Stupanj usvojenosti zadružnih načela u modelu optimizacije zadružnog poslovanja

Nedanov, Aleksandar

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Agriculture / Sveučilište u Zagrebu, Agronomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:204:132140

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Repository Faculty of Agriculture University of Zagreb

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Aleksandar Nedanov

STUPANJ USVOJENOSTI ZADRUŽNIH NAČELA U MODELU OPTIMIZACIJE ZADRUŽNOG POSLOVANJA

DOKTORSKI RAD

Zagreb, 2021.

University of Zagreb

FACULTY OF AGRICULTURE

Aleksandar Nedanov

THE STRENGTH OF COOPERATIVE PRINCIPLES ACCEPTANCE IN OPTIMIZATION MODEL OF COOPERATIVE BUSINESS ACTIVITY

DOCTORAL THESIS

Zagreb, 2021.

Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

ALEKSANDAR NEDANOV

STUPANJ USVOJENOSTI ZADRUŽNIH NAČELA U MODELU OPTIMIZACIJE ZADRUŽNOG POSLOVANJA

DOKTORSKI RAD

Mentori:

doc. dr. sc. Lavoslav Čaklović

prof. dr.sc. Đurđica Žutinić

Zagreb, 2021

University of Zagreb

FACULTY OF AGRICULTURE

ALEKSANDAR NEDANOV

THE STRENGTH OF COOPERATIVE PRINCIPLES ACCEPTANCE IN OPTIMIZATION MODEL OF COOPERATIVE BUSINESS ACTIVITY

DOCTORAL THESIS

Supervisors:

Ph.D. Lavoslav Čaklović, Assistant Professor

prof. dr.sc. Đurđica Žutinić, Full Professor

Zagreb, 2021.

Bibliografski podaci:

- Znanstveno područje: Biotehničke znanosti
- Znanstveno polje: Poljoprivreda (agronomija)
- Znanstvena grana: Ekonomika
- Institucija: Sveučilište u Zagrebu Agronomski fakultet, Zavod za agrarnu ekonomiku i ruralni razvoj
- Voditelji doktorskog rada:
  doc.dr.sc. Lavoslav Čaklović, Prirodoslovno-matematički fakultet (prvi mentor)
  prof.dr.sc. Đurđica Žutinić, Agronomski fakultet (drugi mentor)
- Broj stranica: 196
- Broj slika: 16
- Broj tablica: 23
- Broj priloga: 2
- Broj literaturnih referenci: 189
- Datum obrane doktorskog rada: 15. srpnja 2021.
- Sastav povjerenstva za obranu doktorskog rada:
  izv.prof.dr.sc. Mario Njavro, Sveučilište u Zagrebu Agronomski fakultet
  prof.dr.sc. Josip Tica, Sveučilište u Zagrebu Ekonomski fakultet
  izv.prof.dr.sc. Lari Hadelan, Sveučilište u Zagrebu Agronomski fakultet

Rad je pohranjen u:
Nacionalnoj i sveučilišnoj knjižnici u Zagrebu, Ulica Hrvatske bratske zajednice 4 p.p. 550, 10 000 Zagreb,
Knjižnici Sveučilišta u Zagrebu Agronomskog fakulteta, Svetošimunska cesta 25, 10 000 Zagreb

Tema rada prihvaćena je na sjednici Fakultetskog vijeća Agronomskog fakulteta Sveučilišta u Zagrebu, održanoj dana 04.06.2013. te odobrena na sjednici Senata Sveučilišta u Zagrebu, održanoj dana 15.07.2013.

SVEUČILIŠTE U ZAGREBU

AGRONOMSKI FAKULTET

IZJAVA O IZVORNOSTI

Ja, **Aleksandar Nedanov**, izjavljujem da sam samostalno izradio doktorski rad pod naslovom:

STUPANJ USVOJENOSTI ZADRUŽNH NAČELA U MODELU OPTIMIZACIJE ZADRUŽNOG POSLOVANJA

Svojim potpisom jamčim:

- da sam jedini autor ovog doktorskog rada;
- da je doktorski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onih koji su u njemu navedeni;
- da sam upoznat s odredbama Etičkog kodeksa Sveučilišta u Zagrebu (članak 19).

Zagreb, ____. ____. _____. godine

_____

Potpis doktoranda

Doktorska disertacija je ocijenjena od strane povjerenstva u sljedećem sastavu:

izv. prof. dr. sc. Mario Njavro

Sveučilište u Zagrebu, Agronomski fakultet

prof. dr. sc. Josip Tica

Sveučilište u Zagrebu, Ekonomski fakultet

izv. prof. dr. sc. Lari Hadelan

Sveučilište u Zagrebu, Agronomski fakultet

Doktorska disertacija je obranjena na Agronomskom fakultetu Sveučilišta u Zagrebu na dan _____ pred povjerenstvom u sastavu:

izv. prof. dr. sc. Mario Njavro _____

Sveučilište u Zagrebu, Agronomski fakultet

prof. dr. sc. Josip Tica _____

Sveučilište u Zagrebu, Ekonomski fakultet

izv. prof. dr. sc. Lari Hadelan _____

Sveučilište u Zagrebu, Agronomski fakultet

Prvi mentor - doc. dr. sc. Lavoslav Čaklović

Lavoslav Čaklović je docent Matematičkog odsjeka Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu na kojem je 1972. godine završio diplomski studij. Na istoj instituciji je 1977. godine obranio magistarski rad na temu „*Sferičke funkcije na poluprostim Liejevim grupama*“. Pod mentorstvom prof.dr.sc. H. Berestyckog s fakulteta Ecole Normale u Parizu, 1991. godine, stekao je titulu doktora znanosti obranivši rad „*Applications of topological and variational methods on some problems in nonlinear analysis*“. U više navrata se usavršavao u inozemstvu gdje je u trajanju od 6 mjeseci sudjelovao u nastavi više međunarodnih škola iz diferencijalne geometrije, nelinearne analize i teorije kritičnih točaka na ICTP u Triesteu (1979.-1982.). U sklopu stipendijskog programa se usavršavao dvije akademske godine na Universite Paris XIII i Paris VI (1983/84 i 1984/85), a 2013. godine je završio Međunarodnu školu iz hiperboličkih diferencijalnih jednadžbi u Nici. Od 1972. godine aktivno sudjeluje u znanstveno-nastavnom radu PMF-a gdje predaje na četrnaest prediplomskih (*Matematika za biologe*, *Analiza 1 i Analiza 2 za fizičare*, *Teorijska mehanika*, *Matematičko modeliranje*, Diferencijalne jednadžbe, *Teorije skupova*, *Povijest informatike*, *Teorije odlučivanja*, *Teorije igara*, *Matematičke metode u marketingu*, *Praktikum za biologe*, *Linearno programiranje* i *Web programiranje*) i četiri poslijediplomska kolegija. Dvije akademske godine je održavao predavanja iz Linearne algebre na Universite Paris IX (1983/84 i 1984/85). Vodio je nastavu na Građevinskom fakultetu, Fakultetu elektrotehnike i računarstva, Kineziološkom fakultetu, i Tehnološkom fakultetu u Zagrebu, te na Pedagoškom fakultetu u Osijeku i Sveučilištu u Dubrovniku. Utemeljitelj je *Metode potencijala* i trenutno razvija modele ciljnog mišljenja s primjenama u umjetnoj inteligenciji i mrežama s povratnim vezama.

Kao glavni istraživač bio je voditelj na dva projekta: „*Teorija kritičnih točaka i singulariteta*“ (1996.-2002.) i „*Matematičko modeliranje višekriterijskih problema odlučivanja*“ (2002.-2006. i 2007.-2011.) pod pokroviteljstvom Ministarstva znanosti obrazovanja i športa RH. Bio je voditelj na dva informatička projekta i sudjelovao je u fazi izrade prijedloga projekta za izradu robota za selekciju nerazvrstanog otpada u suradnji s tvrtkom Codel iz Zagreba. Kao član istraživačke skupine sudjelovao je na projektu „*Organizacijsko-ekonomski koncept zadružne mreže hladnjača za voće i povrće*“. Aktivni je član Hrvatskog biometrijskog društva (HBMD) i Hrvatskog matematičkog društva (HMD).

Sudjelovao je na tridesetak međunarodnih kongresa i objavio je više od dvadesetak radova. Autor je tri udžbenika: *Zbirka zadataka iz linearne algebre (1992)*, *Geometrija linearnog programiranja (2010)* i *Teorija vrednovanja s naglaskom na Metodu potencijala: principi, metode i primjene (2014)*. Trenutno je u mirovini, sretno je oženjen i otac je troje djece.

Drugi mentor - prof. dr. sc. Đurđica Žutinić

Đurđica Žutinić je redovita profesorica u trajnom zvanju na Agronomskom fakultetu Sveučilišta u Zagrebu. Diplomski rad na temu „*Tendencije kretanja potrošnje mesa u SFRJ*“ je obranila 1980. godine na agroekonomskom odsjeku Poljoprivrednog fakulteta (danas Agronomski fakultet). Stupanj magistrice znanosti stječe 1988. godine kada je na Fakultetu političkih nauka Sveučilišta u Zagrebu obranila magistarski rad „*Kontroverze o socijalnoj stratifikaciji jugoslavenskog društva*“ pod vodstvom akademika prof.dr.sc. Josipa Županova. Znanstveni stupanj doktora znanosti je stekla 1996. godine na Agronomskom fakultetu gdje je obranila rad na temu „*Profesionalna orijentacija učenika i studenata poljoprivrednih škola i fakulteta prema obiteljskoj poljoprivredi u Hrvatskoj*“ pod mentorstvom prof.dr.sc. Vlade Puljiza. U sklopu doktorskog studija u više navrata se stručno usavršavala u inozemstvu gdje 1992. godine završava Međunarodnu školu za ruralne sociologe u Norveškoj.

Od 1980. godine sudjeluje u znanstvenom, nastavnom i stručnom radu Agronomskog fakulteta. Vodila je više znanstvenih i stručnih domaćih projekata, a kao istraživač aktivno je sudjelovala u pet međunarodnih projekata. Kao glavni autor ili u koautorstvu s drugim istraživačima objavila je zavidan broj radova koji su publicirani u znanstvenim časopisima (35), zbornicima skupova (24) ili kao sažeci skupova (31). Sudjelovala je u izradi još 14 rukopisa koji se klasificiraju kao elaborati, izvješća, nacrti zakona, pozvana predavanja, recenzije i studije. Urednica je dviju monografija i sudjelovala je kao koautor u objavljivanju tri knjige. Članica je tri međunarodne i dvije domaće asocijacije znanstvenika, a djeluje i kao urednica u dva znanstvena časopisa.

U nastavnim aktivnostima sudjeluje od 1987. godine. Trenutno je voditeljica jednog kolegija na preddiplomskom (*Metodologija znanstveno-istraživačkog rada u agroekonomici*) i tri kolegija na diplomskom studiju (*Ruralna sociologija*, *Socioekonomske i rodne analize*, *Poljoprivredno savjetodavstvo i komunikacije*). Suradnik je u nastavi na tri modula preddiplomskog studija. Na poslijediplomskom studiju je nositeljica modula „*Metodologija istraživanja ruralnih zajednica*“. Od akademske godine 2007./2008. kao gostujući nastavnik predaje „*Sociologija podeželja*“ na Fakultetu za kmetijstvo i biosistemske vede, Univerza Maribor u Sloveniji. Tijekom svoje nastavne aktivnosti bila je mentorica na 35 diplomska, 2 magistarska i 3 doktorska rada, a kao predsjednica ili član povjerenstva sudjelovala je u više od pedeset studentskih radova.

Njeno djelovanje u znanstveno-istraživačkoj, nastavnoj i stručnoj djelatnosti je prepoznato 2006. godine kada dobiva Medalju Agronomskog fakulteta za izniman doprinos. Sretno je udana i majka je dvoje djece.

Zahvale

Iskreno se zahvaljujem gospodinu i prof.dr.sc. Miroslavu Tratniku kojeg smatram kamenom temeljcem s kojim je moja doktorska priča simbolično započela. Zahvalan sam jer me kao studenta upoznao s mogućnostima zadrugarstva i pružio priliku da kao znanstveni novak pokažem vlastite potencijale. Zahvalan sam jer je bio podrška tijekom cijelog istraživačkog procesa i pisanja doktorske disertacije. Savjeti sadržajnih rasprava koje smo mnogobrojno puta vodili značajno su utjecali na cjelokupan koncept i izgled doktorskog rada.

Srdačno se zahvaljujem svojim mentorima, doc.dr.sc. Lavoslavu Čakloviću i prof.dr.sc. Đurđici Žutinić, s kojima sam zajedno izgrađivao i dijelio iskustva od prvog do posljednjeg dana. Sretan sam jer sam upoznao ljude koji su svoje znanje, pozitivnu energiju i karizmu, te savjete i iskustva učinkovito prenosili na mene. Zahvalan sam što su vjerovali u mene, a bez njihove bezuvjetne podrške i poticaja izrada ovoga rada ne bi bila moguća.

