00	2006	19200,00	9,86	3578,00	8,18	0,58	11,90	6,80	1,50	250,28	1,40
60	MT00	2007	20500,00	9,93	3228,00	8,08	0,55	12,40	6,50	5,40	258,51	1,30
60	MT00	2008	20700,00	9,94	3373,00	8,12	0,53	13,30	6,00	7,60	297,20	2,60
60	MT00	2009	19800,00	9,89	3369,00	8,12	0,52	13,90	6,90	7,50	296,97	1,30
60	MT00	2010	21200,00	9,96	3795,00	8,24	0,61	14,90	6,80	2,30	307,42	0,90
60	MT00	2011	21500,00	9,98	3321,00	8,11	0,67	16,20	6,40	6,10	318,38	1,20
60	MT00	2012	22200,00	10,01	3321,00	8,11	0,83	17,60	6,30	11,80	325,86	1,40
60	MT00	2013	22900,00	10,04	3091,00	8,04	0,77	18,90	6,40	16,20	307,85	0,90
60	MT00	2014	24800,00	10,12	3453,00	8,15	0,72	19,50	5,80	23,60	285,30	1,50
60	MT00	2015	26700,00	10,19	3683,00	8,21	0,77	19,60	5,40	24,10	271,90	1,70
61	NL11	2005	36600,00	10,51	2835,00	7,95	1,74	29,60	6,60	-1,80	12,85	0,23
61	NL11	2006	41200,00	10,63	2685,00	7,90	1,63	31,40	5,00	-0,70	14,14	0,23
61	NL11	2007	41400,00	10,63	2949,00	7,99	1,51	30,00	4,90	-0,30	13,62	0,23
61	NL11	2008	48400,00	10,79	3119,00	8,05	1,65	30,30	4,00	1,10	15,68	0,28
61	NL11	2009	41300,00	10,63	1992,00	7,60	1,79	31,00	4,80	4,50	12,97	0,29
61	NL11	2010	44200,00	10,70	3368,00	8,12	1,72	33,90	5,30	4,10	15,28	0,31
61	NL11	2011	45900,00	10,73	2697,00	7,90	1,65	33,10	6,80	3,20	16,77	0,29
61	NL11	2012	49800,00	10,82	3834,00	8,25	1,55	33,20	7,00	1,40	18,73	0,30
61	NL11	2013	52700,00	10,87	3156,00	8,06	1,53	33,10	8,20	1,80	19,55	0,31
61	NL11	2014	45800,00	10,73	3892,00	8,27	1,84	31,60	8,60	2,10	17,13	0,27
61	NL11	2015	41500,00	10,63	6119,00	8,72	2,07	33,70	9,10	-0,40	16,01	0,23
62	NL12	2005	22100,00	10,00	906,00	6,81	0,77	24,40	4,90	-1,20	7,76	0,14

62	NL12	2006	23400,00	10,06	1069,00	6,97	0,73	24,10	4,20	0,00	8,03	0,13
62	NL12	2007	25200,00	10,13	1108,00	7,01	0,68	25,20	3,20	1,50	8,29	0,14
62	NL12	2008	25400,00	10,14	868,00	6,77	0,75	24,60	2,90	2,50	8,23	0,14
62	NL12	2009	23800,00	10,08	638,00	6,46	0,81	25,60	3,50	2,30	7,47	0,17
62	NL12	2010	24000,00	10,09	999,00	6,91	0,82	26,30	4,80	1,50	8,30	0,17
62	NL12	2011	25200,00	10,13	400,00	5,99	0,82	26,80	5,10	-0,10	9,21	0,16
62	NL12	2012	25600,00	10,15	441,00	6,09	0,86	26,30	6,40	-0,50	9,63	0,15
62	NL12	2013	25700,00	10,15	240,00	5,48	0,88	27,20	8,30	-0,80	9,53	0,15
62	NL12	2014	25900,00	10,16	324,00	5,78	0,83	26,00	7,90	-0,10	9,69	0,15
62	NL12	2015	26100,00	10,17	404,00	6,00	0,85	25,40	7,90	-0,30	10,07	0,15
63	NL32	2005	39500,00	10,58	69674,00	11,15	1,39	36,20	4,90	2,90	13,87	0,25
63	NL32	2006	41300,00	10,63	78157,00	11,27	1,43	35,80	3,80	2,50	14,18	0,23
63	NL32	2007	43800,00	10,69	84362,00	11,34	1,46	36,50	2,90	5,00	14,41	0,24
63	NL32	2008	43800,00	10,69	98035,00	11,49	1,49	37,80	2,60	7,70	14,19	0,25
63	NL32	2009	40900,00	10,62	85965,00	11,36	1,52	39,70	3,20	8,50	12,84	0,29
63	NL32	2010	41800,00	10,64	90245,00	11,41	1,65	38,70	4,20	8,40	14,45	0,30
63	NL32	2011	42300,00	10,65	88529,00	11,39	1,77	38,60	5,00	6,80	15,46	0,27
63	NL32	2012	42900,00	10,67	91125,00	11,42	1,88	38,50	5,40	5,30	16,13	0,26
63	NL32	2013	44100,00	10,69	93359,00	11,44	1,75	39,20	7,20	6,20	16,36	0,26
63	NL32	2014	45600,00	10,73	97378,00	11,49	1,64	40,80	6,90	7,50	17,05	0,27
63	NL32	2015	47400,00	10,77	99071,00	11,50	1,72	41,60	6,20	8,30	18,29	0,27
64	NL33	2005	33100,00	10,41	353974,00	12,78	1,59	30,80	4,90	0,10	11,62	0,21
64	NL33	2006	34900,00	10,46	361282,00	12,80	1,59	30,40	4,40	-1,10	11,98	0,20
64	NL33	2007	37600,00	10,53	382118,00	12,85	1,58	31,70	3,50	1,80	12,37	0,21
64	NL33	2008	37600,00	10,53	391335,00	12,88	1,65	32,80	3,00	5,80	12,18	0,21
64	NL33	2009	34700,00	10,45	361920,00	12,80	1,71	33,30	3,60	6,90	10,90	0,24
64	NL33	2010	34900,00	10,46	407391,00	12,92	1,83	31,90	5,00	6,50	12,06	0,25

64	NL33	2011	34700,00	10,45	405329,00	12,91	1,94	32,20	5,60	6,80	12,68	0,22
64	NL33	2012	35500,00	10,48	418780,00	12,95	1,93	33,80	6,90	3,20	13,35	0,21
64	NL33	2013	35500,00	10,48	422838,00	12,95	2,02	34,80	7,90	3,70	13,17	0,21
64	NL33	2014	35600,00	10,48	428902,00	12,97	2,19	34,20	8,40	6,40	13,31	0,21
64	NL33	2015	37000,00	10,52	448598,00	13,01	2,19	36,10	7,80	6,20	14,28	0,21
65	NL34	2005	23200,00	10,05	27994,00	10,24	0,62	22,00	3,30	0,50	8,15	0,15
65	NL34	2006	24400,00	10,10	27838,00	10,23	0,62	21,80	2,70	0,80	8,38	0,14
65	NL34	2007	26900,00	10,20	31178,00	10,35	0,62	21,50	2,10	0,20	8,85	0,15
65	NL34	2008	27500,00	10,22	30218,00	10,32	0,67	24,00	2,80	1,00	8,91	0,16
65	NL34	2009	24900,00	10,12	26580,00	10,19	0,72	25,40	2,10	1,10	7,82	0,17
65	NL34	2010	26300,00	10,18	29824,00	10,30	0,56	26,40	2,70	0,30	9,09	0,19
65	NL34	2011	27100,00	10,21	29450,00	10,29	0,40	24,90	3,20	-0,30	9,90	0,17
65	NL34	2012	27200,00	10,21	31780,00	10,37	0,54	22,00	3,50	-0,90	10,23	0,16
65	NL34	2013	27400,00	10,22	32332,00	10,38	0,69	23,80	5,00	-1,20	10,16	0,16
65	NL34	2014	27700,00	10,23	34422,00	10,45	0,66	24,90	5,40	0,30	10,36	0,17
65	NL34	2015	28800,00	10,27	33642,00	10,42	0,59	25,10	5,30	1,40	11,11	0,16
66	NL41	2005	31600,00	10,36	4232,00	8,35	2,92	28,30	3,90	1,90	11,10	0,20
66	NL41	2006	33600,00	10,42	5236,00	8,56	2,82	28,70	3,40	1,30	11,53	0,19
66	NL41	2007	35600,00	10,48	4842,00	8,49	2,71	29,20	2,80	2,40	11,71	0,20
66	NL41	2008	35800,00	10,49	5784,00	8,66	2,49	30,70	2,30	4,00	11,60	0,20
66	NL41	2009	33000,00	10,40	4966,00	8,51	2,26	30,40	3,20	3,90	10,36	0,23
66	NL41	2010	34200,00	10,44	5888,00	8,68	2,34	29,20	4,20	4,10	11,82	0,24
66	NL41	2011	35400,00	10,47	5371,00	8,59	2,41	30,00	4,60	3,90	12,94	0,23
66	NL41	2012	35900,00	10,49	4909,00	8,50	2,59	31,60	5,30	3,00	13,50	0,22
66	NL41	2013	36000,00	10,49	4640,00	8,44	2,62	32,20	6,70	3,30	13,35	0,21
66	NL41	2014	36600,00	10,51	3958,00	8,28	2,75	33,20	7,00	3,80	13,69	0,22
66	NL41	2015	38000,00	10,55	5552,00	8,62	2,78	33,20	6,50	4,00	14,66	0,21