Zahvaljujem se upraviteljima zadruga gospodinu Marku Bačiću i Zlatku Kajmiću, ali i drugim zadrugarima koji su samoinicijativno pomagali u terenskom prikupljanju anketnih podataka. Bez njihove susretljivosti rezultati istraživačkog rada ne bi bili ostvarivi. Njihova volja doći će do izražaja u narednim generacijama praktičara i istraživača o zadružnom poduzetništvu.

Iz srca se zahvaljujem svim mojim kolegama s Odsjeka za Agrarnu ekonomiku. Događaje i okupljanja koja sam dijelio i provodio sa njima su više ili manje, izravno ili neizravno utjecali na moj profesionalni rad i osobni razvoj. Svima Vama dugujem duboku zahvalnost.

Najveću zahvalnost ipak posvećujem roditeljima. Od srca zahvaljujem mami na podršci i ljubavi tijekom cijelog života, a tati na usađenom načinu razmišljanja da se uvijek vrijedi boriti za ono što je ispravno i u što čovjek vjeruje. Uvijek ste bili i uvijek ćete biti dio mene.

Aleksandar Nedanov

SAŽETAK:

U doktorskoj disertaciji je predložen inovativni metodološki okvir za mjerenje i povezivanje stupnja usvojenosti zadružnih načela s poslovnim pokazateljima efikasnosti zadružnog poslovanja. Zadruge se od konvencionalnih oblika poduzetništva razlikuju u primjeni sedam zadružnih načela. Koncept svakog zadružnog načela u sebi sadrži sociološke čimbenike koji zadružno poslovanje reguliraju na istovjetan način kao što tržište reguliraju ekonomski čimbenici. Upravo zbog zadružnih načela zadruge predstavljaju praktičan model poslovanja za ispitivanje povezanosti između socijalnih i financijskih pokazatelja, ili za mjerenje utjecaja pokazatelja socijalnog kapitala na konačan financijski rezultat zadružnog poslovanja.

Interes doktorske disertacije je usmjeren prema ispitivanju međusobne povezanosti između zadružne dobiti i pokazatelja usvojenosti zadružnih načela. U tu svrhu empirijski je ispitan stupanj usvojenosti zadružnih načela među dionicima poljoprivrednih zadruga i postavljen je socioekonomski model optimizacije zadružnog poslovanja. Za potrebe empirijske analize je provedeno terensko istraživanje na području pet županija Slavonije, Baranje i zapadnog Srijema. Pomoću anketnog upitnika je ispitano 202 dionika koji surađuju s 23 poljoprivredne zadruge. Anketom su prikupljeni socioekonomski podaci, ispitano je poznavanje zadružnih načela i prikupljeni su podaci o organizaciji zadružnog poslovanja. Ekonomski pokazatelji poslovanja poljoprivrednih zadruga su dobiveni od strane Financijske agencije (FINA).

Pomoću Analize omeđivanja podataka su analizirani poslovni podaci poljoprivrednih zadruga u vremenskom razdoblju od pet godina. Rezultati analize su pokazali da samo dvije zadruge istodobno postižu ukupnu tehničku, čistu tehničku efikasnost i efikasnost razmjera, i predstavljaju idealan obrazac poslovanja. Još tri zadruge postižu čistu tehničku efikasnost. Međutim, unatoč efikasnom korištenju resursa ove zadruge posluju iznad svojih optimalnih razina zbog čega postižu padajuće stope povrata i rastuće prosječne troškove proizvodnje.

Pokazatelji za mjerenje stupnja usvojenosti zadružnih načela od strane dionika zadružnog poslovanja analizirani su korištenjem Konfirmatorne faktorske analize. Analiza je potvrdila robustnost (invarijantnost) modela koji sadrži dvadeset i jedan pokazatelj raspoređenih na šest mjernih konstrukata koji sadržajno odgovaraju teoriji zadružnih načela: *demokratičnost poslovanja* (N2), *gospodarsko sudjelovanje* (N3), *autonomija poslovanja* (N4), *zadružna edukacija* (N5), *suradnja među zadrugama* (N6) i *briga za lokalnu zajednicu* (N7).

Na kraju je provedena Metoda potencijala koja je potvrdila ekonomsku važnost zadružnog poduzetništva. Zadružna načela *gospodarsko sudjelovanje* i *suradnja među zadrugama* zauzimaju prva dva vodeća mjesta na obje razine samodualne hijerarhije, uz male razlike u ukupnom poretku. Kada se zadružna načela rangiraju obzirom na poslovne pokazatelje načelo *gospodarsko sudjelovanje* zauzima prvo, a načelo *suradnje među zadrugama* zauzima drugo mjesto u poretku. Kod rangiranja načela s uvažavanjem postojanja sinergije između zadružnih načela dolazi do zamjene njihovih pozicija i prvo mjesto zauzima načelo *suradnje među zadrugama*, a drugo mjesto u poretku načelo *gospodarsko sudjelovanje*.

Značaj ovog istraživanja proizlazi iz prilagodljivosti i fleksibilnosti metodološkog okvira koji omogućuje jednostavnu interpretaciju rezultata o usvojenosti zadružnih načela. Pri tome, objedinjuje sve kriterije koji opisuju teoriju zadružnog poduzetništva, daje jasan uvid koja zadružna načela su poželjnija i koji je kriterij uzrok tome. Metodološki okvir može pomoći u mjerenjima efikasnosti u drugim regijama RH (i šire) i zadružnim sektorima. On predstavlja opću paradigmu znanstvene metodologije za mjerenje efikasnosti zadružnog poslovanja uz istodobno uvažavanje teorije zadružnih načela. Metodologija predstavlja koristan dodatak klasičnim financijskim analizama koje se obično koriste za mjerenje efikasnosti investicijski usmjerenih poduzeća jer istodobno mjeri višekriterijsku učinkovitost zadružnog poslovanja.

Ključne riječi: poljoprivredne zadruge, zadružna načela, socijalni kapital, Konfirmatorna faktorska analiza, Analiza omeđivanja podataka, Metoda potencijala, Hrvatska.

ABSTRACT:

The doctoral dissertation proposes an innovative methodological framework for measuring and linking the cooperative principle's acceptance indicators with the business efficiency indicators. Cooperative entrepreneurship differs from other conventional business forms in the application of seven coop principles. The concept of each principle contains sociological factors that regulate cooperative business in the same manner as economic factors control the market. Because of these principles, cooperatives represent a practical business model for examining the relationship between social and financial indicators or measuring the impact of social capital indicators on the final financial result of cooperative business.

The scientific interest of the doctoral dissertation is to examine the interrelationship between profit and the principle's acceptance indicators. For this purpose, the strength of accepting principles among stakeholders is examined, and the socio-economic optimization model of cooperative business activity is constructed. The field research is conducted in the five counties of Slavonija, Baranja, and Western Srijem. The questionnaire is used to survey 202 stakeholders that are collaborating with 23 agricultural cooperatives. The survey collects data about the stakeholder's socio-economic status, member's attitudes towards principles, and information about the business organization. The Financial Agency (FINA) provided business indicators of cooperatives.

In the first step, the business indicators during the five years were analyzed using Data Envelopment Analysis. The results show that two cooperatives achieve overall technical, pure technical efficiency, and scale efficiency simultaneously and represent an ideal business pattern. The three other cooperatives achieved only pure technical efficiency. However, despite their efficient allocation of resources, these cooperatives operate above optimal levels, decrease returns to scale and increase average production costs.

In the second step, Confirmatory Factor Analysis confirmed the validity of the indicators measuring the strength of cooperative principles acceptance by stakeholders. The analysis confirms the robustness (invariance) of the model, which contains the six latent constructs with twenty-one indicators that correspond to the theory of cooperative principles: *democratic member control*, *economic participation*, *autonomy (independence)*, *education*, *cooperation among cooperatives*, and *concern for the local community*.

In the final step, the Potential Method confirmed the economic importance of cooperative entrepreneurship. Cooperative principles of *economic participation* (N3) and *cooperation among cooperatives* (N6) take two leading positions at both levels of the dual hierarchy, with minor differences in the overall ranking. According to business indicators, *economic participation* takes first place, while *cooperation among cooperatives* takes second place. They switch their positions when we are ranking principles concerning the existence of synergy between cooperative principles. The principle of *cooperation among cooperatives* is now in the first place, while *economic participation* takes second place.

The importance of the research arises in the adaptability and flexibility of the methodological framework that allows simple interpretation of the results about principles acceptance. Also, it combines all essential criteria of the theory of cooperative entrepreneurship and clarifies what principles are preferable and which criterium is the cause. The framework can assist in measuring efficiency in other Croatian regions (or beyond) and sectors. It would represent a general paradigm of scientific methodology for measuring cooperative business efficiency while respecting the theory of principles. This method could be a valuable addition to the classic financial analyzes commonly used to measure the efficiency of investment-oriented firms. Also, it allows the multicriteria efficiency measurement of co-op business activity.

Key words: agricultural cooperatives, cooperative principles, social capital, Confirmatory Factor Analysis, Data Envelopment Analysis, Potential Method, Croatia.

SADRŽAJ:

1. UVOD 1

1.1. Hipoteze i ciljevi istraživanja 5

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA 7

2.1. Definiranje pojmova zadrugarstvo, zadruga i zadružna načela 7

2.2. Pregled ekonomskih istraživanja o zadrugarstvu 11

2.2.1. Razvoj ekonomske teorije zadružnog poduzetništva 11

2.2.2. Ekonomska praksa zadružnog poduzetništva u istraživanjima 19

2.3. Pregled socioloških istraživanja o zadrugarstvu 27

2.4. Socijalni kapital u zadružnom poduzetništvu 33

2.5. Zadrugarstvo u svijetu i Republici Hrvatskoj 42

2.5.1. Ekonomski doprinos zadružnog poduzetništva u Europi i svijetu 42

2.5.2. Pregled zakonodavstva i razvoj zadrugarstva u RH 43

2.5.3. Financijski pokazatelji uspješnosti zadružnog sustava RH 50

3. METODOLOGIJA ISTRAŽIVANJA 54

3.1. Izvori podataka i metode istraživanja 54

3.2. Postupak izrade anketnog upitnika i prikupljanje podataka 54

3.3. Uzorkovanje i uzorak istraživanja 55

3.4. Metode za izradu modela optimizacije zadružnog poslovanja 61

3.5. Analiza omeđivanja podataka-AOMP 61

3.5.1. Pregled literature o razvoju i primjeni Analize omeđivanja podataka 61

3.5.2. Osnove mjerenja (ne)efikasnosti u Analizi omeđivanja podataka 63

3.5.3. Model s nepromjenjivim stopama povrata (CCR model) 67

3.5.4. Dualni model linearne funkcije koja minimizira ulazne podatke 70

3.5.5. Dualni model linearne funkcije koja maksimizira ulazne podatke 73

3.5.6. Model s promjenjivim stopama povrata (BCC model) 73

3.5.7. Usmjerenost ili orijentacija AOMP modela 76

3.5.8. Definiranje sličnosti i razlika između dva osnovna AOMP modela 78
3.5.9. Oblik skupa proizvodnih mogućnosti i stope povrata 79
3.6. Konfirmatorna faktorska analiza-CFA 82
3.6.1. Značaj i razlike između glavnih razreda faktorske analize (EFA vs. CFA)..... 82
3.6.2. Postupak promjene i preinake EFA modela 83
3.6.3. Ispitivanje razina robustnosti (invarijantnosti) CFA modela 85
3.6.4. Utvrđivanje robustnosti CFA modela nametanjem djelomičnih zahtjeva 86
3.6.5. Ispitivanje i procjena slaganja CFA modela s empirijskim podacima..... 87
3.7. Metoda potencijala 89
3.7.1. Subjektivno mjerenje 89
3.7.2. Graf preferencije 89
3.7.3. Metoda potencijala 90
3.7.4. Računanje potencijala u konzistentnom grafu preferencije..... 93
3.7.5. Računanje potencijala u nekonzistentnom grafu preferencije 94
3.7.6. Agregiranje toka i konstruiranje multigrafa preferencije 96
3.7.7. Hijerarhijsko odlučivanje s jednim i više ciljeva 97
3.7.8. Postupak vrednovanja hijerarhije metodom potencijala..... 99
3.7.9. Samodualna hijerarhija i revizija prioriteta..... 100

4. REZULTATI ISTRAŽIVANJA 101
4.1. Analiza tehničke efikasnosti i efikasnosti razmjera zadruga 101
4.1.1. Opis izvornog skupa varijabli za definiranje konačnog AOMP modela..... 101
4.1.2. Određivanje broja ulaznih i izlaznih podataka u AOMP modelu 104
4.2. Konfirmatorna faktorska analiza stupnja usvojenosti zadružnih načela..... 110
4.2.1. Eksplorativna faktorska analiza usvojenosti zadružnih načela 110
4.2.2. Preinake EFA modela za mjerenje stupnja usvojenosti zadružnih načela..... 113
4.2.3. Mogućnosti poboljšanja CFA modela uvažavanjem kovarijance varijabli..... 118
4.2.4. Ispitivanje razina robustnosti (invarijantnosti) CFA modela 119
4.2.5. Ispitivanje robustnosti CFA modela nametanjem djelomičnih zahtjeva 122
4.2.6. Ispitivanje konstruktne validnosti CFA modela..... 124
4.2.7. Ispitivanje karakteristika metrike CFA modela 127
4.2.8. Ispitivanje i procjena slaganja CFA modela s empirijskim podacima..... 130