67	PL42	2005	10700,00	9,28	20836,00	9,94	0,18	16,10	22,70	-0,40	4,33	0,15
67	PL42	2006	11300,00	9,33	18476,00	9,82	0,19	17,60	17,20	-0,80	4,76	0,17
67	PL42	2007	12300,00	9,42	17289,00	9,76	0,24	19,50	11,50	-0,30	4,87	0,18
67	PL42	2008	13000,00	9,47	18618,00	9,83	0,24	19,30	9,50	0,40	4,92	0,21
67	PL42	2009	12700,00	9,45	14722,00	9,60	0,22	20,10	10,40	0,10	4,46	0,24
67	PL42	2010	13600,00	9,52	20286,00	9,92	0,31	20,80	12,40	0,10	4,82	0,25
67	PL42	2011	14300,00	9,57	20643,00	9,94	0,33	21,00	11,80	-0,80	5,03	0,24
67	PL42	2012	14900,00	9,61	20520,00	9,93	0,37	22,50	10,90	-0,70	5,16	0,20
67	PL42	2013	14900,00	9,61	21300,00	9,97	0,30	23,90	10,10	-1,90	5,20	0,17
67	PL42	2014	15600,00	9,66	22286,00	10,01	0,28	24,10	8,40	-1,70	5,41	0,20
67	PL42	2015	16800,00	9,73	21486,00	9,98	0,33	24,50	7,50	-2,60	5,62	0,19
68	PL63	2005	11700,00	9,37	33502,00	10,42	0,51	16,60	18,90	2,30	4,73	0,16
68	PL63	2006	12400,00	9,43	34227,00	10,44	0,50	17,50	13,80	2,10	5,23	0,18
68	PL63	2007	13600,00	9,52	34789,00	10,46	0,50	18,50	9,50	3,30	5,39	0,19
68	PL63	2008	13800,00	9,53	29908,00	10,31	0,56	19,50	5,50	3,90	5,22	0,22
68	PL63	2009	14300,00	9,57	30065,00	10,31	0,50	21,10	6,40	4,80	5,02	0,27
68	PL63	2010	15300,00	9,64	38719,00	10,56	0,60	22,70	9,30	4,70	5,42	0,28
68	PL63	2011	16400,00	9,71	36478,00	10,50	0,70	23,90	8,50	3,30	5,77	0,28
68	PL63	2012	17400,00	9,76	37452,00	10,53	1,07	25,90	9,50	2,90	6,02	0,24
68	PL63	2013	17300,00	9,76	42060,00	10,65	0,98	26,70	10,00	2,40	6,03	0,19
68	PL63	2014	17800,00	9,79	45715,00	10,73	1,05	26,50	8,60	3,00	6,17	0,22
68	PL63	2015	19000,00	9,85	47040,00	10,76	1,12	28,10	6,60	2,40	6,36	0,21
69	PT11	2005	15200,00	9,63	13331,00	9,50	0,65	9,80	8,80	0,30	7,09	0,33
69	PT11	2006	16100,00	9,69	13233,00	9,49	0,81	10,60	8,80	0,50	7,72	0,27
69	PT11	2007	16800,00	9,73	14053,00	9,55	0,94	10,80	9,30	0,00	7,98	0,26
69	PT11	2008	16900,00	9,74	14703,00	9,60	1,17	11,80	8,60	-1,90	8,34	0,29
69	PT11	2009	16100,00	9,69	13271,00	9,49	1,37	12,50	10,90	-1,80	7,11	0,31

69	PT11	2010	16900,00	9,74	13565,00	9,52	1,45	12,80	12,60	-3,40	7,94	0,39
69	PT11	2011	16400,00	9,71	15289,00	9,63	1,49	14,80	13,00	-1,70	8,64	0,28
69	PT11	2012	16500,00	9,71	15282,00	9,63	1,42	16,40	16,00	-5,70	9,19	0,21
69	PT11	2013	17000,00	9,74	15872,00	9,67	1,39	16,50	17,10	-6,00	9,51	0,21
69	PT11	2014	17800,00	9,79	16662,00	9,72	1,35	18,20	14,80	-6,20	9,84	0,30
69	PT11	2015	18700,00	9,84	17459,00	9,77	1,35	18,70	13,70	-5,00	9,95	0,24
70	PT16	2005	16500,00	9,71	3328,00	8,11	0,62	10,20	5,10	-1,20	7,69	0,36
70	PT16	2006	17400,00	9,76	4539,00	8,42	0,82	11,60	5,40	-0,80	8,34	0,29
70	PT16	2007	18000,00	9,80	4477,00	8,41	1,00	11,80	5,50	-1,00	8,55	0,28
70	PT16	2008	17600,00	9,78	4574,00	8,43	1,17	11,50	5,30	-1,80	8,69	0,30
70	PT16	2009	17100,00	9,75	4138,00	8,33	1,19	11,20	6,80	-1,70	7,55	0,33
70	PT16	2010	17700,00	9,78	5232,00	8,56	1,23	12,30	7,60	-2,60	8,32	0,41
70	PT16	2011	17100,00	9,75	4966,00	8,51	1,25	14,60	10,00	-6,70	9,01	0,30
70	PT16	2012	17200,00	9,75	5051,00	8,53	1,30	16,50	11,70	-7,50	9,58	0,21
70	PT16	2013	17700,00	9,78	6051,00	8,71	1,28	17,00	11,40	-7,80	9,90	0,22
70	PT16	2014	18200,00	9,81	6598,00	8,79	1,35	19,70	10,60	-7,60	10,06	0,30
70	PT16	2015	19200,00	9,86	6612,00	8,80	1,22	21,80	9,20	-3,40	10,21	0,24
71	PT17	2005	27800,00	10,23	17905,00	9,79	1,08	20,10	8,60	4,80	12,96	0,60
71	PT17	2006	29200,00	10,28	17224,00	9,75	1,36	20,50	8,50	5,00	14,00	0,49
71	PT17	2007	30200,00	10,32	18740,00	9,84	1,60	20,50	8,90	5,80	14,34	0,47
71	PT17	2008	30000,00	10,31	17863,00	9,79	2,14	21,10	8,20	5,90	14,81	0,51
71	PT17	2009	28700,00	10,26	15994,00	9,68	2,33	21,80	9,80	5,70	12,67	0,56
71	PT17	2010	29500,00	10,29	17786,00	9,79	2,21	22,90	11,30	5,20	13,87	0,68
71	PT17	2011	28300,00	10,25	17879,00	9,79	1,97	24,20	14,10	1,50	14,91	0,49
71	PT17	2012	27500,00	10,22	15980,00	9,68	1,77	24,90	17,60	-3,10	15,32	0,34
71	PT17	2013	28100,00	10,24	17819,00	9,79	1,68	27,00	18,50	-3,90	15,72	0,34
71	PT17	2014	28600,00	10,26	18560,00	9,83	1,58	31,00	14,90	0,60	15,81	0,47

71	PT17	2015	29700,00	10,30	17742,00	9,78	1,51	32,50	13,10	1,20	15,80	0,37
72	PT18	2005	17800,00	9,79	24929,00	10,12	0,44	9,80	9,10	-2,90	8,30	0,38
72	PT18	2006	19100,00	9,86	26934,00	10,20	0,53	9,50	9,10	-2,00	9,16	0,32
72	PT18	2007	19600,00	9,88	25970,00	10,16	0,63	11,50	8,40	-2,30	9,31	0,31
72	PT18	2008	19100,00	9,86	24531,00	10,11	0,87	13,10	8,90	-3,80	9,43	0,33
72	PT18	2009	18000,00	9,80	23857,00	10,08	0,75	11,70	10,50	-3,40	7,94	0,35
72	PT18	2010	19100,00	9,86	24728,00	10,12	0,43	13,50	11,40	-4,40	8,98	0,44
72	PT18	2011	18400,00	9,82	24871,00	10,12	0,42	14,70	12,40	-5,70	9,69	0,32
72	PT18	2012	18100,00	9,80	27423,00	10,22	0,47	14,20	16,00	-7,60	10,08	0,23
72	PT18	2013	18400,00	9,82	34600,00	10,45	0,46	15,60	16,90	-7,20	10,29	0,22
72	PT18	2014	19100,00	9,86	35054,00	10,46	0,47	16,80	14,30	-13,50	10,56	0,32
72	PT18	2015	20100,00	9,91	41218,00	10,63	0,53	18,00	13,30	-12,30	10,69	0,25
73	PT20	2005	17100,00	9,75	1562,00	7,35	0,35	7,70		2,60	7,97	0,37
73	PT20	2006	18100,00	9,80	1576,00	7,36	0,38	8,20		2,30	8,68	0,31
73	PT20	2007	18600,00	9,83	1601,00	7,38	0,40	7,50	4,30	2,90	8,83	0,29
73	PT20	2008	19000,00	9,85	1516,00	7,32	0,41	7,30	5,40	1,20	9,38	0,33
73	PT20	2009	18300,00	9,81	1547,00	7,34	0,77	8,30	6,70	0,90	8,08	0,36
73	PT20	2010	19100,00	9,86	1535,00	7,34	0,37	9,90	6,80	-0,60	8,98	0,44
73	PT20	2011	18400,00	9,82	1602,00	7,38	0,39	10,70	11,30	1,80	9,69	0,32
73	PT20	2012	18200,00	9,81	1372,00	7,22	0,58	12,10	15,10	1,40	10,14	0,23
73	PT20	2013	18600,00	9,83	1241,00	7,12	0,35	11,90	17,00	-0,40	10,40	0,23
73	PT20	2014	19100,00	9,86	1142,00	7,04	0,35	13,00	16,30	-4,40	10,56	0,32
73	PT20	2015	19700,00	9,89	1222,00	7,11	0,34	14,30	12,80	-2,40	10,48	0,25
74	PT30	2005	19300,00	9,87	1187,00	7,08	0,32	9,90	4,50	9,00	9,00	0,42
74	PT30	2006	20400,00	9,92	1595,00	7,37	0,33	9,60	5,30	9,40	9,78	0,34
74	PT30	2007	20900,00	9,95	1172,00	7,07	0,34	10,90	6,80	9,00	9,92	0,33
74	PT30	2008	20900,00	9,95	1192,00	7,08	0,45	11,60	5,90	6,40	10,32	0,36

74	PT30	2009	19800,00	9,89	1154,00	7,05	0,34	12,30	7,50	5,90	8,74	0,39
74	PT30	2010	20300,00	9,92	1071,00	6,98	0,38	12,70	7,40	4,70	9,54	0,47
74	PT30	2011	19900,00	9,90	1011,00	6,92	0,30	13,80	13,50	-14,00	10,48	0,35
74	PT30	2012	18800,00	9,84	876,00	6,78	0,30	14,70	17,20	-4,30	10,47	0,23
74	PT30	2013	19300,00	9,87	932,00	6,84	0,35	16,20	18,10	-6,80	10,80	0,24
74	PT30	2014	20200,00	9,91	931,00	6,84	0,36	16,60	15,00	-10,10	11,17	0,34
74	PT30	2015	20700,00	9,94	1022,00	6,93	0,36	17,30	14,70	-8,80	11,01	0,26
75	RO22	2005	7100,00	8,87	47678,00	10,77	0,13	8,50	7,90	-2,20	7,77	
75	RO22	2006	8300,00	9,02	46006,00	10,74	0,14	9,20	9,00	-3,30	7,76	
75	RO22	2007	9000,00	9,10	48180,00	10,78	0,18	8,80	8,50	-3,00	6,82	0,35
75	RO22	2008	10100,00	9,22	49751,00	10,81	0,18	9,40	7,20	-2,60	6,08	0,35
75	RO22	2009	9700,00	9,18	35160,00	10,47	0,17	10,00	7,50	-2,50	5,63	0,37
75	RO22	2010	10700,00	9,28	36528,00	10,51	0,16	10,30	8,20	-3,10	6,91	0,37
75	RO22	2011	11000,00	9,31	37489,00	10,53	0,11	11,40	9,60	-4,10	7,62	0,35
75	RO22	2012	12400,00	9,43	38427,00	10,56	0,08	12,30	9,40	-6,20	8,35	0,51
75	RO22	2013	13100,00	9,48	42512,00	10,66	0,06	12,40	9,50	-5,70	8,78	0,40
75	RO22	2014	13700,00	9,53	42598,00	10,66	0,06	12,00	10,40	-6,70	9,05	0,42
75	RO22	2015	14600,00	9,59	43648,00	10,68	0,08	12,90	9,00	-9,10	8,93	0,36
76	FI19	2005	24200,00	10,09	12817,00	9,46	3,43	32,60	8,80	2,90	13,11	0,34
76	FI19	2006	25100,00	10,13	15316,00	9,64	3,59	32,70	7,80	3,50	14,03	0,32
76	FI19	2007	27800,00	10,23	15771,00	9,67	3,52	33,20	6,50	4,20	14,61	0,35
76	FI19	2008	28400,00	10,25	17548,00	9,77	3,72	33,70	6,50	3,70	15,47	0,38
76	FI19	2009	25700,00	10,15	13778,00	9,53	3,88	35,00	9,00	4,10	12,22	0,40
76	FI19	2010	26600,00	10,19	14745,00	9,60	3,81	36,00	9,00	3,60	13,40	0,40
76	FI19	2011	28000,00	10,24	15758,00	9,67	3,61	36,20	8,30	3,80	14,20	0,41
76	FI19	2012	28000,00	10,24	13074,00	9,48	3,30	36,50	8,20	3,70	14,20	0,42
76	FI19	2013	27200,00	10,21	13913,00	9,54	3,25	38,50	8,50	2,90	13,60	0,42

76	FI19	2014	27300,00	10,21	13294,00	9,50	3,05	39,20	8,70	2,10	13,14	0,44
76	FI19	2015	28300,00	10,25	11995,00	9,39	2,85	40,90	9,80	1,30	12,84	0,44
77	FI1D	2005	22000,00	10,00	14907,00	9,61	3,14	30,60	11,40	-0,20	11,92	0,31
77	FI1D	2006	23100,00	10,05	17083,00	9,75	3,11	31,20	10,80	-1,20	12,91	0,30
77	FI1D	2007	25000,00	10,13	17488,00	9,77	3,47	31,30	9,90	-0,90	13,14	0,32
77	FI1D	2008	25500,00	10,15	19448,00	9,88	3,65	31,40	8,70	-0,40	13,89	0,34
77	FI1D	2009	22600,00	10,03	16665,00	9,72	4,03	32,40	10,50	0,70	10,75	0,35
77	FI1D	2010	23800,00	10,08	20262,00	9,92	3,70	33,20	10,10	0,80	11,99	0,36
77	FI1D	2011	25000,00	10,13	21220,00	9,96	3,64	33,80	9,40	1,10	12,68	0,37
77	FI1D	2012	25100,00	10,13	20659,00	9,94	3,39	34,60	9,50	0,50	12,72	0,38
77	FI1D	2013	25000,00	10,13	20688,00	9,94	3,09	35,20	9,90	1,10	12,50	0,38
77	FI1D	2014	25200,00	10,13	22170,00	10,01	2,80	36,80	10,00	-0,30	12,13	0,40
77	FI1D	2015	25800,00	10,16	19556,00	9,88	2,50	36,70	10,40	-1,50	11,71	0,40
78	SE11	2005	40400,00	10,61	11635,00	9,36	4,02	38,00	6,90	9,10	15,52	0,44
78	SE11	2006	42400,00	10,65	11791,00	9,38	3,90	38,40	6,10	14,80	15,90	0,43
78	SE11	2007	46200,00	10,74	11850,00	9,38	3,78	38,90	5,60	16,20	16,33	0,44
78	SE11	2008	45400,00	10,72	12021,00	9,39	3,69	40,40	5,20	16,20	16,81	0,47
78	SE11	2009	43400,00	10,68	10445,00	9,25	3,59	41,90	6,80	19,00	15,88	0,57
78	SE11	2010	44100,00	10,69	9411,00	9,15	3,56	42,30	7,20	17,30	15,75	0,53
78	SE11	2011	46200,00	10,74	9520,00	9,16	3,53	43,70	6,60	17,90	16,33	0,52
78	SE11	2012	47400,00	10,77	8961,00	9,10	3,70	44,40	6,80	16,80	16,20	0,54
78	SE11	2013	46700,00	10,75	9009,00	9,11	3,87	45,70	6,90	16,80	15,30	0,50
78	SE11	2014	47900,00	10,78	11868,00	9,38	3,84	47,60	7,10	16,10	16,03	0,50
78	SE11	2015	50300,00	10,83	11740,00	9,37	3,81	48,70	7,00	15,10	16,23	0,49
79	SE12	2005	25000,00	10,13	15024,00	9,62	3,71	28,30	8,10	2,30	9,61	0,27
79	SE12	2006	26900,00	10,20	13502,00	9,51	3,66	28,80	7,30	4,20	10,09	0,27
79	SE12	2007	29000,00	10,28	13775,00	9,53	3,60	29,00	6,70	6,60	10,25	0,27