4.2.9. Ispitivanje pouzdanosti CFA modela 131
4.3. Procjena stupnja usvojenosti zadružnih načela Metodom potencijala 134
4.3.1. Agregiranje preferencija 134
4.3.2. Povezivanje poslovnih pokazatelja sa zadružnim načelima 135
4.3.3. Konkretizacija vrednovanja hijerarhije 138

5. RASPRAVA 140
5.1. Efikasnost zadružnog poslovanja po godinama 140
5.2. Efikasnost zadružnog poslovanja u cijelom razdoblju 142
5.3. CFA model za mjerenje stupnja usvojenosti zadružnih načela 145
5.4. Rangiranje poslovnih varijabli obzirom na zadružna načela 150
5.5. Rangiranje zadružnih načela obzirom na poslovne varijable 157
5.6. Sinergija zadružnih načela 162
5.7. Potvrđivanje istraživačkih hipoteza 165

6. ZAKLJČCI ISTRAŽIVANJA 167

7. POPIS LITERATURE 169

8. PRILOZI 185
8.1. Prilog 1: Anketni upitnik za dionike zadružnog poslovanja 185
8.2. Prilog 2. Deskriptivna analiza pokazatelja reduciranog skupa 192

9. ŽIVOTOPIS AUTORA I POPIS OBJAVLJENIH RADOVA 193

POPIS KORIŠTENIH KRATICA:

AIC	hrvatski	Akaike informacijski kriterij (mjera) o gubitku informacija
	engleski	Akaike's Information Criterion - AIC
ANP	hrvatski	Analitički mrežni proces
	engleski	Analytic Network Process - ANP
AOMP	hrvatski	Analiza omeđivanja podataka
	engleski	Data Envelopment Analysis - DEA
BDP	hrvatski	Bruto društveni proizvod
	engleski	Gross Domestic Product - GDP
CA	hrvatski	Analiza korespondencije
	engleski	Correspondence Analysis - CA
CFA	hrvatski	Konfirmatorna faktorska analiza
	engleski	Confirmatory Factor Analysis - CFA
CFI	hrvatski	Komparativni indeks slaganja
	engleski	Comparative Fit Index - CFI
DMU	hrvatski	Jedinica odlučivanja ili donositelj odluke
	engleski	Decision Making Unit - DMU
ECVI	hrvatski	Indeks očekivane validnosti
	engleski	Expected Cross-Validation Index - ECVI
EFA	hrvatski	Eksplorativna faktorska analiza
	engleski	Exploratory Factor Analysis - EFA
EIB	hrvatski	Europska investicijska banka
	engleski	The European Investment Bank - EIB
EK	hrvatski	Europska komisija
	engleski	European Commission - EC
EU	hrvatski	Europska unija
	engleski	European Union - EU
EVA	hrvatski	Dodana ekonomska vrijednost
	engleski	Economic Added Value - EVA
HCZP	hrvatski	Hrvatski centar za zadružno poduzetništvo
	engleski	Croatian Centre for Cooperative Entrepreneurship - CCCE
HNB	hrvatski	Hrvatska narodna banka
	engleski	Croatian National Bank
HSZ	hrvatski	Hrvatski savez zadruga
	engleski	Croatian Co-operative Alliance - CCA
ICA	hrvatski	Međunarodni savez zadruga
	engleski	International Co-operative Alliance - ICA

ILO	hrvatski	Međunarodna organizacija rada
	engleski	International Labor Organization - ILO
ILO COOP	hrvatski	Jedinica za zadrugarstvo u sklopu Međunarodne organizacije rada
	engleski	International Labor Organization Cooperatives Unit - ILO COOP
IOF	hrvatski	Investicijski usmjereno poduzeće
	engleski	Investor-Oriented Firm - IOF
KU	hrvatski	Kreditne unije
	engleski	Credit Union - CU
MI	hrvatski	Indeksi prilagodbe
	engleski	Modification indices - MI
MFA	hrvatski	Višestruka faktorska analiza
	engleski	Multiple Factor Analysis - MFA
MP	hrvatski	Metoda potencijala
	engleski	Potential Method - PM
N1	hrvatski	Načelo 1 - Dragovoljno i otvoreno članstvo
	engleski	Principle 1 - Voluntary and Open Membership
N2	hrvatski	Načelo 2 - Demokratično upravljanje
	engleski	Principle 2 - Democratic Member Control
N3	hrvatski	Načelo 3 - Gospodarsko sudjelovanje članova
	engleski	Principle 3 - Member Economic Participation
N4	hrvatski	Načelo 4 - Autonomija i neovisnost zadruge
	engleski	Principle 4 - Autonomy and Independence
N5	hrvatski	Načelo 5 - Obrazovanje, osposobljavanje i obavještavanje članova
	engleski	Principle 5 - Education, Training, and Information
N6	hrvatski	Načelo 6 - Suradnja među zadrugama
	engleski	Principle 6 - Cooperation among Cooperatives
N7	hrvatski	Načelo 7 - Briga o zajednici
	engleski	Principle 7 - Concern for the Local Community
NN	hrvatski	Narodne novine
	engleski	Official Gazette - OG
OG	hrvatski	Obiteljsko gospodarstvo
	engleski	Household
OPG	hrvatski	Obiteljsko poljoprivredno gospodarstvo
	engleski	Family Farm, Agricultural Household
PCA	hrvatski	Analiza glavnih komponenti
	engleski	Principal Component Analysis - PCA
PZ	hrvatski	poljoprivredna zadruga
	engleski	Agricultural Cooperatives
RH	hrvatski	Republika Hrvatska

	engleski	Republic of Croatia
ROA	hrvatski	Stopa povrata na imovinu
	engleski	Return on Assets - ROA
ROE	hrvatski	Stopa povrata na kapital
	engleski	Return on Equity - ROE
ROI	hrvatski	Stopa povrata na ulaganja
	engleski	Return on Investment - ROI
RMSEA	hrvatski	Prosječna standardizirana rezidualna pogreška mjerenja
	engleski	Root Mean Square Error of Approximation - RMSEA
RZ	hrvatski	Radničke zadruga
	engleski	Worker Cooperatives
SAD	hrvatski	Sjedinjene Američke države
	engleski	United States of America - USA
SEM	hrvatski	Modeliranje strukturnih jednadžbi
	Engleski	Structural Equation Modeling - SEM
SOCZ	hrvatski	Socijalne zadruge
	engleski	Social Cooperatives
SRMR	hrvatski	Standardizirana prosječna kvadratna kovarijanca reziduala
	engleski	Standardized Root Mean Square Residual - SRMR
SZ	hrvatski	Stambene zadruge
	engleski	Housing Cooperatives
ŠKZ	hrvatski	Štedno-kreditne zadruge
	engleski	Savings and Loans Cooperatives
TLI	hrvatski	Tucker-Lewisov indeks slaganja
	engleski	Tucker-Lewis Fit Index - TLI
UN	hrvatski	Ujedinjeni narodi
	engleski	United Nations - UN

POPIS TABLICA:

Tablica 2.1. Pregled zakonodavstva i promjene u zadružnom sektoru (1995.-2014.) 46

Tablica 2.2. Socio-demografski pokazatelji razvijenosti zadružnih sektora (2011.-2016.) 49

Tablica 2.3. Financijski rezultat ukupnog zadružnog sektora u RH (2009. - 2013.) 51

Tablica 3.1. Veličina uzorka i poljoprivrednog zadružnog sektora na području pet županija 57

Tablica 3.2. Sociodemografska obilježja dionika uzorkovanih poljoprivrednih zadruga 60

Tablica 3.3. Sažeti prikaz obilježja CCR i BCC modela 79

Tablica 4.1. Opis sadržaja varijabli izvornog skupa za definiranje konačnog AOMP modela 103

Tablica 4.2. Opisna statistika svih potencijalnih ekonomskih varijabli izvornog skupa (N = 23).... 105

Tablica 4.3. Matrica korelacije između ulaznih i izlaznih varijabli poslovnih podataka 106

Tablica 4.4. Zadržana varijanca i mjere efikasnosti nakon uklanjanja varijabli..... 109

Tablica 4.5. Rezultati eksplorativne faktorske analize (model sa 7 i 6 faktora) 112

Tablica 4.6. Rezultati pristajanja i ispitivanje razlika između potencijalnih CFA modela 115

Tablica 4.7. Mjerenje robustnosti modela obzirom na socioekonomska obilježja ispitanika 120

Tablica 4.8. Pouzdanost i validnost faktora u CFA modelu usvojenosti zadružnih načela [a]..... 125

Tablica 4.9. Rezultati testiranja i indeksi slaganja ugniježđenih strukturalnih modela..... 128

Tablica 4.10. Podaci o pouzdanosti skale za mjerenje usvojenosti zadružnih načela..... 131

Tablica 4.11. Laplaceova matrica i vektor razlike toka za tri multigrafa preferencije..... 136

Tablica 4.12. Matrice incidencije za grafove preferencije samodualne hijerarhije..... 137

Tablica 5.1. Efikasnost poslovanja poljoprivrednih zadruga po godinama 141

Tablica 5.2. Efikasnost poljoprivrednih zadruga u pet godina ukupno..... 144

Tablica 5.3. Potencijal i poredak poslovnih pokazatelja (Razina 2) 152

Tablica 5.4. Potencijal i poredak zadružnih načela (Razina 3) 157

Tablica 5.5. Poredak zadružnih načela nakon treće i četvrte razine samodualne hijerarhije 163

POPIS SLIKA:

Slika 2.1. Usporedni integrativni učinci ekonomskog i socijalnog kapitala (Valentinov, 2004). 40

Slika 2.2. Omjer prihoda i troškova po zadružnim sektorima (2009.-2013.). 51

Slika 2.3. Povrat imovine (ROA) po zadružnim sektorima (2009.-2013.). 52

Slika 3.1. Granica efikasnosti za skup poljoprivrednih zadruga u dva različita CCR modela. 65

Slika 3.2. Granice efikasnosti i skupovi proizvodnih mogućnosti CCR i BCC modela..... 75

Slika 3.3. Granice efikasnosti u ulazno (lijevo) i izlazno usmjerenom CCR modelu (desno). 77

Slika 3.4. Mjere efikasnosti u uvjetima nepromjenjivih i promjenjivih stopa povrata..... 81

Slika 3.5. Prikaz intenziteta preferencije između dva vrha u grafu preferencije. 89

Slika 3.6. Primjer konzistentnog grafa preferencije sa šest čvorova (alternativa). 91

Slika 3.7. Primjer nekonzistentnog i nepotpunog grafa preferencije..... 96

Slika 3.8. Samodualna hijerarhija s više ciljeva i četiri razine za sve elemente odlučivanja..... 98

Slika 4.1. Konačan CFA model za mjerenje usvojenosti zadružnih načela (Model 1.8 - M1)..... 133

Slika 4.2. Multigrafovi preferencije samodualne hijerarhije na razini 2 i razini 3..... 134

Slika 4.3. Grafovi preferencije za svako načelo zasebno (Razina 2)..... 139

Slika 4.4. Grafovi preferencije za svaki poslovni pokazatelj zasebno (Razina 3). 139

Slika 4.5. Grafovi preferencije za svako načelo zasebno (Razina 4)..... 139

1. UVOD

Pronalazak i implementacija prikladnih gospodarskih programa koji će omogućiti učinkovito iskorištavanje raspoloživih resursa i preradu poljoprivrednih proizvoda od strane lokalnog stanovništva, postale su prioritetne zadaće nacionalnih politika u zemljama EU. Dosadašnja iskustva u razvoju agrarne politike EU pokazuju, kako se osim ekonomskih pitanja, sve više pažnje posvećuje zaustavljanju negativnih društvenih promjena *senilizacije*, *deagrarizacije*, *nemogućnosti akumuliranja kapitala*, *nedostatka radne snage* i *disperzirane naseljenosti* u ruralnim područjima koja slijede globalni proces liberalizacije tržišta. Sukladno s time dolazi do značajnog pada broja poljoprivrednih gospodarstava kojeg prati trend restrukturiranja, okrupnjavanja i unapređenja posjedovne strukture na razini EU.[1] Mjere agrarne politike u unapređenju i revitalizaciji seoskih prostora sve više uključuju ekonomsku domenu ruralnog poduzetništva, menadžmenta i marketinga u rješavanje društvenih pitanja poput podizanja životnog standarda, zadržavanja seoskog stanovništva u ruralnim prostorima i jačanja društvenog aktivizma u funkciji lokalnog ekonomskog razvitka.[2] U zadnjih tridesetak godina socijalna ekonomija se afirmirala kao stup društvene korisnosti, unutar političkih i pravnih krugova zemalja EU koje svoje nacionalne strateške dokumente usmjeravaju upravo prema „pluralizmu“ dragovoljnih poslovnih organizacija trećeg sektora (Chaves Avila i Luis Monzón Campos, 2010). U tom povezivanju prednjače zadruge koje se pokazuju kao uspješan model organiziranja lokalnih poljoprivrednika i učinkovit instrumentarij za nosioce agrarne politike u konkretnim realizacijama postavljenih mjera (European Parliament, 2012).

U odnosu na razvijene europske zemlje Hrvatska je do Domovinskog rata imala suprotne tendencije u razvitku poljoprivrednog sektora. Dok su zapadnoeuropske zemlje provodile proces koncentracije, kod nas se u sklopu SFR Jugoslavije, provodio proces permanentnog usitnjavanja poljoprivrednih kapaciteta.[3] Tadašnje mjere agrarne politike bile su naklonjene

[1] Unatoč padu broja poljoprivrednih gospodarstava u EU-i je površina zemljišta koja se upotrebljava za proizvodnju i dalje stabilna. Od ukupno 10,5 milijuna poljoprivrednih gospodarstava dvije trećine je manje od 5 ha i koriste samo 6,9% poljoprivrednih površina u EU. Sva poljoprivredna gospodarstva u EU raspolažu s ukupno 173 milijuna hektara obradivog zemljišta (EUROSTAT, 2016).

[2] Mjere politike teže stvaranju značajne društvene vrijednosti u obliku zaposlenja, unapređenja uvjeta rada, smanjenja siromaštva i razine sive ekonomije, povećanju povjerenja prema institucijama koje potiču štednju i ulaganja lokalnog stanovništva, zaštitu prirode, promoviraju aktivno stanovništvo, jačanje socijalnog kapitala i izgradnju potrebne društvene infrastrukture poput vrtića i škola.

[3] Agrarnom reformom (1945.) je određen zemljišni maksimum od 35 hektara, da bi se Zakonom o zemljišnom fondu općenarodne imovine (1953.) ovo ograničenje dodatno smanjilo na 10 hektara. Svim poljoprivrednicima koji su imali više od propisanog oduzimano je zemljište koje postaje državno (društveno) vlasništvo. Republika Hrvatska je ukinula zemljišni maksimum Ustavom iz 1990. godine.

društvenom sektoru kojem je politički dodijeljena uloga nositelja poljoprivredne proizvodnje. Nositelji društvenog sektora bili su kombinati kojima su se po propisu o udruženom radu iz 1965. godine poslovno pripajale i zadruge. U isto vrijeme agrarna politika je marginalizirala značaj privatnog sektora i sprječavala povrat novčanog kapitala na selo. Navedene mjere agrarne politike ne samo da su doprinijele smanjenju tržišne konkurentnosti poljoprivredne proizvodnje čije posljedice vidimo i danas, nego su i potaknule razvoj negativne percepcije o zadružnom poduzetništvu kao pogrešnoj ideologiji bivšeg političko-društvenog uređenja.[4] Tome treba pridružiti procese depopulacije i starenja stanovništva, stalnu tendenciju rasta neobrađenih površina, problem imovinsko-pravnih odnosa oko zemljišta, kao i nepostojanje pravne regulative koja bi spriječila proces „atomizacije" tj. cijepanja zemljišnih posjeda ispod zakonom propisane veličine (Mihalj, 1998: 232-235). Novonastale društveno-političke promjene nakon tranzicije i nedavnog ulaska RH na tržište EU, pogodovale su „snažnom" tržišnom uređenju kapitalne ekonomije u domaćoj poljoprivredi. Strateške mjere agrarne politike sve više počinju naglašavati važnost OPG-a kao temeljnog stupa razvoja hrvatske poljoprivrede, ali u operativnim mjerama i dalje ne zauzimaju prioritetnu poziciju iako sadrže najveći dio poljoprivredno prerađivačkih resursa i kapaciteta u Hrvatskoj.[5] Iako o tome nema transparentnih podataka, Župančić (2005) navodi kako je privatizacija u poljoprivredi tekla prilično kaotično i malo je vjerojatno za očekivati da su perspektivno bolji i poslovno vitalniji poljoprivrednici „*odlomili veći dio kolača*". Proces prilagođavanja i uvođenja regulativa koje bi osnažile srednji sloj poljoprivrednika nije mogao pratiti brzinu širenja privatizacije. U tom procesu koji je pogodovao „*polarizaciji posjedovne strukture*" zanemarene su spomenute društvene okolnosti ruralnih krajeva i ekonomska određenja tržišno orijentiranih OPG-a.

Franić i sur. (2004) konstatiraju da je zbog preusmjeravanja političkih interesa i alokacije resursa u poljoprivredi tijekom tranzicijskog razdoblja, nastao jaz zbog kojeg je RH još uvijek u potrazi za „pravim" nositeljima poljoprivrednog razvoja, sposobnim da daju odgovore na izazove međunarodnih ekonomskih i sociokulturnih integracija. Radinović i Žutinić (2007) iznose podatke koji jasno ukazuju da je velika rascjepkanost ionako malih posjeda i nizak stupanj profesionalizacije radne snage u obiteljskoj poljoprivredi glavni razlog njene tržišne nekonkurentnosti. Ograničeni proizvodni kapaciteti, nepovoljna organizacijska struktura,

[4] Unatoč povlaštenom i monopolističkom položaju na tržištu mnogi poljoprivredni kombinati nisu uspjeli osigurati poslovnu efikasnost. Početkom 1990-ih godina kombinati prolaze kroz dugotrajan put privatizacije koji je obilježen brojnim aferama, novim zaduživanjima i manipulacijama nakon kojih poljoprivrednici zauvijek gube vlasništvo nad zemljištem (Franić i sur., 2004: 67).

[5] Prema Popisu poljoprivrede iz 2003. godine, u RH je registrirano 448.532 OG-a što je za čak 18% manje u odnosu na 1991. godinu. Podaci Eurostata iz 2010. godine pokazuju da je u RH registrirano 233.280 poljoprivrednih kućanstava, a prosječna veličina je 5,6 hektara. Podaci Popisa poljoprivrede (2003) govore da OPG-a u Hrvatskoj u prosjeku imaju 4,3 parcele, svaka veličine oko 0,61 ha.

niska produktivnost, neorganizirani otkup i prodaja proizvoda, te slabija povezanost OPG-a s prehrambenim opskrbnim lancima samo se neki od razloga trenutno nezavidne situacije u domaćoj poljoprivredi (Franić i sur., 2014). Dostupni podaci javnih institucija potvrđuju da postojeće prepreke povećanju tržišne konkurentnosti nisu samo prirodne naravi (veličina i rasparceliranost posjeda), nego i društvenog i političkog karaktera. Prepreke se uočavaju u poslovnom povezivanju, visokim troškovima inputa u sektoru nabave, otežanom pristupu OPG-a komercijalnim kreditima za razvoj poljoprivrede i pretjeranom utjecaju politike na gospodarske odluke.[6] Stipetić (2005) upozorava da u takvim uvjetima, integracija u globalno tržište EU, može predstavljati opasnost za hrvatsku poljoprivredu ako ne bude pravodobno korigirana odgovarajućim potezima bankarskog sustava i državne politike.[7] Dugoročan razvitak hrvatske poljoprivrede na tržištu EU i jačanje njene međunarodne konkurentnosti prvenstveno će ovisiti o organizaciji poljoprivrede i poslovnom umrežavanju OPG-a koje povezuju slične ekonomske mogućnosti i proizvodni kapaciteti. Poljoprivredne zadruge imaju značajnu ulogu u suvremenoj poljoprivrednoj proizvodnji koja zahtjeva razgranatu informacijsku, tržišnu i financijsku infrastrukturu, kao i snažne državne mehanizme potpore (Župančić, 2005).

Relevantni dokumenti EU zadruge često spominju u kontekstu sveobuhvatnog rješenja za socijalne i ekonomske probleme tranzicijskih gospodarstva. U svojim cjelovito elaboriranim stajalištima o promicanju zadrugarstva Europska komisija jasno ističe golem gospodarski, društveni i kulturni značaj zadruga u Europi. Babić i Račić (2011) navode da zadružni model poslovanja ima jaku potporu europskih institucija jer istodobno stvara ekonomske i socijalne učinke. Zadruge pridonose ekonomskoj aktivnosti, proširuju mogućnosti zapošljavanja i jačaju socijalnu koheziju lokalnih zajednica. Iskustva pokazuju da mogućnosti i perspektive razvoja zadrugarstva uvelike ovise o zakonskim, fiskalnim, političkim i institucijskim okvirima zemalja u kojima zadruge obitavaju. Pravni okviri koji reguliraju transparentnost zadružnog poslovanja omogućuju zadrugama da postanu važan čimbenik razvojne stabilnosti za resursno limitirana poljoprivredna gospodarstava (Tratnik i sur., 2007: 74). Iako je zadružna legislativa sa zadnjim izmjenama i dopunama Zakona o zadrugama u Hrvatskoj (NN, br. 34/2011; 125/2013; 76/2014; 114/2018 i 98/2019) usklađena prema EU standardima,

[6] Nepostojanje suvremene državne poljoprivredne uprave, permanentnog sustava školovanja i obrazovanja poljoprivrednika, te snažne i primjerene savjetodavne službe otežava proces obnove i razvoja poljoprivrede koja će biti u skladu s europskim okruženjem (Budin, 1992: 51).

[7] Nakon osamostaljenja ruralni prostori su ostali bez financijskih institucija, infrastrukturnih projekata, te tehničkih i profesionalnih usluga koje bi obnovile konkurentsku sposobnost na zajedničkom tržištu EU. Zbog toga RH već tada počinje zaostajati za europskim proizvođačima. Novonastala situacija je dodatno potencirala imanentne poteškoće ruralnih sredina (Stipetić, 2005: 39-46; Mataga, 2009: 234-251).

operativna potpora (porezna, financijska i institucijska) i dalje usporava revitalizaciju razvoja zadrugarstva (Nedanov i Žutinić, 2015). Ekonomske analize potvrđuju da je u RH doprinos zadruga u proizvodnji, otkupu i prometu poljoprivrednih proizvoda marginalan, u odnosu na ostale članice EU. Tako je u 2012. godini zadružni sektor sudjelovao sa svega 6% u ukupnoj vrijednosti hrvatske poljoprivredne proizvodnje. Nepovoljnu situaciju u zadružnom sustavu opisuju i podaci o niskom udjelu zadrugara u ukupnom stanovništvu (0,3%) i niskom udjelu radno aktivnog stanovništva u zadružnom sustavu (0,2%). Nedostatak pravnih temelja, manjak informacija i znanja, nepoštivanje zadružnih načela i vrijednosti, način razmišljanja i ostavština stvorena u zadnjih 50-tak godina pokazatelji su trenutno nepovoljne situacije u zadružnom sustavu RH. Da bi se trenutna situacija promijenila neophodno je osigurati snažne državne mehanizme potpore i permanentni sustav obrazovanja, kako za najmlađe uzraste, tako i za visokokvalificirane stručnjake iz područja zadružnog menadžmenta.[8] Publikaciju radova i radionice na kojima se nesustavno predstavljaju primjeri dobre prakse potrebno je upotpuniti konkretnijim mjerama koje bi praksu suradnje pretvarali u konkretne protokole suradnje. Stvaranje baze podataka koja će sadržavati sve moguće partnere i protokole suradnje (postupak mapiranja) potaknula bi repliciranje broja primjera dobre prakse i uspostavljanje trajnih sporazuma suradnje (Božić i sur., 2020: 347, 352). Postupak mapiranja bi analitički objasnio osnovne korake i moguće načine povezivanja zadruga na nacionalnoj razini, istodobno stvarajući cjelovitu sliku koju pojedinačne zadruge ne mogu same vidjeti.