79	SE12	2008	28600,00	10,26	14079,00	9,55	3,95	29,40	6,90	7,20	10,59	0,29
79	SE12	2009	26000,00	10,17	6663,00	8,80	4,29	30,30	9,30	8,20	9,51	0,34
79	SE12	2010	27600,00	10,23	10021,00	9,21	4,09	30,70	9,70	7,00	9,86	0,33
79	SE12	2011	28700,00	10,26	11924,00	9,39	3,89	31,50	8,40	5,60	10,15	0,32
79	SE12	2012	29600,00	10,30	9935,00	9,20	3,89	33,10	8,60	7,40	10,12	0,33
79	SE12	2013	29300,00	10,29	11397,00	9,34	3,88	35,10	8,80	9,70	9,60	0,31
79	SE12	2014	29400,00	10,29	12527,00	9,44	3,90	36,60	8,30	10,10	9,84	0,31
79	SE12	2015	30600,00	10,33	12445,00	9,43	3,91	36,80	7,90	10,60	9,87	0,30
80	SE21	2005	24300,00	10,10	6688,00	8,81	1,04	23,50	6,10	0,40	9,34	0,26
80	SE21	2006	26900,00	10,20	5548,00	8,62	1,07	23,50	5,90	2,70	10,09	0,27
80	SE21	2007	29200,00	10,28	7232,00	8,89	1,09	25,00	5,10	3,90	10,32	0,28
80	SE21	2008	29100,00	10,28	8479,00	9,05	1,41	26,30	5,00	3,10	10,78	0,30
80	SE21	2009	25100,00	10,13	2609,00	7,87	1,73	26,30	8,10	2,70	9,19	0,33
80	SE21	2010	26800,00	10,20	3603,00	8,19	1,55	26,30	7,90	1,90	9,57	0,32
80	SE21	2011	28100,00	10,24	3438,00	8,14	1,36	27,50	7,10	1,60	9,93	0,31
80	SE21	2012	28700,00	10,26	3153,00	8,06	1,42	28,40	7,40	3,50	9,81	0,32
80	SE21	2013	28600,00	10,26	3705,00	8,22	1,47	29,20	7,10	4,40	9,37	0,30
80	SE21	2014	28800,00	10,27	3818,00	8,25	1,51	31,20	6,70	8,30	9,64	0,30
80	SE21	2015	30000,00	10,31	3526,00	8,17	1,54	32,90	6,00	9,70	9,68	0,29
81	SE22	2005	25600,00	10,15	36835,00	10,51	4,20	29,40	8,90	6,80	9,84	0,28
81	SE22	2006	27300,00	10,21	40015,00	10,60	4,36	31,50	8,20	11,90	10,24	0,28
81	SE22	2007	30600,00	10,33	43242,00	10,67	4,51	33,00	7,10	11,40	10,82	0,29
81	SE22	2008	28900,00	10,27	42237,00	10,65	4,51	33,60	7,40	11,60	10,70	0,30
81	SE22	2009	25900,00	10,16	35832,00	10,49	4,50	34,90	8,70	12,10	9,48	0,34
81	SE22	2010	27300,00	10,21	38371,00	10,56	4,43	35,90	8,80	9,30	9,75	0,33
81	SE22	2011	27800,00	10,23	38641,00	10,56	4,36	36,30	9,20	6,70	9,83	0,31
81	SE22	2012	28500,00	10,26	38021,00	10,55	4,11	36,60	9,40	6,70	9,74	0,32

81	SE22	2013	28400,00	10,25	36569,00	10,51	3,86	37,90	9,90	8,00	9,31	0,30
81	SE22	2014	29000,00	10,28	37493,00	10,53	3,58	38,90	10,00	11,30	9,71	0,31
81	SE22	2015	30200,00	10,32	38211,00	10,55	3,30	40,90	9,50	11,60	9,74	0,29
82	SE23	2005	27800,00	10,23	64502,00	11,07	5,06	28,20	7,40	4,80	10,68	0,30
82	SE23	2006	30200,00	10,32	66252,00	11,10	4,28	29,60	6,80	7,00	11,33	0,31
82	SE23	2007	32200,00	10,38	64894,00	11,08	3,50	31,20	5,90	6,30	11,38	0,31
82	SE23	2008	32200,00	10,38	69297,00	11,15	3,75	31,00	6,10	7,10	11,92	0,33
82	SE23	2009	28800,00	10,27	64271,00	11,07	3,99	31,80	8,60	7,80	10,54	0,38
82	SE23	2010	30500,00	10,33	50432,00	10,83	3,88	33,00	8,70	7,20	10,89	0,36
82	SE23	2011	31600,00	10,36	48908,00	10,80	3,77	34,10	7,40	6,70	11,17	0,35
82	SE23	2012	32000,00	10,37	48955,00	10,80	3,70	35,40	7,70	6,40	10,94	0,36
82	SE23	2013	32100,00	10,38	47025,00	10,76	3,62	36,50	8,00	9,10	10,52	0,34
82	SE23	2014	32700,00	10,40	46526,00	10,75	3,71	38,80	7,60	10,70	10,94	0,34
82	SE23	2015	35000,00	10,46	47416,00	10,77	3,80	39,20	6,60	10,60	11,29	0,34
83	SE31	2005	24500,00	10,11	5914,00	8,69	1,28	23,40	9,20	-1,40	9,41	0,27
83	SE31	2006	26300,00	10,18	5311,00	8,58	1,39	23,90	7,90	-0,20	9,87	0,27
83	SE31	2007	27800,00	10,23	4649,00	8,44	1,50	23,20	6,30	0,20	9,83	0,26
83	SE31	2008	27500,00	10,22	4975,00	8,51	1,43	23,50	6,60	0,20	10,18	0,28
83	SE31	2009	24500,00	10,11	4340,00	8,38	1,36	25,30	9,40	0,90	8,97	0,32
83	SE31	2010	26200,00	10,17	3994,00	8,29	1,21	26,40	9,00	1,10	9,36	0,31
83	SE31	2011	26800,00	10,20	4325,00	8,37	1,06	27,30	8,80	-1,70	9,47	0,30
83	SE31	2012	27700,00	10,23	3947,00	8,28	1,21	27,30	8,60	1,00	9,47	0,31
83	SE31	2013	27300,00	10,21	6481,00	8,78	1,36	27,40	8,80	3,50	8,95	0,29
83	SE31	2014	27500,00	10,22	6660,00	8,80	1,33	28,30	8,60	5,40	9,20	0,29
83	SE31	2015	28500,00	10,26	7574,00	8,93	1,30	30,60	7,90	6,20	9,20	0,28
84	SE32	2005	26100,00	10,17	4476,00	8,41	0,86	25,60	8,90	-2,30	10,03	0,28
84	SE32	2006	27300,00	10,21	4382,00	8,39	0,80	26,40	7,30	0,60	10,24	0,28

84	SE32	2007	28200,00	10,25	4481,00	8,41	0,74	27,50	6,30	-1,70	9,97	0,27
84	SE32	2008	29200,00	10,28	4384,00	8,39	0,81	28,30	7,10	-0,30	10,81	0,30
84	SE32	2009	27100,00	10,21	3243,00	8,08	0,87	29,10	8,90	-1,50	9,92	0,36
84	SE32	2010	29400,00	10,29	3856,00	8,26	0,86	29,70	10,30	-1,10	10,50	0,35
84	SE32	2011	29400,00	10,29	5432,00	8,60	0,84	29,30	8,80	-2,30	10,39	0,33
84	SE32	2012	30000,00	10,31	4917,00	8,50	0,82	28,90	8,40	-0,70	10,26	0,34
84	SE32	2013	29400,00	10,29	5079,00	8,53	0,80	30,50	7,20	1,20	9,63	0,31
84	SE32	2014	29500,00	10,29	5480,00	8,61	0,78	31,10	7,40	3,30	9,87	0,31
84	SE32	2015	30600,00	10,33	4931,00	8,50	0,75	32,00	7,10	3,90	9,87	0,30
85	SE33	2005	26400,00	10,18	13267,00	9,49	2,41	29,00	8,80	-0,10	10,14	0,29
85	SE33	2006	29400,00	10,29	12688,00	9,45	2,44	29,20	8,50	0,10	11,03	0,30
85	SE33	2007	30100,00	10,31	14232,00	9,56	2,46	29,50	6,80	-2,50	10,64	0,29
85	SE33	2008	31200,00	10,35	14086,00	9,55	2,58	30,10	6,60	-1,40	11,55	0,32
85	SE33	2009	26400,00	10,18	11174,00	9,32	2,70	30,00	8,90	0,20	9,66	0,35
85	SE33	2010	31400,00	10,35	14173,00	9,56	2,51	31,50	9,50	0,60	11,22	0,37
85	SE33	2011	32200,00	10,38	13826,00	9,53	2,31	33,10	8,00	0,60	11,38	0,36
85	SE33	2012	32700,00	10,40	13221,00	9,49	2,41	33,90	7,70	1,30	11,18	0,37
85	SE33	2013	31800,00	10,37	12901,00	9,47	2,51	35,40	7,20	3,30	10,42	0,34
85	SE33	2014	31400,00	10,35	12615,00	9,44	2,61	37,00	7,40	3,50	10,51	0,33
85	SE33	2015	32100,00	10,38	12905,00	9,47	2,71	37,30	7,20	1,50	10,36	0,31
86	UKC1	2005	18700,00	9,84	55790,00	10,93	0,89	24,30	5,90	3,10	0,89	0,03
86	UKC1	2006	19800,00	9,89	53348,00	10,88	0,83	24,80	5,80	3,70	0,98	0,03
86	UKC1	2007	20000,00	9,90	49779,00	10,82	1,15	24,70	6,00	4,10	0,90	0,03
86	UKC1	2008	19800,00	9,89	45436,00	10,72	1,21	23,40	7,80	2,90	0,97	0,03
86	UKC1	2009	18500,00	9,83	39163,00	10,58	1,13	25,20	8,30	3,10	0,95	0,04
86	UKC1	2010	19300,00	9,87	35697,00	10,48	1,13	29,40	9,10	4,20	1,03	0,03
86	UKC1	2011	19000,00	9,85	35198,00	10,47	0,94	27,90	11,80	2,80	1,07	0,03