Veliku pozornost u oblikovanju realnijih temelja za budući razvoj zadružnog sektora u RH, zaslužuju sveobuhvatna istraživanja i analize koje će osim značaja zadruga u poslovnoj vitalnosti OPG-a, ispitivati i njihov utjecaj u izgradnji zaliha socijalnog kapitala. Temeljne sastavnice *socijalnog kapitala* poput: *povjerenja*, *pravednosti*, *uzajamnosti* (*obostranosti*), *demokratičnosti* i *stopa gospodarskog sudjelovanja* proizlaze iz kvalitete među-članskih odnosa i suradnje zadruga s nadležnim institucijama. Prema tome, socijalni kapital sačinjava sve ono što pojedince povezuje, odlika je svake društvene skupine ili poslovne organizacije (u našem slučaju zadruge) i može pozitivno utjecati na njenu poslovnu učinkovitost. Stavljajući u odnos ekonomiju i socijalni kapital Siisiäinen (2000) argumentira kako različite društvene vrijednosti i subjektivne koristi mogu imati višestruki „*utjecaj množenja*“ na druge oblike kapitala. Dobit koja u sebi sadrži društvenu vrijednost dodatno smanjuje troškove istodobno stvarajući bolje poslovne rezultate. Konkretnije analize koje

[8] Takve mjere stvorile bi skupinu poljoprivrednika inovatora i ranih usvojitelja koji zainteresirani za novim tehnološkim dostignućima i inovativnim rješenjima, ali i za znanjem iz područja ekonomike, marketinga i menadžmenta čine osnovu buduće propulzivnije i tržišno orijentirane poljoprivredne proizvodnje.

empirijski objašnjavaju zašto isti iznosi ekonomskog i socijalnog kapitala mogu dati različite stupnjeve (oblike) dobiti, neophodne su za cjelovito razumijevanje njihove međusobne povezanosti. Zadruge zbog svoje pregledne organiziranosti i lokalnog karaktera poslovanja mogu predstavljati idealan poslovni model za konkretnija empirijska istraživanja povezanosti ekonomskog i socijalnog kapitala koja će doprinijeti preciznosti postojećih modela.

Težište analize ove doktorske disertacije je usmjereno rješavanju pitanja na koje načine zadružno poslovanje akumulira socijalni kapital između članova i kakav je utjecaj socijalnog kapitala na krajnji ekonomski rezultat zadružnog poslovanja. Proučavanje odnosa između društvenog i ekonomskog aspekta zadruga, mjerenje subjektivne koristi i zadružne dobiti pomoći će akterima politike i široj društvenoj zajednici, ali prije svega zadrugarima i zadruzi u poboljšanju poslovanja i jačanju društvenih interakcija. Osim toga, proučavanjem stupnja povezanosti i razlikovanjem pojmova ekonomskog i socijalnog kapitala stalo bi se na kraj mnogim konceptualnim i terminološkim objašnjenjima koja su tijekom vremena rezultirala različitim i nepotpunim viđenjima što to zadružni sustav zapravo jest.

Primjena zadružnih načela u poslovnoj praksi zadruga pridonosi transparentnosti odnosa unutar zadruge i ispunjavanju profesionalnih i drugih interesa dionika poslovanja. Pozadina stavova i namjera zadrugara nije jednoznačna i na njih učestalo mogu utjecati demografski, socioekonomski, kulturološki i psihološki čimbenici koji nastaju u neposrednim okolinama. To može utjecati na poslovne aspiracije zadrugara, obujam gospodarskog sudjelovanja i na učinkovitost poslovanja. Promatrajući zadrugu kao međusobno povezanu grupu ljudi koja posluje za interese članova, u skladu sa zadružnim načelima, stvara se teorijski okvir za empirijska ispitivanja i provjeru utjecaja pojedinih pokazatelja socijalnog kapitala koji mogu u većoj ili manjoj mjeri utjecati na ekonomsku i poslovnu učinkovitost zadruge.

1.1. Hipoteze i ciljevi istraživanja

Temeljni problem istraživanja je utvrditi povezanost i jačinu utjecaja pokazatelja usvojenosti zadružnih načela na izbor zadrugara i posljedično kretanje financijskih pokazatelja zadruge. Prije toga je važno ustanoviti: osnovne motive pristupa, stavove članova, razinu povjerenja među članovima, ali i razinu povjerenja prema tijelima zadruge, koheziju grupe, poznavanje zadružnih načela, poslovne težnje i financijsku uspješnost zadružnog poslovanja. U svrhu istraživanja međusobne povezanosti zadanih pokazatelja, postavit će se i provjeriti socioekonomski model optimizacije poslovanja koji uvodi pokazatelje usvojenosti zadružnih načela i jačinu utjecaja na financijski rezultat zadruge.

Interes našeg istraživanja je usmjeren prema ispitivanju međusobne povezanosti socijalnih i ekonomskih pokazatelja. Polazeći od opće pretpostavke da se kroz zajedničko ulaganje i rad dionika, osim poticanja boljih financijskih rezultata izgrađuje i povjerenje, jača uzajamno ponašanje, kohezija grupe i društveni dodiri, istraživanje je usmjereno na ispitivanje njihove međuovisnosti unutar zadružnog modela poslovanja. Na izbor uzorkovane skupine utjecali su čimbenici društvene okoline u kojoj zadruga poslovno djeluje i teorija zadružnih načela koja je poslužila za postavljanje ankete i provedbu cjelokupnog istraživanja.

U skladu s time, postavljene su sljedeće hipoteze:

- postoji povezanost između pokazatelja zadružne dobiti i pokazatelja stupnja usvojenosti zadružnih načela;
- viši stupanj usvojenosti zadružnih načela rezultira većom zadružnom dobiti.

Ciljevi istraživanja su:

1. empirijski ustanoviti stupanj usvojenosti zadružnih načela od strane članova poljoprivrednih zadruga;
2. razviti socioekonomski model optimizacije zadružnog poslovanja;
3. utvrditi povezanost između pokazatelja zadružne dobiti i pokazatelja usvojenosti zadružnih načela od strane članova poljoprivrednih zadruga.

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Začetak zadrugarstva treba tražiti u dalekoj prošlosti, u vremenima kada je porodica postala oblik zajedničke ekonomije i zajedničkog načina življenja (prvobitna zajednica). Već tada su ljudi živjeli u mnogobrojnim porodicama, čiji su članovi zajedno proizvodili sve ono što im je bilo potrebno za život, zajednički lovili, odmarali odnosno jeli i radili. Prevladavao je kolektivni način razmišljanja, nije bilo privatnog vlasništva, a članovi sa zajedničkom proizvodnjom predstavljali su početak zadružnog života.[9] Početkom 19. stoljeća, razvojem poljoprivrede i sela, u čitavom svijetu dolazi do promjena u društveno-ekonomskom razvitku. Prateći procesi industrijalizacije, deagrarizacije, razvoja znanosti i obrazovanja dovode do razvoja novčane (tržišne) privrede i propadanja kućnih zadruga koje obilježava krvna povezanost, zajedničko vlasništvo i naturalna proizvodnja.[10] U novonastalim uvjetima poljoprivrednici se počinju povezivati i na taj način popunjavati vakuumske praznine tržišnih niši koje nisu bile interesantne velikim proizvođačima i klasičnim ekonomskim načelima poslovanja. Javljaju se prve poljoprivredne zadruge koje posluju na modernim načelima. Seljak ulazi dragovoljno, sa strogo definiranim vlasništvom, slobodno odlučuje i može istupiti ako zadruga ne ostvaruje njegove interese. Nova rješenja u obliku formiranja poljoprivrednih zadruga stvarala su pozitivne učinke koji su rezultirali širenjem zadrugarstva i povećanjem proizvodnje hrane na globalnoj razini.

2.1. Definiranje pojmova zadrugarstvo, zadruga i zadružna načela

Zadruge su dio zadružnog sustava i društvenog pokreta (zadrugarstva) koji je oduvijek bio vezan uz seoske ruralne sredine i društvene interakcije lokalnih zajednica.[11] Zadrugarstvo je društveno inovativan pokret čija je glavna pokretačka snaga ekonomska osnova bazirana

[9] U drugoj polovici 19. i početkom 20. stoljeća na našim prostorima dolazi do pojave kućnih zadruga koje se danas smatraju pretečom modernog zadrugarstva u RH. Kućne zadruge nisu dozvoljavale razvoj poduzetništva i afirmaciju sposobnijih članova, već su služile kao racionalan model preživljavanja i opstanka u teškim situacijama (Pavličević, 2010).

[10] Kućne zadruge nisu bile u skladu s novonastalim društvenim okolnostima jer nisu dozvoljavale napredak gospodarstva, ograničavale su pravo vlasništva i osobnog razvoja. Nakon njihove diobe dolazi do gubitka osnovnih moralnih vrijednosti i jačanja osjećaja individualizma, javlja se osjećaj nesputane slobode nad samim sobom, te jača samopouzdanje i sigurnost kod poljoprivrednika.

[11] Pojam *zadruge* se u angloameričkoj literaturi prevodi kao *cooperatives*, dok se pojam *zadrugarstvo* (*zadružni sustav* ili *zadružni pokret)* prevodi kao *cooperative movement*.

na načelu samopomoći. Zadrugarstvo predstavlja pokret koji uključuje sve oblike zadruga, njihove članove i druge dionike, kao i definiranje zadružne legislative i osnivanje potpornih institucija koje utječu na učinkovitost zadružnog sektora. Radi se o ekonomskoj inicijativi koja pojedinca pretvara u poduzetnika, razvija vještine štednje i stvara osjećaj odgovornosti nad individualnim i zajedničkim vlasništvom zbog čega njegov napredak ovisi o ljudskoj (društvenoj) sposobnosti da ga se suštinski shvati i operativno prihvati. Zadrugarstvo sadrži pozitivnu energiju spajanja koja se zasniva na načelima *filantropije*, *slobode*, *dragovoljnosti* i *nesputanim zakonima* koje stvaraju ljudi, a ne politička sila vlasti. Sa sociološkog aspekta zadruge i zadrugarstvo utječu na *slabljenje individualizma*, *jačanje društvene solidarnosti*, *tolerantnosti*, *društvenih dodira* i *propusnosti za mišljenja drugih*. Zadrugarstvo posjeduje određenu ideologiju i čitav niz vrlina kojima zadruge kao poslovni subjekti danas hrane čitav svijet. Tako su na primjer poljoprivredne zadruge u SAD-a organizirane kao revolt i reakcija poduzetnih poljoprivrednika na nepopularne političke mjere i monopolističke utjecaje velikih korporacija, banaka, željezničkih kompanija i ostalih dionika poljoprivredno-prehrambenog sektora koji su tijekom povijesti na njih nepovoljno djelovali (Mooney i Majka, 1995).

Kroz povijest su se upotrebljavala različita tumačenja pojma *zadruga*. Zadruga predstavlja oblik zajedničkog rada, autonomnu i dragovoljnu organizaciju kojom demokratski rukovode članovi. Ekonomski teoretičar Eberhard Dülfer opisuje zadruge kao gospodarske jedinice čiji nositelji, njeni članovi, međusobno surađuju u cilju ostvarenja pojedinačnih i zajedničkih interesa zbog kojih je zadruga osnovana.[12] Zadruge osiguravaju jednostavniju i povoljniju nabavu repromaterijala, otkup robe, transport i plasman proizvoda na tržište. Navedeni odnosi su poljoprivrednicima omogućavali da postanu faktor reguliranja tržišta, a ne samo proizvođači sirovina. Prema Mooneyu i Grayu (2002) zadruge su hibridne organizacije koje istodobno djeluju kao dragovoljno udruženje i kao klasično poduzeće koje poslovnu praksu uređuju na zadružnim načelima. Zadruge dijele dobit svojim članovima razmjerno volumenu suradnje sa zadrugom i kao takve one pridonose održivom razvoju okruženja i lokalne zajednice. One su ekonomske i političko-demokratske organizacije čije poslovanje određuju sociološki čimbenici na istovjetan način kao što tržište reguliraju ekonomski čimbenici. Zato je važno uvažavati društvene i psihološke odnose članova prilikom osnivanja i tijekom životnog vijeka zadruge, jer unutrašnja raspodjela resursa će ovisiti o kvaliteti međuljudskih odnosa (Valentinov, 2004).

Osnovne karakteristike po kojima se zadružni modeli razlikuju od drugih oblika poslovanja leži u sedam zadružnih načela koja čine zajedničku jezgru i organizacijsku poveznicu za

[12] Moderna teorija zadružnog poduzetništva kao bitnu odrednicu navodi *načelo istovjetnosti* prema kojem su osobe koje ulažu kapital i upravljaju zadrugom istodobno njeni poslovni partneri ili radnici.

sve oblike zadruga. Prema Dunnu (1988) filozofija zadružnog poslovanja proizlazi iz skupa osnovnih pravila koja imaju značajnu ulogu u postizanju ekonomskih, socijalnih, političkih i znanstvenih ciljeva. Svako načelo potrebno je promatrati kao dio integrirane cjeline, uvažavati ih i odražavati ravnotežu među njima. Obrazovanje se često spominje kao važan element zadružnog poslovanja koji je neophodan za provođenje ostalih načela i održivost poslovanja. Zato dionici zadružnog poslovanja trebaju imati neograničen pristup poslovnim informacijama u cilju učinkovitog donošenja poslovnih odluka. Torgerson i sur. (1998) navode da se zadruge uspješno prilagođavaju novim tržišnim uvjetima, no da bi zadržale ulogu: „… *one moraju prakticirati zadružna načela kao svoju temeljnu poslovnu praksu i disciplinu. Zadružna načela poslovanja teže održivosti demokratskog društva i kulture*“. Rasprave između stručnjaka koji zagovaraju pridržavanje osnovnih zadružnih načela (tradicionalno zadrugarstvo) i onih koji pogoduju novim trendovima zadružnog organiziranja u cilju povećanja poslovnih rezultata i dalje ostaju aktualna pitanja.

Postoje mnoge formalne i ne formalne definicije što su to zadruge. Danas u svijetu postoji veliki broj različitih oblika zadružnog poduzetništva. Zadruge se razlikuju od zemlje do zemlje, a u tome važnu ulogu imaju ekonomske, društvene, kulturološke, političke i religijske prilike. U preporuci o unapređenju zadrugarstva, koju je Međunarodna organizacija rada (ILO) donijela 20. lipnja 2002. godine, zadruga se definira kao „*autonomno udruženje osoba koje su se dragovoljno udružile radi ostvarivanja gospodarskih, socijalnih i kulturnih potreba, ali i htjenja da zajednički i na demokratski način upravljaju poduzećem.*“ U izjavi o zadružnoj istovjetnosti *Međunarodni savez zadruga* (ICA) navedenu definiciju nadopunjuje zadružnim vrijednostima i načelima. Prema njoj zadrugu čini svaka skupina ljudi koja se udružuje kako bi zajedničkim radom ostvarila interese u skladu sa sedam načela poslovanja:

1. **Načelo 1**: Dragovoljno i otvoreno članstvo;
2. **Načelo 2**: Demokratično upravljanje;
3. **Načelo 3**: Gospodarsko sudjelovanje članova;
4. **Načelo 4**: Autonomija i neovisnost zadruge;
5. **Načelo 5**: Obrazovanje, osposobljavanje i obavještavanje članova;
6. **Načelo 6**: Suradnja među zadrugama i
7. **Načelo 7**: Briga o zajednici.

(1) *Načelo dragovoljnog i otvorenog članstva* omogućuje svakom pojedincu da postane član zadruge, ali ga istodobno obvezuje na pridržavanje državnih zakona, unutarnjih pravilnika

zadruge, prihvaćanje zajedničkih interesa i poslovnih obveza. Izlazak člana iz zadruge je moguć tek nakon podmirenja svih zakonskih obveza prema zadruzi i drugim članovima.

(2) *Načelo nadzora poslovanja od strane članova* (načelo demokratičnosti) daje svim članovima jednaka glasačka prava u radu skupštine što omogućuje ravnopravno upravljanje i potiče aktivnu suradnju u stvaranju poslovnih interesa. Pri čemu, upravitelj i nadzorni odbor zadruge provode, reguliraju i kontroliraju transparentnost zadružnog poslovanja.

(3) *Načelo gospodarskog sudjelovanja članova i raspodjele* obvezuje članove da posluju putem zadruge što im zauzvrat daje novčane i druge oblike koristi razmjerno obujmu njihove suradnje. Svako poslovanje člana mimo zadruge podrazumijeva neposredni financijski gubitak za zadrugu i njene zadrugare. Sudjelovanje članova regulira ekonomsku održivost i zasebno je kontrolirana u sustavu korporacijskog oporezivanja u državama EU. Koncept trećeg načela vrijedi i u slučaju naplate obveza i dugovanja između članova.

(4) *Načelo samostalnosti i neovisnosti* jamči poslovnu autonomnost zadruge i članova prilikom rješavanja sporova unutar zadruge, ili prilikom sklapanja sporazuma s vanjskim ulagačima, poslovnim suradnicima i Vladinim organizacijama. Zadruge u pravnom prometu moraju poslovati u skladu s nacionalnim zakonima i propisima o financijskom poslovanju, poreznim obvezama, vođenju poslovnih knjiga, itd.

(5) *Načelo obrazovanja, stručnog usavršavanja i informiranja* odnosi se na neprekidan proces obrazovanja i obuku dionika (upravu, članove, zaposlenike i kooperante) u cilju jačanja učinkovitosti i održivosti poslovanja. Obrazovanje o vrijednostima, mogućnostima i prednostima zadružnih organizacija nikada nije i neće biti završen proces, jer je za početak i održivost zadružnog sustava kroz povijest bilo zaslužno upravo ovo načelo.

(6) *Načelo suradnje među zadrugama* potiče zadruge da učvršćuju suradnju unutar zadruge kao i suradnju s ostalim privrednim i neprivrednim organizacijama na lokalnoj, regionalnoj, državnoj i međunarodnoj razini. Na taj način zadruge i članovi doprinose jačanju povjerenja, uzajamnosti i aktivizma, ali i ekonomskoj, socio-kulturalnoj, ekološkoj i političkoj održivosti lokalnih zajednica (integralna održivost).

(7) *Načelo brige za lokalnu zajednicu* obvezuje zadruge da sukladno odlukama skupštine svoje aktivnosti usmjeravaju interesima i potrebama članova, te prema razvoju i učešću u javnom životu lokalnih zajednica. Re-investiranjem dobiti u lokalnu zajednicu zadruge otvaraju radna mjesta, izgrađuju škole, vrtiće i ostalu infrastrukturu u lokalnim zajednicama.

Na globalnoj razini tradicionalno zadrugarstvo unazad četrdesetak godina prolazi kroz trend restrukturiranja i pojave novih organizacijskih oblika koji više nalikuju klasičnim poduzećima (Chaddad i Cook, 2004).[13] Novonastali zadružni modeli odstupaju od tradicionalne strukture i zadružnih načela kako bi ublažili ograničenja vlasničke strukture unutar tradicionalnih zadruga. Glavni razlog restrukturiranja je nedostatak *rizičnog (operativnog) kapitala* i ograničenost investicijskih ulaganja koja se javljaju jer su vlasnička prava ograničena na članove, nisu prenosiva i ne mogu se otkupiti, a raspodjela dobiti se vrši proporcionalno s razinom suradnje, a ne s visinom ulaganja članova. Alternativni organizacijski oblici koji se pojavljuju čine potpunu inovaciju koja omogućuje poslovno afirmativniji nastup na tržištu. Ovo je proces o čemu svjedoče svjetska iskustva i koji neće zaobići niti RH (Nedanov i sur., 2013). S druge strane, iskustva pokazuju da nepoštivanje zadružnih načela dovodi u pitanje održivost zadružnog poslovanja i gospodarski razvoj lokalnih zajednica. Tradicionalne zadruge uspješno rješavaju društvena pitanja poput zadržavanja mladih na selu, smanjenja devitalizacije i depopulacije ruralnih prostora.

2.2. Pregled ekonomskih istraživanja o zadrugarstvu

2.2.1. Razvoj ekonomske teorije zadružnog poduzetništva

Teorijska ispitivanja o ekonomskim osnovama zadružnog poduzetništva su tijekom povijesti imala važan utjecaj na usmjeravanje kvantitativnih ekonomskih analiza. Sa svakim novim prijedlogom za mijenjanje teorijskog okvira dolazilo je do stvaranja empirijskih modela s kojima se pokušavalo razumjeti i predviđati obrasce ponašanja zadruga u stvarnim tržišnim prilikama.[14] Modernu teoriju zadružnog poduzetništva oblikovale su tri ekonomske škole koje zadruge promatraju kao: (1) *oblik vertikalne integracije koja služi interesima članova*, (2) *zasebno poduzeće odvojeno od posjeda članova*, ili kao (3) *koaliciju dionika*.

[13] Pojam „*demutualizacije*“ (engl. *demutualization*) se opisuje kao proces napuštanja tradicionalnih oblika zadružnog poslovanja, promjenu kontrole i vlasničke strukture unutar zadruga isključivo u cilju ostvarivanja novčanog profita (Chaddad i Cook, 2004: 348).

[14] Teorija i modeliranje ponašanja su po definiciji apstrakcija koja pojednostavljuje stvarnost. Njihova svrha je pronaći ključne elemente koji određuju kako nešto funkcionira i pomoći u razumijevanju odnosa između prethodno utvrđenih elemenata. Teorija istraživanja po svojoj prirodi ima zadaću stvarati nove, a ne testirati unaprijed postavljene hipoteze (Staatz, 1989: 24).

Prva ekonomska škola svoj pristup promatranja zadruge kao vertikalne organizacije temelji na načelu gospodarskog sudjelovanja i raspodjeli dobiti razmjerno obujmu poslovanja članova sa zadrugom. Iz toga proizlazi temeljni argument prve ekonomske škole koji kaže da zadruga nije zasebno poduzeće jer ne ostvaruje dobit ili gubitak na kraju godine. Glavni predstavnici ove škole su Nourse (1922) koji je prvi predstavio koncept u kojem zadrugu promatra kao oblik organizacijskog „*proširenja*“ poljoprivrednih gospodarstava članova i Emelianoff (1948) koji je zadrugu analizirao kao oblik vertikalne integracije neovisnih članova.[15] Edwin Nourse se zalagao da zadruge trebaju biti „*mjerilo konkurentnosti*“ tj. da njihova zadaća ne bih trebala biti pokušaj monopolizacije tržišta, već povećavanje tržišne konkurentnosti kako bi se poljoprivrednicima osigurala osnova za prosuđivanje učinaka konvencionalnih poduzeća. Prva ekonomska škola zadrugu promatra kao skup ekonomskih jedinica (članova) koje prilikom traženja dobiti zadržavaju neovisnost. Analize su usmjerene na pokrivanje operativnih troškova i ispunjenje ciljeve investitora. Emelianoffova teorijska stajališta nastavio je razvijati Robotka (1947), a Phillips (1953) formalizira njihove ideje u obliku modela u kojem iznosi pravila za definiranje cijena i optimalne razine proizvodnje. Njegove pretpostavke za poboljšanje financijske strukture i računovodstvenih postupaka izazvale su mnogobrojne i žustre reakcije među istraživačima ekonomske teorije zadružnog poduzetništva.[16] Osim kritika, Phillips je pokrenuo raspravu o problemu raspodjele dobiti i troškova zadruge čija je problematika danas još uvijek aktualna i postaje sve naglašenija s rastom raznolikosti interesa. Smatrao je da načelo „*jedan član-jedan glas*“ nema utemeljenu osnovu i zalagao se da glasačka prava, troškovi i dobit budu raspodijeljeni proporcionalno pokroviteljstvu članova (Phillips, 1953: 86-87). Većina poljoprivrednih zadruga u zapadnoj Europi i Sjevernoj Americi su danas organizirane upravo u obliku višenamjenskih, lokalnih i tradicionalnih oblika vertikalnih integracija.

Rasprave o Phillipsovim pravilima definiranja cijena i optimalne razine proizvodnje nastavile su se tijekom 1940-ih i trajale sve do početka 1960-ih godina. U tom razdoblju najveći dio rasprave bio je usredotočen da li zadruge treba promatrati kao oblik vertikalne integracije poljoprivrednika, ili je zadruge legitimno analizirati kao zasebna poduzeća koja imaju prostora za donošenje odluka neovisno o članovima. Upravo posljednja struja razmišljanja

[15] Ivan V. Emelianoff je svoju ekonomsku teoriju o zadružnom organiziranju prvi puta pismeno objavio 1942. godine, a knjiga je publicirana nakon njegove smrti 1945. godine od strane njegove supruge.

[16] Pravilo o cijenama i proizvodnji pretpostavlja da članovi ostvaruju onu razinu proizvodnje u kojoj su granični troškovi jednaki graničnom prihodu koje zadruga ostvaruje povećanjem proizvodnje za svaku dodatnu jedinicu. U slučaju da se zadruga suoči s povećanjem ili smanjenjem marginalnih troškova članovi nemaju razumne razloge da nastave s održavanjem trenutne proizvodnje. U tom slučaju granični troškovi članova razlikuju se od troškova zadruge, a u pojedinim slučajevima članovi imaju razuman razlog da povećaju vlastitu proizvodnju iznad optimalne razine zadružne proizvodnje.

o analiziranju zadruga kao zasebnih poduzeća utemeljila je drugu (neoklasičnu) ekonomsku školu u području zadružnog poduzetništva koja je dominantna još i danas. Modeli se svode na maksimiziranje različitih ciljeva, a pri tome koriste različite pretpostavke i definicije o dobrobiti članova. Analiziraju se mjere ekonomska efikasnost (alokacija resursa) i poslovna efikasnost (financijski profit) u različitim scenarijima otuđenja između članova i zadruge. Najčešći primjeri su *prestanak članske suradnje*, *smanjenje plasmana robe putem zadruge* ili *oportunističko ponašanje upravitelja* koji ne pokazuje interes da ispuni potrebe članova. Znanstveni pristup neoklasične ekonomske škole temelji se na važnosti uloge upravitelja u odlučivanju koje ciljeve zadruga treba maksimizirati. Glavnim predstavnikom neoklasične teorije se smatra Enke (1945) koji je prvi analizirao potrošačke zadruge kao zasebnu vrstu poduzeća. Njegov rad je potaknuo dugogodišnju i ponekad nejasnu raspravu oko toga koje ciljeve zadruga nastoji ili bi trebala nastojati maksimizirati.[17] U svom radu je prikazao kako potrošačka zadruga, u situacijama monopola ili monopolističke konkurencije, mijenjanjem cijena usluga može maksimizirati dobit bez gubitka pokrovitelja (članova) i tako ukloniti negativne utjecaje tržišnog okruženja. U takvoj situaciji dobrobit članova i zadruge može biti maksimalna ako upravitelj odluči maksimizirati zbroj dobiti zadruge i koristi koje članovi ostvaruju od nižih cijena. Ako je interes maksimizirati koristi članova, upravitelj zadruge mora održavati ravnotežu između koristi koje članovi ostvaruju kao vlasnici zadruge (engl. *stockholders*) i koristi koje ostvaruju kao pokrovitelji poslovanja (engl. *patrons*).[18] Model je u početku bilo zanemaren od strane ekonomskih teoretičara koji istražuju poljoprivredne zadruge, a većina tadašnjih neoklasičnih istraživača je usmjerena na pisanje kritičkih osvrta o radovima Emelianoffova (1948), Robotke (1947) i Phillipsa (1953).