86	UKC1	2012	19400,00	9,87	33967,00	10,43	0,97	27,60	11,50	2,20	1,04	0,03
86	UKC1	2013	19700,00	9,89	37641,00	10,54	1,00	27,40	10,90	3,70	1,04	0,03
86	UKC1	2014	20400,00	9,92	39537,00	10,58	0,91	30,70	9,80	4,00	0,98	0,03
86	UKC1	2015	21200,00	9,96	35849,00	10,49	0,99	34,50	8,50	1,40	0,95	0,03
87	UKC2	2005	22200,00	10,01	4278,00	8,36	0,72	23,60	6,20	1,80	1,06	0,04
87	UKC2	2006	22900,00	10,04	4981,00	8,51	1,26	26,30	6,90	2,20	1,14	0,04
87	UKC2	2007	22700,00	10,03	5637,00	8,64	1,11	27,10	6,20	2,60	1,02	0,04
87	UKC2	2008	22200,00	10,01	6222,00	8,74	1,12	26,70	7,20	2,40	1,09	0,04
87	UKC2	2009	20200,00	9,91	4191,00	8,34	1,25	27,40	9,80	3,60	1,04	0,04
87	UKC2	2010	20800,00	9,94	3624,00	8,20	1,15	28,80	9,60	4,00	1,11	0,04
87	UKC2	2011	21400,00	9,97	5835,00	8,67	1,05	32,20	9,80	3,10	1,21	0,03
87	UKC2	2012	22200,00	10,01	6950,00	8,85	1,08	31,50	9,00	3,10	1,19	0,03
87	UKC2	2013	22200,00	10,01	8712,00	9,07	1,13	31,50	9,20	2,90	1,17	0,03
87	UKC2	2014	23100,00	10,05	7387,00	8,91	1,05	32,00	8,30	4,30	1,11	0,03
87	UKC2	2015	24600,00	10,11	5743,00	8,66	1,23	35,30	7,70	3,40	1,10	0,04
88	UKD3	2005	23800,00	10,08	7222,00	8,88	0,96	27,00	4,90	6,30	1,14	0,04
88	UKD3	2006	24800,00	10,12	8049,00	8,99	0,96	28,90	5,40	6,70	1,23	0,04
88	UKD3	2007	25100,00	10,13	8079,00	9,00	1,01	29,00	6,40	7,30	1,13	0,04
88	UKD3	2008	24200,00	10,09	7438,00	8,91	1,03	28,20	7,60	7,90	1,19	0,04
88	UKD3	2009	22600,00	10,03	6670,00	8,81	1,13	30,50	9,50	7,90	1,16	0,04
88	UKD3	2010	23400,00	10,06	7084,00	8,87	0,95	31,40	8,70	8,60	1,25	0,04
88	UKD3	2011	22900,00	10,04	7355,00	8,90	0,94	34,10	9,70	7,50	1,29	0,04
88	UKD3	2012	23700,00	10,07	6438,00	8,77	0,94	34,80	10,10	5,50	1,27	0,04
88	UKD3	2013	24400,00	10,10	7489,00	8,92	0,85	36,10	9,40	6,10	1,29	0,04
88	UKD3	2014	25000,00	10,13	7125,00	8,87	0,91	37,70	7,90	7,50	1,20	0,04
88	UKD3	2015	26300,00	10,18	6528,00	8,78	0,97	38,90	6,50	7,00	1,18	0,04
89	UKD4	2005	21800,00	9,99	5312,00	8,58	2,42	26,90	4,30	4,10	1,04	0,04

89	UKD4	2006	22000,00	10,00	5684,00	8,65	2,25	24,50	4,90	3,20	1,09	0,04
89	UKD4	2007	22800,00	10,03	5357,00	8,59	2,89	28,00	5,60	1,80	1,03	0,04
89	UKD4	2008	22100,00	10,00	4756,00	8,47	2,23	27,90	5,40	1,20	1,09	0,04
89	UKD4	2009	20200,00	9,91	4429,00	8,40	1,14	30,10	7,20	2,10	1,04	0,04
89	UKD4	2010	21000,00	9,95	4598,00	8,43	1,01	34,10	5,90	2,90	1,12	0,04
89	UKD4	2011	20700,00	9,94	4291,00	8,36	1,05	31,70	6,80	2,90	1,17	0,03
89	UKD4	2012	21500,00	9,98	4035,00	8,30	0,93	34,90	7,80	2,60	1,15	0,03
89	UKD4	2013	22000,00	10,00	3920,00	8,27	0,90	32,20	7,20	2,40	1,16	0,03
89	UKD4	2014	22600,00	10,03	4472,00	8,41	0,92	31,70	6,50	3,20	1,09	0,03
89	UKD4	2015	23900,00	10,08	4557,00	8,42	0,94	33,90	4,50	2,50	1,07	0,03
90	UKE1	2005	22200,00	10,01	88439,00	11,39	0,45	21,20	5,40	5,00	1,06	0,04
90	UKE1	2006	22800,00	10,03	90869,00	11,42	0,50	22,90	6,00	4,00	1,13	0,04
90	UKE1	2007	23800,00	10,08	92633,00	11,44	0,51	23,60	6,10	4,70	1,07	0,04
90	UKE1	2008	22700,00	10,03	91010,00	11,42	0,53	25,80	5,10	2,80	1,12	0,04
90	UKE1	2009	22600,00	10,03	76676,00	11,25	0,46	26,80	9,40	1,60	1,16	0,04
90	UKE1	2010	22100,00	10,00	76597,00	11,25	0,59	27,50	9,40	2,70	1,18	0,04
90	UKE1	2011	21800,00	9,99	79831,00	11,29	0,58	29,30	8,90	3,30	1,23	0,04
90	UKE1	2012	22300,00	10,01	82990,00	11,33	0,63	27,90	9,70	2,20	1,20	0,03
90	UKE1	2013	21900,00	9,99	85888,00	11,36	0,08	29,10	8,30	3,60	1,16	0,03
90	UKE1	2014	22500,00	10,02	83074,00	11,33	0,73	29,60	8,00	3,60	1,08	0,03
90	UKE1	2015	23400,00	10,06	79896,00	11,29	0,80	32,60	6,40	-0,90	1,05	0,03
91	UKF3	2005	19900,00	9,90	767,00	6,64	0,33	23,40	3,70	9,60	0,95	0,03
91	UKF3	2006	20700,00	9,94	834,00	6,73	0,37	23,90	4,70	12,00	1,03	0,03
91	UKF3	2007	21000,00	9,95	836,00	6,73	0,37	25,30	5,40	11,10	0,95	0,03
91	UKF3	2008	21000,00	9,95	961,00	6,87	0,46	24,10	6,20	8,50	1,03	0,04
91	UKF3	2009	18700,00	9,84	702,00	6,55	0,24	26,70	6,30	7,80	0,96	0,04
91	UKF3	2010	20000,00	9,90	951,00	6,86	0,55	28,40	4,90	6,50	1,07	0,03

91	UKF3	2011	20100,00	9,91	838,00	6,73	0,41	28,60	6,50	4,90	1,13	0,03
91	UKF3	2012	20800,00	9,94	829,00	6,72	0,31	29,10	8,50	6,70	1,11	0,03
91	UKF3	2013	21400,00	9,97	724,00	6,58	0,34	31,30	6,40	7,20	1,13	0,03
91	UKF3	2014	22200,00	10,01	824,00	6,71	0,35	31,30	4,60	9,20	1,07	0,03
91	UKF3	2015	22900,00	10,04	852,00	6,75	0,34	32,10	4,50	8,10	1,02	0,03
92	UKH1	2005	25500,00	10,15	27486,00	10,22	4,27	26,70	4,10	10,60	1,22	0,04
92	UKH1	2006	27200,00	10,21	28824,00	10,27	4,97	26,90	4,70	8,60	1,35	0,04
92	UKH1	2007	27000,00	10,20	29382,00	10,29	5,34	29,80	4,30	9,10	1,22	0,04
92	UKH1	2008	26500,00	10,18	28344,00	10,25	5,44	28,40	4,50	8,30	1,30	0,05
92	UKH1	2009	24100,00	10,09	27740,00	10,23	4,99	31,10	5,90	8,70	1,24	0,05
92	UKH1	2010	25300,00	10,14	29486,00	10,29	5,20	32,60	6,60	9,80	1,35	0,04
92	UKH1	2011	25500,00	10,15	30188,00	10,32	4,54	32,20	6,30	8,10	1,44	0,04
92	UKH1	2012	26600,00	10,19	29363,00	10,29	4,55	36,70	6,40	6,20	1,43	0,04
92	UKH1	2013	27000,00	10,20	28744,00	10,27	4,61	37,60	6,20	7,30	1,43	0,04
92	UKH1	2014	28100,00	10,24	31192,00	10,35	4,89	37,00	5,00	8,60	1,35	0,04
92	UKH1	2015	29500,00	10,29	31360,00	10,35	4,60	35,70	4,30	7,60	1,32	0,04
93	UKH3	2005	23400,00	10,06	4221,00	8,35	3,19	23,90	3,80	7,60	1,12	0,04
93	UKH3	2006	24500,00	10,11	4176,00	8,34	2,77	23,20	4,60	7,10	1,21	0,04
93	UKH3	2007	24800,00	10,12	3784,00	8,24	4,22	25,30	5,00	7,90	1,12	0,04
93	UKH3	2008	24000,00	10,09	3739,00	8,23	2,99	23,90	5,10	7,20	1,18	0,04
93	UKH3	2009	21700,00	9,99	2942,00	7,99	3,11	25,00	6,90	6,60	1,12	0,04
93	UKH3	2010	22900,00	10,04	3141,00	8,05	3,62	26,20	7,00	7,20	1,23	0,04
93	UKH3	2011	22900,00	10,04	3090,00	8,04	2,21	26,80	6,80	6,70	1,29	0,04
93	UKH3	2012	23000,00	10,04	3189,00	8,07	1,57	30,60	7,40	6,90	1,23	0,03
93	UKH3	2013	23400,00	10,06	3638,00	8,20	1,54	31,30	6,30	7,80	1,24	0,04
93	UKH3	2014	24700,00	10,11	3888,00	8,27	1,55	31,10	6,20	10,60	1,19	0,04
93	UKH3	2015	25900,00	10,16	4550,00	8,42	1,55	32,50	4,30	9,00	1,16	0,04

94	UKJ2	2005	28300,00	10,25	2704,00	7,90	1,23	37,10	3,70	7,90	1,35	0,05
94	UKJ2	2006	29800,00	10,30	2843,00	7,95	1,12	36,80	4,00	9,50	1,48	0,05
94	UKJ2	2007	30100,00	10,31	2992,00	8,00	1,09	38,60	4,00	9,30	1,36	0,05
94	UKJ2	2008	29600,00	10,30	2987,00	8,00	1,30	37,70	4,40	7,80	1,46	0,05
94	UKJ2	2009	27300,00	10,21	2597,00	7,86	1,44	39,30	5,60	8,50	1,41	0,05
94	UKJ2	2010	28700,00	10,26	2675,00	7,89	1,61	40,90	5,10	9,00	1,54	0,05
94	UKJ2	2011	28200,00	10,25	2835,00	7,95	1,73	43,10	5,30	7,90	1,59	0,05
94	UKJ2	2012	30000,00	10,31	2696,00	7,90	1,64	45,10	5,90	7,50	1,61	0,04
94	UKJ2	2013	30600,00	10,33	2306,00	7,74	1,54	44,20	5,50	7,80	1,62	0,05
94	UKJ2	2014	32000,00	10,37	2524,00	7,83	1,38	45,30	4,60	9,20	1,54	0,05
94	UKJ2	2015	33200,00	10,41	2772,00	7,93	1,55	46,40	3,70	9,00	1,48	0,05
95	UKJ3	2005	27500,00	10,22	48849,00	10,80	3,09	30,30	3,90	6,70	1,31	0,05
95	UKJ3	2006	28300,00	10,25	48607,00	10,79	3,35	30,80	4,60	5,60	1,40	0,05
95	UKJ3	2007	29400,00	10,29	50620,00	10,83	3,10	31,00	4,30	6,50	1,33	0,05
95	UKJ3	2008	28800,00	10,27	48106,00	10,78	2,74	32,20	3,50	6,80	1,42	0,05
95	UKJ3	2009	26600,00	10,19	43915,00	10,69	2,76	33,10	5,20	8,00	1,37	0,05
95	UKJ3	2010	28100,00	10,24	45151,00	10,72	2,50	35,20	6,30	8,70	1,50	0,05
95	UKJ3	2011	28000,00	10,24	44095,00	10,69	2,73	38,30	6,00	7,50	1,58	0,05
95	UKJ3	2012	29000,00	10,28	44058,00	10,69	2,45	40,20	6,30	6,20	1,55	0,04
95	UKJ3	2013	29300,00	10,29	41852,00	10,64	2,66	42,10	5,70	6,80	1,55	0,05
95	UKJ3	2014	30000,00	10,31	43091,00	10,67	2,50	43,50	4,20	7,80	1,44	0,04
95	UKJ3	2015	31300,00	10,35	44007,00	10,69	2,20	40,80	4,10	6,40	1,40	0,04
96	UKJ4	2005	23600,00	10,07	38488,00	10,56	2,19	25,90	4,20	9,30	1,13	0,04
96	UKJ4	2006	23800,00	10,08	44465,00	10,70	2,09	26,50	5,50	11,00	1,18	0,04
96	UKJ4	2007	24000,00	10,09	42576,00	10,66	2,25	28,30	5,60	11,60	1,08	0,04
96	UKJ4	2008	24000,00	10,09	41268,00	10,63	1,92	28,00	5,30	9,50	1,18	0,04
96	UKJ4	2009	21500,00	9,98	39819,00	10,59	2,52	28,80	7,30	9,70	1,11	0,04

96	UKJ4	2010	22600,00	10,03	39795,00	10,59	2,37	31,60	7,70	10,50	1,21	0,04
96	UKJ4	2011	22500,00	10,02	41468,00	10,63	3,23	33,10	8,20	9,70	1,27	0,04
96	UKJ4	2012	23200,00	10,05	36431,00	10,50	1,80	33,00	8,00	9,50	1,24	0,03
96	UKJ4	2013	23400,00	10,06	33895,00	10,43	1,27	35,30	7,60	8,40	1,24	0,04
96	UKJ4	2014	24200,00	10,09	36066,00	10,49	1,29	37,50	5,70	10,80	1,16	0,04
96	UKJ4	2015	25600,00	10,15	36416,00	10,50	1,25	36,30	5,30	11,10	1,14	0,04
97	UKK1	2005	28300,00	10,25	11206,00	9,32	2,81	34,20	3,50	9,60	1,35	0,05
97	UKK1	2006	28600,00	10,26	12261,00	9,41	2,89	35,40	3,30	9,30	1,42	0,05
97	UKK1	2007	29800,00	10,30	11178,00	9,32	2,66	35,90	3,40	9,30	1,34	0,05
97	UKK1	2008	29300,00	10,29	11527,00	9,35	2,90	34,00	3,70	7,30	1,44	0,05
97	UKK1	2009	27400,00	10,22	8999,00	9,10	2,76	35,90	5,70	7,00	1,41	0,05
97	UKK1	2010	29100,00	10,28	7272,00	8,89	2,68	38,10	5,40	7,90	1,56	0,05
97	UKK1	2011	28500,00	10,26	8202,00	9,01	2,67	40,70	6,50	8,20	1,61	0,05
97	UKK1	2012	29000,00	10,28	10762,00	9,28	2,60	41,10	6,10	8,40	1,55	0,04
97	UKK1	2013	29300,00	10,29	10633,00	9,27	2,59	40,80	6,20	8,40	1,55	0,05
97	UKK1	2014	31100,00	10,34	11421,00	9,34	2,63	44,70	4,80	9,70	1,50	0,05
97	UKK1	2015	32500,00	10,39	8877,00	9,09	2,05	45,50	3,90	10,10	1,45	0,05
98	UKK2	2005	23400,00	10,06	1712,00	7,45	0,80	29,30	3,50	6,80	1,12	0,04
98	UKK2	2006	24000,00	10,09	1806,00	7,50	0,76	30,50	3,70	8,50	1,19	0,04
98	UKK2	2007	24300,00	10,10	1405,00	7,25	0,55	30,40	3,70	8,80	1,10	0,04
98	UKK2	2008	23900,00	10,08	1518,00	7,33	0,63	30,00	4,10	5,00	1,18	0,04
98	UKK2	2009	22200,00	10,01	1127,00	7,03	0,79	30,70	6,50	5,50	1,14	0,04
98	UKK2	2010	22800,00	10,03	982,00	6,89	0,75	33,80	5,40	7,80	1,22	0,04
98	UKK2	2011	22700,00	10,03	950,00	6,86	0,72	33,90	6,00	7,30	1,28	0,04
98	UKK2	2012	23400,00	10,06	752,00	6,62	0,72	36,50	5,10	6,10	1,25	0,03
98	UKK2	2013	23500,00	10,06	634,00	6,45	0,81	38,60	5,40	5,80	1,24	0,04
98	UKK2	2014	24800,00	10,12	573,00	6,35	0,79	37,50	4,50	7,10	1,19	0,04