Veliki doprinos na razvoj neoklasične teorije u području zadrugarstva su imali Helmberger i Hoos (1962). Bili su kritičari prve ekonomske škole i Emelianoffovo tumačenje zadružnih organizacija opisuju „… *pogrešnim putom koji je njegove sljedbenike naveo da zalutaju*“. Prema njima Phillipsova (1953) pretpostavka da članovi rukovode poslovnim aktivnostima zadruge nije realna za očekivati i ne objašnjava ulazak novih jedinica odlučivanja (članova) u zadrugu. Oni predlažu da se zadrugu promatra kao zasebnu jedinicu odlučivanja (engl. *decision-making unit*). Na taj način pažnja se „*usmjerava na zadrugu kao ekonomski agent*

[17] Rasprave su često miješale poželjne ciljeve s izvedivim ciljevima i nisu razlikovale kratkoročne od dugoročnih ishoda. U literaturi se to naziva rasprava o „*zadružnom maksimumu*“ (Staatz, 1989: 4).

[18] Odabir strategije koja ide previše u korist maksimiziranja dobiti ili u korist minimiziranja cijena naposljetku će rezultirati smanjenjem ukupne koristi za članove. Međutim, postoji problem s Enkeovom pretpostavkom o ravnoteži između dva oblika koristi. U pojedinim situacijama članovi neće htjeli biti pokrovitelji zadružnog poslovanja koje maksimizira ukupne koristi za članove. Razlog tome je što članovi zadruge proporcionalno smanjenje neto marže po jedinici proizvoda sukladno razini njihovog pokroviteljstva tumače kao smanjenje cijene. To im daje poticaj da prošire svoje pokroviteljstvo iznad točke maksimalne dobrobiti.

čije se ponašanje i poslovni učinci pokazuju mnogo prikladnijim za istraživanje i razvoj teorije“ (Helmberger i Hoos, 1962: 290). Njihov model se počeo standardno koristiti u teoriji zadružnog poduzetništva i koristio je alate iz standardne neoklasične *teorije poduzetništva* gotovo 20 godina. Prepoznatljiva značajka njihovog modela je pretpostavka da zadruga slijedi samo jedan cilj pri čemu se svi raspoloživi resursi usmjeravaju prema njegovom ostvarenju. Model ne analizira kako je cilj postavljen, niti pokušava analizirati moguće konflikte oko toga koje bi ciljeve upravitelj zadruge trebao slijediti. Glavna svrha modela je bila omogućiti kratkoročno i dugoročno promatranje ponašanja prerađivačkih zadruga u sektoru poljoprivrede.[19] Modelom je moguće analizirati u kojim situacijama će zadruga imati više koristi od ograničavanja ulaska novih članova.[20] Slične rezultate su dobili i kod analize opravdanosti visine pokroviteljstva poslovanja od strane članova. Rezultati pokazuju da postoje opravdani razlozi da se putem ugovora ograniči količina robe koju članovi plasiraju putem zadruge ako povećanje njihove suradnje dovodi do povećanja graničnih troškova zadruge. Ovakvi načini ograničavanja članstva i pokroviteljstva mogu potencijalno rezultirati konfliktima između trenutnih i potencijalnih članova. Iako nisu pokušavali modelirati procese pregovaranja između članova, odbora i uprave, oni navode da rješavanje sukoba ovisi o tome tko ima kontrolu nad zadrugom.[21] Unatoč iznimnom doprinosu, pretpostavka modela Helmbergera i Hoosa (1962), da članovi ne mogu utjecati na cijene koje ponudi upravitelj zadruge suočila se s istim problemom kao i Enkeov model (1945). Mnoge varijante njihovog modela su korištene u kasnijim analizama utjecaja prisustva zadruga na različitim tržištima. Rezultati tih istraživanja su pokazali do prerađivačke zadruge koje drže monopol i slijede politiku otvorenog članstva postižu slične rezultate i cijene koje bi ostvarivale i u uvjetima savršene konkurencije. Također je potvrđeno da zadruge provode pravedniju poslovnu politiku za razliku od *investicijski usmjerenih poduzeća* (engl. *investor-oriented firm-IOF*).[22]

---

[19] U kratkoročnom modelu zadružnu proizvodnju određuje proizvodnja članova, a u dugoročnom modelu razina proizvodnje varira ovisno o tome da li zadruga ima otvoreno ili zatvoreno članstvo.

[20] Rezultati pokazuju da otvoreno članstvo ima prednosti sve dok zadruga postiže ekonomiju razmjera tj. smanjuje troškove prerade po jedinici proizvoda. Zatvoreno članstvo se pokazuje boljim odabirom kada povećanje proizvodnje dovodi do rasta marginalnih troškova. Rezultati su dobiveni pod pretpostavkom da povećanje proizvodnje ne dovodi do nižih cijena proizvoda.

[21] Kada zadrugom rukovodi upravitelj velika je vjerojatnost da će članstvo biti otvoreno kako bi se osigurale prednosti koje donosi ekonomija razmjera, a kada zadrugom rukovode članovi velika je vjerojatnost da će doći do zatvorenosti članstva.

[22] Posebna varijanta modela se koristila u sudskom procesu protiv zadruge Sunkist. Model je bio važan dio obrane u odbacivanju optužbe da je prerađivačka zadruga ilegalno monopolizirala tržište citrusa u Kaliforniji i Arizoni krajem 1970-ih godina. Ishod je ojačao stajalište antitrustovske politike SAD-a da monopolističke zadruge ne predstavljaju prijetnju za potrošače jer načelo otvorenosti članstva, po svojoj prirodi, ne može ograničiti opskrbu (Staatz, 1989: 7).

Modeli koji nastaju pod utjecajem dviju prethodno opisanih ekonomskih škola zanemarivali su pojavu konflikta u organizaciji zadružne proizvodnje. U pedesetim godinama prošloga stoljeća dolazi do razvoja treće ekonomske škole koja zadruge promatra kao *koaliciju dionika* koji unatoč različitim interesima sudjeluju u radu koalicije sve dok se njihovi interesi ispunjavaju. Pretpostavka je da suradnja nastaje kao posljedica pregovaranja u kojem dionici pokazuju relativnu moć kako bi postigli željene ciljeve. Sljedbenici treće ekonomske škole analiziraju kako pregovarački procesi unutar zadruge utječu na održavanje zadružne prakse i provođenje demokratičnosti, financiranje poslovanja od strane članova i stabilne ravnoteže u kojoj niti jedan dionik poslovanja nema poticaj za promjenu ponašanja. Pažnja je usredotočena na situacije u kojima članovi ne preuzimaju cijele granične troškove ili ne dobivaju cijeli marginalni povrat zbog čega dobivaju poticaj da djeluju na načine koji nisu u skladu s dugoročnom dobrobiti zadruge i ostalih članova. Sukob interesa se najčešće javlja između postojećih i potencijalnih članova oko pitanja proširenja članstva u zadruzi. Pioniri treće ekonomske škole su Kaarlehto (1955) i Ohm (1956). Oni smatraju da *heterogenost interesa*, *konflikti*, *troškovi informiranja* i *razlozi suradnje* narušavaju stabilnost poslovnih rezultata zadruge. O konfliktima unutar zadruga češće su pisali europski teoretičari nego teoretičari s područja Sjeverne Amerike (Ollila, 1984; Agrell i Karantininis, 2000). Zajedničko im je da postavljaju realne pretpostavke o poslovnim ciljevima koje prve dvije ekonomske škole pokušavaju optimizirati. Sljedbenici ove škole su usredotočeni na ishode koji nastaju kao posljedica pregovaranja o ciljevima koji su neophodni za poslovnu održivost zadruga.

Kaarlehto (1955) analizira ponašanje aktera unutar zadruge i uspoređuje uspješnost takve vrste koalicijske suradnje s klasičnim poduzećem u različitim tržišnim situacijama. Analiza je pokazala da kada na tržištu istodobno postoji, nesavršena konkurencija u marketingu i savršena konkurencija u proizvodnji, zadruga ima bolje mogućnosti da članovima ponudi veće cijene za razliku od klasičnog poduzeća. U takvoj situaciji je logično za očekivati da će članovi imati veću optimalnu razinu proizvodnje od konkurenata koji robu prodaju klasičnim poduzećima. To je važna činjenica koju treba imati na pameti kada se operativni rezultati poslovanja zadruge i poduzeća proučavaju u kontekstu tehničke dobrobiti (Kaarlehto, 1955: 94-95). Slične rezultate koalicija članova postiže kada na tržištu istodobno postoji savršena konkurencija u marketingu i nesavršena konkurencija u proizvodnji. U uvjetima savršene konkurencije ne postoje značajne razlike u poslovanju zadruge i poduzeća, dok u uvjetima nesavršene konkurencije pritisak tržišta ide u korist zadružne koalicije.[23] Upravo u tome leži

[23] Uspoređivanje rezultata u različitim tržišnim prilikama je omogućila pretpostavka da su operativni troškovi zadruge, proizvodni troškovi članova i maksimalni prosječni prihodi koje članovi ostvaruju od proizvodnje jednaki u situacijama monopola i savršene konkurencije u ravnoteži.

najvažnije obilježje zadružne suradnje kao jednog oblika ekonomske integracije (Kaarlehto, 1955: 96-97).

Veliki doprinos u proučavanju zadruga kao koalicija je ostavio Ohm (1956). U svom radu je pokazao da granični troškovi predstavljaju analitički ispravniji način za proučavanje uvjeta i načina maksimiziranja dobiti. Na taj način je opovrgnuta tvrdnja Aresvika (1955) koji je pokušao uvesti novinu i Phillipsov (1953) princip marginalnih troškova u regulaciji cijena zamijeniti principom prosječnih troškova.[24] Korištenjem prosječnih marginalnih troškova Ohm je analizirao *probleme informiranja* i *ponašanja članova* u situacijama kada zadruga pokušava ostvariti maksimalnu dobit. Rezultati su pokazali da uprava zadruge neće uspjeti maksimizirati dobit u situacijama kada članovi nisu informirani o prihodima i troškovima poslovanja. Razlog tome je što u takvim uvjetima članovi ne mogu svoje poslovne planove temeljiti na neto povratu i počinju regulirati razinu proizvodnju (engl. *quantity adjusters*).[25] Ako članovi ne dobiju povrat novca za pokroviteljstvo, tada početne cijene koje su dogovorili s upravom zadruge počinju obračunavati kao neto prinos. U takvim situacijama mijenjanje dogovorenih cijena postaje poželjan instrument pomoću kojeg upravitelj zadruge može osigurati maksimalnu dobit. Međutim, nedostatak njegove primjene je to što prilagođavanje cijena podrazumijeva pretpostavku o reguliranju proizvodnje od strane članova tj. potrebno je poznavati relevantne informacije o članovima zadruge. Članovi u pravilu nisu informirani o troškovima i prihodima zadruge, a kada i jesu članovi se u pravilu ne ponašaju u skladu s tim informacijama zbog reguliranja vlastite proizvodnje i računskih problema. U situacijama kada članovi počinju regulirati proizvodnju zbog institucijskih svojstva zadružne suradnje svaki pokušaj uprave da osigura maksimalnu dobit postaje uzaludan.

Prva značajna istraživanja koja su pokušala analizirati kako se članovi zadruge dogovaraju oko raspodjele troškova i financiranja zajedničkog poslovanja bila su zapravo pokušaji da se proces pregovaranja modelira kao proces glasovanja (Zusman, 1982; Knoeber i Baumer, 1983). Analize su pokazale da raspodjela troškova i financiranje zajedničkog poslovanja vjerojatno dovodi do stanja stabilne ravnoteže.[26] Zusman (1982) analizira odluke skupina i

---

[24] Aresvik (1955) je smatrao da granični troškovi koje članovi zadruge preuzimaju prilikom suradnje predstavljaju prosječne troškove, a granični prihodi koje ostvaruju u suradnji predstavljaju prosječne prihode. On je smatrao da s ovako postavljenom pretpostavkom Phillipsov model postaje dosljedan (Aresvik, 1955: 140-141).

[25] Prilagodba proizvodnje označava situaciju kada tržišni viškovi dovode do smanjenja isporučene količine ili kada nestašica uzrokuje povećanje isporučene količine. To je samo jedna od više mogućih posljedica neuravnotežene ponude i potražnje na tržištu. U takvim uvjetima članovi pokušavaju kompenzirati nepovoljne cijene koje im nudi uprava zadruge reguliranjem razine vlastite proizvodnje.