98	UKK2	2015	25900,00	10,16	582,00	6,37	0,82	40,10	3,90	7,90	1,16	0,04
99	UKK3	2005	20600,00	9,93	1270,00	7,15	0,25	22,50	3,40	6,00	0,98	0,03
99	UKK3	2006	22300,00	10,01	1103,00	7,01	0,15	27,00	3,90	6,70	1,11	0,04
99	UKK3	2007	21600,00	9,98	1121,00	7,02	0,15	30,70	4,40	6,70	0,97	0,03
99	UKK3	2008	21000,00	9,95	935,00	6,84	0,15	27,90	5,70	4,10	1,03	0,04
99	UKK3	2009	19600,00	9,88	774,00	6,65	0,15	28,20	5,10	4,40	1,01	0,04
99	UKK3	2010	20000,00	9,90	773,00	6,65	0,15	30,30	8,10	7,00	1,07	0,03
99	UKK3	2011	19900,00	9,90	688,00	6,53	0,20	32,60	6,20	7,60	1,12	0,03
99	UKK3	2012	21100,00	9,96	641,00	6,46	0,19	33,20	5,50	7,00	1,13	0,03
99	UKK3	2013	20700,00	9,94	656,00	6,49	0,19	32,70	5,60	8,60	1,10	0,03
99	UKK3	2014	20700,00	9,94	581,00	6,36	0,23	36,90	3,80	8,70	1,00	0,03
99	UKK3	2015	21900,00	9,99	513,00	6,24	0,36	32,00	4,50	5,40	0,98	0,03
100	UKK4	2005	22400,00	10,02	2308,00	7,74	0,70	25,90	3,90	7,20	1,07	0,04
100	UKK4	2006	23100,00	10,05	2452,00	7,80	0,68	27,70	4,40	6,50	1,15	0,04
100	UKK4	2007	23000,00	10,04	2486,00	7,82	0,74	29,10	4,70	6,20	1,04	0,04
100	UKK4	2008	22400,00	10,02	2322,00	7,75	0,71	31,80	3,80	2,70	1,10	0,04
100	UKK4	2009	20900,00	9,95	1944,00	7,57	0,73	32,50	7,10	2,20	1,08	0,04
100	UKK4	2010	22200,00	10,01	2208,00	7,70	0,94	33,90	6,50	4,30	1,19	0,04
100	UKK4	2011	21500,00	9,98	2141,00	7,67	0,91	35,20	6,50	5,80	1,21	0,04
100	UKK4	2012	22200,00	10,01	2374,00	7,77	0,66	38,10	5,80	6,00	1,19	0,03
100	UKK4	2013	22800,00	10,03	2161,00	7,68	0,79	35,60	7,00	5,00	1,21	0,04
100	UKK4	2014	23300,00	10,06	2089,00	7,64	0,86	37,90	5,00	7,90	1,12	0,03
100	UKK4	2015	24100,00	10,09	2217,00	7,70	1,08	40,10	3,70	9,50	1,08	0,03
101	UKL1	2005	17300,00	9,76	51476,00	10,85	0,62	24,10	5,00	3,80	0,83	0,03
101	UKL1	2006	18100,00	9,80	48343,00	10,79	0,63	23,60	5,40	5,40	0,90	0,03
101	UKL1	2007	18100,00	9,80	49270,00	10,81	0,61	25,60	5,50	5,40	0,82	0,03
101	UKL1	2008	17500,00	9,77	48590,00	10,79	0,59	26,90	6,10	3,70	0,86	0,03

101	UKL1	2009	16200,00	9,69	48068,00	10,78	0,88	30,40	8,90	2,50	0,83	0,03
101	UKL1	2010	16700,00	9,72	55298,00	10,92	0,64	31,40	9,20	2,90	0,89	0,03
101	UKL1	2011	17200,00	9,75	59809,00	11,00	0,67	31,70	9,90	3,10	0,97	0,03
101	UKL1	2012	18000,00	9,80	49420,00	10,81	0,61	32,00	9,20	2,30	0,96	0,03
101	UKL1	2013	18100,00	9,80	53676,00	10,89	0,64	33,50	7,80	3,60	0,96	0,03
101	UKL1	2014	18600,00	9,83	48353,00	10,79	0,86	33,50	6,90	3,90	0,89	0,03
101	UKL1	2015	19600,00	9,88	51147,00	10,84	0,80	36,40	6,50	-0,70	0,88	0,03
102	UKL2	2005	24400,00	10,10	2450,00	7,80	1,65	31,80	3,50	6,40	1,17	0,04
102	UKL2	2006	25200,00	10,13	2873,00	7,96	1,47	32,70	4,90	7,60	1,25	0,04
102	UKL2	2007	25700,00	10,15	3057,00	8,03	1,53	33,00	4,80	8,90	1,16	0,04
102	UKL2	2008	24000,00	10,09	2596,00	7,86	1,62	34,30	5,60	8,40	1,18	0,04
102	UKL2	2009	22300,00	10,01	1992,00	7,60	1,76	36,50	6,70	6,50	1,15	0,04
102	UKL2	2010	22800,00	10,03	2232,00	7,71	1,45	38,40	7,80	6,10	1,22	0,04
102	UKL2	2011	23400,00	10,06	2025,00	7,61	1,39	37,50	6,50	5,30	1,32	0,04
102	UKL2	2012	24000,00	10,09	1830,00	7,51	1,48	38,70	7,60	4,20	1,29	0,04
102	UKL2	2013	24300,00	10,10	1712,00	7,45	1,79	40,40	7,40	8,80	1,29	0,04
102	UKL2	2014	24600,00	10,11	1731,00	7,46	1,56	43,20	6,10	6,50	1,18	0,04
102	UKL2	2015	26000,00	10,17	1791,00	7,49	1,22	43,00	4,80	-2,60	1,16	0,04
103	UKM2	2005	25500,00	10,15	35440,00	10,48	2,37	37,20	5,10	6,90	1,22	0,04
103	UKM2	2006	27300,00	10,21	32758,00	10,40	1,95	38,20	5,30	7,60	1,35	0,04
103	UKM2	2007	27800,00	10,23	37716,00	10,54	2,10	38,20	5,10	8,20	1,25	0,04
103	UKM2	2008	26600,00	10,19	40032,00	10,60	2,06	39,40	4,80	7,10	1,31	0,05
103	UKM2	2009	25300,00	10,14	37500,00	10,53	2,17	38,50	7,60	7,00	1,30	0,05
103	UKM2	2010	25200,00	10,13	35298,00	10,47	2,27	39,70	7,80	8,50	1,35	0,04
103	UKM2	2011	25000,00	10,13	28800,00	10,27	1,26	43,20	7,40	7,30	1,41	0,04
103	UKM2	2012	25400,00	10,14	26174,00	10,17	1,25	46,10	7,60	4,50	1,36	0,04
103	UKM2	2013	26100,00	10,17	27181,00	10,21	2,30	47,80	7,20	4,70	1,38	0,04

103	UKM2	2014	26800,00	10,20	25124,00	10,13	2,29	50,40	5,60	5,50	1,29	0,04
103	UKM2	2015	28200,00	10,25	27589,00	10,23	2,21	50,60	6,00	6,00	1,26	0,04
104	UKM3	2005	23500,00	10,06	19931,00	9,90	0,91	31,00	6,20	1,10	1,12	0,04
104	UKM3	2006	24300,00	10,10	19348,00	9,87	0,87	32,60	6,00	2,60	1,20	0,04
104	UKM3	2007	24200,00	10,09	16457,00	9,71	0,89	33,90	5,20	4,10	1,09	0,04
104	UKM3	2008	23900,00	10,08	18455,00	9,82	0,94	33,20	5,40	3,90	1,18	0,04
104	UKM3	2009	22600,00	10,03	16301,00	9,70	1,11	33,30	7,50	3,50	1,16	0,04
104	UKM3	2010	22700,00	10,03	15935,00	9,68	1,14	34,30	10,10	4,10	1,21	0,04
104	UKM3	2011	22800,00	10,03	17349,00	9,76	1,50	40,30	9,60	2,40	1,28	0,04
104	UKM3	2012	23100,00	10,05	19845,00	9,90	1,51	39,60	9,20	0,10	1,24	0,03
104	UKM3	2013	23700,00	10,07	19283,00	9,87	1,10	40,80	8,20	1,10	1,25	0,04
104	UKM3	2014	25300,00	10,14	20608,00	9,93	1,04	44,00	7,10	1,80	1,22	0,04
104	UKM3	2015	26500,00	10,18	17196,00	9,75	1,11	44,40	6,60	1,10	1,18	0,04
105	UKM5	2005	31500,00	10,36	5537,00	8,62	1,50	34,60	3,90	9,30	1,51	0,05
105	UKM5	2006	34100,00	10,44	5610,00	8,63	1,53	34,80	2,60	11,70	1,69	0,05
105	UKM5	2007	37400,00	10,53	5921,00	8,69	1,48	37,50	3,30	11,00	1,69	0,06
105	UKM5	2008	39800,00	10,59	5665,00	8,64	1,48	38,60	3,00	10,00	1,96	0,07
105	UKM5	2009	37000,00	10,52	5367,00	8,59	1,63	38,90	3,60	11,00	1,91	0,07
105	UKM5	2010	38200,00	10,55	5271,00	8,57	1,46	40,40	3,60	10,70	2,04	0,07
105	UKM5	2011	38800,00	10,57	5218,00	8,56	2,93	44,80	4,60	9,70	2,19	0,06
105	UKM5	2012	41600,00	10,64	5516,00	8,62	2,61	44,00	4,70	9,10	2,23	0,06
105	UKM5	2013	42100,00	10,65	5233,00	8,56	1,45	43,50	4,70	9,30	2,23	0,07
105	UKM5	2014	44800,00	10,71	5605,00	8,63	1,96	47,50	4,00	7,00	2,15	0,07
105	UKM5	2015	44800,00	10,71	5844,00	8,67	1,38	52,20	3,20	8,60	2,00	0,06
106	UKM6	2005	24100,00	10,09	43406,00	10,68	0,50	28,60	3,50	9,70	1,15	0,04
106	UKM6	2006	23900,00	10,08	39906,00	10,59	0,70	29,80	3,20	9,10	1,18	0,04
106	UKM6	2007	24000,00	10,09	37703,00	10,54	0,59	36,70	2,20	9,70	1,08	0,04

106	UKM6	2008	24000,00	10,09	27916,00	10,24	0,63	35,60	2,00	7,30	1,18	0,04
106	UKM6	2009	22500,00	10,02	22913,00	10,04	0,67	40,70	4,30	5,60	1,16	0,04
106	UKM6	2010	22600,00	10,03	24023,00	10,09	0,97	37,60	7,00	5,20	1,21	0,04
106	UKM6	2011	23300,00	10,06	22577,00	10,02	0,94	37,60	6,90	1,60	1,31	0,04
106	UKM6	2012	23700,00	10,07	21273,00	9,97	0,83	38,80	8,10	0,30	1,27	0,04
106	UKM6	2013	24400,00	10,10	16563,00	9,71	0,69	42,50	5,60	1,30	1,29	0,04
106	UKM6	2014	25300,00	10,14	16274,00	9,70	0,58	41,60	4,40	0,50	1,22	0,04
106	UKM6	2015	26600,00	10,19	15924,00	9,68	0,53	41,10	4,10	2,10	1,19	0,04
107	UKN0	2005	21700,00	9,99	23560,00	10,07	0,92	26,60	4,70	8,40	1,04	0,04
107	UKN0	2006	22700,00	10,03	24155,00	10,09	0,96	27,70	4,30	9,70	1,13	0,04
107	UKN0	2007	23700,00	10,07	23616,00	10,07	0,97	29,40	3,80	10,20	1,07	0,04
107	UKN0	2008	22400,00	10,02	23031,00	10,04	0,99	30,40	4,40	8,90	1,10	0,04
107	UKN0	2009	20400,00	9,92	20338,00	9,92	1,44	28,50	6,40	7,20	1,05	0,04
107	UKN0	2010	20800,00	9,94	22308,00	10,01	1,41	31,50	7,10	5,80	1,11	0,04
107	UKN0	2011	20700,00	9,94	22745,00	10,03	1,43	29,10	7,20	5,20	1,17	0,03
107	UKN0	2012	21300,00	9,97	23226,00	10,05	1,59	32,10	7,40	4,20	1,14	0,03
107	UKN0	2013	21400,00	9,97	23805,00	10,08	1,61	32,50	7,50	5,80	1,13	0,03
107	UKN0	2014	21800,00	9,99	24034,00	10,09	1,33	34,00	6,40	5,30	1,05	0,03
107	UKN0	2015	22600,00	10,03	24002,00	10,09	1,68	33,60	6,10	6,20	1,01	0,03

Prilog 3. Životopis doktorandice s popisom objavljenih radova

Gorana Mudronja rođena je 08. svibnja 1989. godine u Rijeci. Završila je Osnovnu školu „Vladimir Gortan“ nakon čega je upisala Prvu sušačku hrvatsku gimnaziju. U četvrtom razredu srednje škole odlazi na razmjenu u Sjedinjene američke države gdje završava srednju školu „Clearview High School“. Po povratku u Hrvatsku 2008. godine upisuje Ekonomski fakultet u Rijeci na kojemu završava preddiplomski i diplomski studij, smjer „Menadžment“ te 2013. godine stječe titulu magistra ekonomije. Godine 2014. zapošljava se na Pomorskom fakultetu u Rijeci kao asistent na Zavodu za logistiku i menadžment u pomorstvu i prometu. Doktorski studij upisuje 2015. godine na Ekonomskom fakultetu u Rijeci, smjer „Poslovna ekonomija“, a završava ga 2019. obranom doktorske disertacije pod nazivom „Ekonomski učinci morskih luka i njihov utjecaj na regionalno gospodarstvo“.

Popis objavljenih radova:

a) Znanstveni radovi u drugim časopisima

1. Smojver, Ž.; **Stumpf, G.;** Schiozzi, D. (2017.): **Reorganization of the public utility companies**, Pomorstvo: Scientific Journal of Maritime Research, Vol. 31, No. 1, str. 53-59.
2. Šošić, I.; **Stumpf, G.;** Mezak, V. (2014.): **Planning cruises**, Pomorstvo: Scientific Journal of Maritime Research, Vol 28, No. 1, str. 65-69.
3. Rathman, D.; Debelić, B.; **Stumpf, G.** (2014.): **Structural analysis of development capabilities of the Port of Ploče as a potential container port within MoS services**, Pomorstvo: Scientific Journal of Maritime Research, Vol 28, No. 2, str. 140-150.

b) Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom

1. Jugović, A.; **Stumpf, G.;** Perić Hadžić, A. (2018.): **Consumption and Activities of Tourists in Cruise Tourism in the Republic of Croatia - Case Study of Port of Rovinj.** u M. Zanne, P. Bajec, P. Vidan, M. Krčum (ur.) *ICTS 2018 Maritime, Transport and Logistics Science, Conference proceedings* (str. 150-154). Portorož, Slovenia: Slovene Association of Transport Sciences, University of Ljubljana: Faculty of Maritime Studies and Transport, University of Split: Faculty of Maritime Studies
2. Jugović, A.; Munitić, N.; Tijan, E.; **Stumpf, G.** (2018.). **Independence of governance structure in state owned port authorities - example of Croatia.** u M. Bozina Beros, N. Recker, M. Kozina (ur.) *Economic and Social Development,* (str. 599-608). Rim,

Italija: Varaždin Development and Enterpreneurship Angency, University North, Croatia, Faculty of Management University of Warsaw, Poland.

3. Jugović, A.; **Stumpf, G.;** Schiozzi, D. (2017.). **General Competence Analysis of Management in Nautical Tourism Ports in the Republic of Croatia.** u D. Barković, B. Runzheimer (ur.) *Interdisciplinary Management Research XIII,* (str. 287-296). Opatija, Hrvatska: Josip Juraj Strossmayer University of Osijek, Faculty of Economics in Osijek Croatia, Postgraduate Doctoral Study program in Management, Hochschule Pforzheim University.
4. Sundać, D.; **Stumpf, G.** (2016.). **The Impact of Brain Drain on the Competitiveness of the Croatian Economy.** u M. Cingula, R. D. Vlahov, D. Dobrinić (ur.) *Economic and Social Development,* (str. 199-206). Varaždin, Hrvatska: Varaždin Developmenet and Enterpreneurship Agency, University of North.
5. Aksentijević, S.; Tijan, E.; **Stumpf, G.** (2015**..). Microeconomic and macroeconomic overview of ICT as a primary driver behind the digital economy.** u P. Biljanović (ur.) *38th International Convention on Information and Communication Technology Proceedings*, (str. 1444-1450). Opatija, Hrvatska: Croatian Society for Information and Communication Technology, Electronics and Microelectronics – MIPRO.

c) Sažeci u zbornicima skupova

1. Zubak, A.; Jugović, A.; **Stumpf, G.** (2014.). **Analysis and Evaluation of the Nautical Tourism in the Republic of Croatia and its Impact on Destination Development.** u T. Vranešević (ur.) *3rd Internetional M-Sphere Conference Book of Abstracts,* (str. 19). Zadar, Hrvatska: Accent.
2. **Stumpf, G.;** Jugović, A.; Škalamera – Alilović, D. (2019**.) Research and Development and Economic Growth: EU Port Regions.** u S. Drazgić (ur.) *Smart Governments, Regions and Cities, Economics of Digital Transformation EDT Conference 2019. Book of Abstracts* (str.21). Opatija, Hrvatska: University of Rijeka, Faculty of Economics and Business.

d) Neobjavljena sudjelovanja na skupovima

1. Jugović, A.; **Stumpf, G.;** Poletan Jugović, T. (2017.). **Complex Effects of Investments in Sea Ports and Their Impact on the Economy of the Republic of Croatia.** *Management International Conference.* Venecija, Italija.

IZJAVA

kojom ja, Gorana Mudronja, broj indeksa: 143/15 doktorandica Ekonomskog fakulteta Sveučilišta u Rijeci, kao autorica doktorske disertacije s naslovom: Ekonomski učinci morskih luka i njihov utjecaj na regionalno gospodarstvo

1. Izjavljujem da sam doktorsku disertaciju izradila samostalno pod mentorstvom prof. dr. sc. Alena Jugovića i komentorstvom izv. prof. dr. sc. Dunje Škalamera-Alilović. U radu sam primijenila metodologiju znanstvenoistraživačkog rada i koristila literaturu koja je navedena na kraju rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući navela u radu citirala sam i povezala s korištenim bibliografskim jedinicama sukladno odredbama Pravilnika o izradi i opremanju doktorskih radova Sveučilišta u Rijeci, Ekonomskog fakulteta u Rijeci. Rad je pisan u duhu hrvatskog jezika.

2. Dajem odobrenje da se, bez naknade, trajno pohrani moj rad u javno dostupnom digitalnom repozitoriju ustanove i Sveučilišta te u javnoj internetskoj bazi radova Nacionalne i sveučilišne knjižnice u Zagrebu, sukladno obvezi iz odredbe članka 83. stavka 11. Zakona o znanstvenoj djelatnosti i visokom obrazovanju (NN 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).

Potvrđujem da je za pohranu dostavljena završna verzija obranjene i dovršene doktorske disertacije. Ovom izjavom, kao autor dajem odobrenje i da se moj rad, bez naknade, trajno javno objavi i besplatno učini dostupnim studentima i djelatnicima ustanove.

Gorana Mudronja

_____

U Rijeci, 06. studenog 2019.