[26] Modeli su pretpostavljali da članovi o svakom pitanju odlučuju samostalno, da prilikom rasprave nisu podijeljeni u različite grupacije i da se sve odluke donose na principu većinskog glasovanja. Tehnički gledano, modeli pretpostavljaju da raspodjela učestalosti preferencija članova o određenom

učinkovitost raspodjele troškova proizvodnje između članova. Rezultati su pokazali da u uvjetima heterogenih interesa i plasmana različitih količina robe može doći do sukoba interesa oko raspodjele troškova. Donošenje odluka je u stvarnosti mnogo složeniji proces koji istodobno uključuje više međusobno povezanih pitanja o kojima članovi mogu imati različite sklonosti.[27] U tim situacijama kada zadruga postaje složena organizacija unutar koje dolazi do grupiranja interesnih skupina jednostavne modele glasovanja je potrebno zamijeniti složenijim modelima pregovaranja (Zusman, 1982: 233).

Prema Merrettu i Walzeru (2003) prvi modeli pregovaranja koristili su neoklasične pristupe, a najveći doprinos u analiziranju njihove primjene su postignuli američki istraživači Staatz (1983) i Sexton (1986). Oni su popularizirali *teoriju igara* kao operativno korisnu metodu za modeliranje grupnih odluka članova unutar zadruge ili ponašanje zadruge unutar strateških saveza. Za njihove modele pregovaranja, Fulton i Vercammen (1995) navode da pružaju najpotpunije uvide u optimizaciju zadružnog poslovanja.[28] Unatoč iznimnom doprinosu i njihovi modeli su imali stanovite poteškoće u predviđanjima ishoda ponašanja (stohastičko modeliranje) i višekriterijskom odlučivanju.

U mnogim situacijama postojanje jedne cijene za sve članove neće rezultirati stvaranjem stabilne ravnoteže, već poticajem da članovi s boljim tržišnim alternativama počnu napuštati zadrugu. To se može spriječiti uvođenjem politike *promjenjivih* i *minimalno potrebnih cijena* prilikom raspodjele troškova i dobiti zadruge (engl. *price differentiation*).[29] Staatz (1983) analizira poslovnu stabilnost zadruga obračunavanjem različitih otkupnih cijena za svakog člana zadruge zasebno. Analiza je pokazala da su veliki proizvođači u pravilu uspješniji u pregovorima za postizanje privilegiranih cijena, dok se mali proizvođači suprotstavljaju davanju privilegiranih cijena većim proizvođačima iz straha da će takve cijene oslabiti njihovu pregovaračku moć. To sugerira da zadruge koje imaju nekoliko većih proizvođača češće vode kontraproduktivne pregovore oko raspodjele troškova i dobiti nego zadruge s

---

problemu ima jedan vrh kao što ima krivulja u obliku zvona. Ako su ove pretpostavke zadovoljene, modeliranje odlučivanja unutar zadruge svodi se na modeliranje preferencija putem medijana.

[27] Na primjer, određivanje cijena za proizvode različite kakvoće, lokacija za marketinška postrojenja i podjela poslovnog rizika utječu na distribuciju i učinkovitost poslovanja marketinške zadruge.

[28] Staatz (1983) je pretpostavio da racionalno ponašanje članova prelazi funkciju korisnosti, a ne funkciju dobiti kako je to u modelu pretpostavio Sexton (1986). Problem neracionalnog ponašanja u modelima je izbjegnut pretpostavkom da je sklonost članova prema riziku neutralna, a interesi koalicije odgovaraju njihovim individualnim željama.

[29] Definiranje cijena na principu prosječnih troškova, kako predlažu Helmberger i Hoos (1962), ne stvara stabilnu koaliciju u situacijama kada prosječni troškovi počinju rasti. U takvim situacijama uvijek će postojati skupina članova koja će prekinuti suradnju sa zadrugom i uz niži prosječni trošak početi proizvoditi za sebe.

više malih proizvođača. Zadruge s nekoliko većih proizvođača suočavaju se sa sličnim problemom raspodjele kao i u kartelima. Isto tako analiza je pokazala da uprava zadruge ne smije obračunavati cijene za svoje usluge na temelju marginalnih troškova koji su zajednički samo jednom dijelu članstva jer takve cijene neće odgovarati drugim članovima i dolazi do napuštanja zadruge. Određivanje raspodjele troškova je složen postupak koji je problematično dogovoriti na temelju načela „*jedan član-jedan glas*“. Uprava zadruge mora biti oprezna u odluci kada proširiti članstvo, a kada poslovne aktivnosti. Širenje poslovanja je opravdano ako postoji sinergija koja će usporiti rast prosječnih troškova. Nemogućnost pronalaska stabilnog načina određivanja cijena usluga među heterogenim članstvom može spriječiti zadrugu da ispuni interese svakom članu.

Ulogu promjenjivih cijena u ublažavanju negativnih posljedica gubitka lojalnosti članova dodatno je istražio Sexton (1986). On smatra da optimalan način financiranja poslovanja zadruge uključuje određivanje otkupnih cijena na dvije razine. Prva razina podrazumijeva naplaćivanje usluga na principu marginalnih troškova, dok druga razina podrazumijeva naplaćivanje fiksnih naknada kojima bi se pokrivali fiksni troškovi (npr. kupnja dionica). Fiksne naknade ne smiju biti jednake za sve članove i potrebno ih je odrediti tako da se kreću proporcionalno s povećanjem dobiti koje članovi ostvaruju nakon ulaska u zadrugu. Politika promjenjivih cijena je nužna ako se želi riješiti problem članske lojalnosti. Zato promjenjive cijene moraju odražavati kako participiranje člana utječe na operativne troškove zadruge i kakve su poslovne mogućnosti člana za dobivanje usluga izvan zadruge. Rezultati ukazuju da lojalnost raste tijekom vremena beskonačne suradnje, veća je u zadrugama s manjim brojem članova, raste zajedno s visinom kazni za kršenje lojalnosti. S druge strane, lojalnost se smanjuje kako jača utjecaj članova s visokom diskontnom stopom. U modelu pokazuje kako mehanizam određivanja promjenjivih cijena kojeg naziva „*financiranje zasnovano na koristi*“ dovodi do postizanja Pareto učinkovitog ishoda tj. „*organizacijske stabilnosti koja daje mogućnost naplaćivanja različitih naknada i u kojoj članovi nemaju potrebu za međusobnim subvencioniranjem*“ (Sexton, 1986: 221). Međutim, mehanizam promjenjivih cijena zahtjeva poznavanje podataka o članovima zadruge i njegova primjena nije nimalo jednostavna. U kraćim vremenskim periodima primjena promjenjivih cijena nije najbolje rješenje, ali dugoročno gledajući njena primjena dovodi do povećanja tržišnih prilika.[30] Analiza je potvrdila da određivanje minimalne otkupne cijene predstavlja uvjet postojanosti i neophodna je za održivost koalicije u uvjetima monopola. Na kraju zaključuje

[30] Teorija igara je pokazala da mnoge postojeće prakse za određivanje cijena u zadrugama teorijski nisu stabilne. Međutim, teorija igara isto tako u sebi sadrži pretpostavku da članovi raspolažu savršenim informacijama o tržišnim alternativama i da bez dodatnih troškova oni mogu sklapati nove ugovore s njima. Očito je da ovakvi uvjeti u stvarnosti nisu mogući (Staatz, 1989: 20).

da neoklasični modeli imaju „*urođen nedostatak*“ koji im oduzima prostor za proučavanje interakcija između postojećih poduzeća i potencijalnih dionika, ali i narušava temelje za razumijevanje prisutnosti ili odsutnosti zadruga na promatranom tržištu.

Naknadno istraživanje Fultona i Vercammena (1995) je potvrdilo da uvođenje promjenjivih cijena može riješiti pitanja neučinkovitosti zadružnog poslovanja i članske lojalnosti. Njihovo istraživanje je pokazalo da *korištenje ugovora u dogovaranju volumena poslovne suradnje*, *komunikacija*, *zadovoljstvo članova* i *angažman upravitelja* predstavljaju važne čimbenike za stvaranje zadružne koalicije, ali i raspodjelu dobara između članova.

2.2.2. Ekonomska praksa zadružnog poduzetništva u istraživanjima

Iz datog povijesnog pregleda razvoja ekonomske teorije zadružnog poduzetništva jasno se vidi da postojeće mikroekonomske analize promatraju zadruge kao klasična poduzeća. Najveći broj empirijskih istraživanja temelje i dalje pronalazi u drugoj ekonomskoj školi koja naglasak stavlja na ekonomsku funkciju poduzetništva tj. stjecanje kontrole i učinkovito upravljanje mrežom materijalnih resursa. Bez obzira o kojoj se školi suvremene ekonomske teorije radilo literatura empirijski ispituje utjecaje: *free-rider problema*, *oportunističkog ponašanja*, *heterogenosti interesa*, *povećanja članstva*, *konflikta* i *troškova informiranja* na uspješnost zadružnog poslovanja. Stoga su tijekom posljednjih desetljeća empirijska i teorijska istraživanja doprinosila isključivo razvoju instrumenata i pokazatelja za mjerenje i testiranje učinkovitosti rukovodstva zadruge.

Na taj način je osnovna funkcija zadruga nepotpuno i pogrešno interpretirana, a teorija zadružnog poduzetništva se razvijala iz skupa pretpostavki koje pretjerano pojednostavljuju ekonomsko ponašanje čovjeka (Mooney i Gray, 2002). Zbog toga što su vođene misijom da vrše distribuciju dobiti među članovima, zadruge se često nazivaju neprofitnim oblicima poduzetništva (Valentinov i Iliopoulos, 2013), a zbog svoje ideološke dimenzije smatraju se produktom „*vjetra demagogije*“.[31] Pogrešna percepcija o zadrugama ostavlja sve veći trag u suvremenom društvu. To potvrđuje nedostatak prihvaćenih mjera za računanje financijske učinkovitosti zadruga koja se i dalje proučava kroz prizmu neoklasične paradigme (Lerman i Parliament, 1991; Kyriakopoulos i sur., 2004; Arcas i sur., 2011). Ekonomski učinci zadružnog poslovanja se analiziraju pomoću standardnih pokazatelja koji se obično koriste

[31] U SAD-a neprofitne organizacije su oslobođene od plaćanja poreza. Njihov porezni zakon zadruge klasificira kao organizacije oslobođene od plaćanja poreza, ali ih istodobno razlikuje od dobrotvornih organizacija čije se donacije također odbijaju od poreza.

za procjenjivanje financijske uspješnosti IOF-a.[32] Korištene mjere uspješnosti usredotočuju su na zadrugu kao poslovno poduzeće i ne kvantificiraju dodatne koristi za članove (Lerman i Parliament, 1991: 17). Za razliku od IOF-a koja posluju u korist svojih ulagača, zadruge posluju isključivo u korist svojih članova što nadilazi klasičnu optimizaciju isplativosti koja se oslanja na korištenje standardiziranih ekonomskih omjera (Guzmán i Arcas, 2008: 110-111).[33] Pokazatelji i postupak mjerenja uspješnosti zadružnog poslovanja treba uvažavati jedinstvenost organizacijske strukture svakog zadružnog sektora. Mateos-Ronco i Lajara-Camilleri (2014) smatraju da je za kvalitetnije praćenje ekonomske uspješnosti zadružnog poslovanja potrebno koristiti računovodstvene podatke u više vremenskih razdoblja zbog makroekonomskih učinaka i financijskih ograničenja strukture kapitala.[34] Također, treba voditi računa i o specifičnostima financijske evidencije zadružnih sektora. Kritike na račun nepotpunih analiza su česta pojava, međutim treba navesti da je razlog tome ograničenost statističkih podataka i institucijska nevidljivost zadruga i cijelog sektora socijalne ekonomije u regulativi nacionalnih računa (Monzón Campos i Chaves Ávila, 2012).[35] Istovremeno empirijske analize ne pružaju vjerodostojan uvid u društvenu korisnost zadružnog sektora, a njihov jednodimenzionalan pristup zasjenjuje induktivnu kvalitetu institucijske ekonomije i udaljuje zadružnu praksu od njene holističke teorije.

Moderna teorija zadružnog poduzetništva pokazuje da zadruge ne treba promatrati kao zasebna poduzeća nego kao *uslužne agencije* ili *koalicije dionika*. Kao uslužne agencije, zadruge postoje da služe interesima svojih dionika poput članova, upravitelja, zaposlenika, kooperanata, volontera, ostalog osoblja, ali i šire javnosti. S druge strane, zadruge kao oblik koalicije moraju uravnotežiti interese različitih skupina dionika. Iako je moguće pretpostaviti o komparativnoj važnosti navedenih perspektiva, stvar je istraživača kako će postaviti svoje istraživanje i pokazati stvarnu važnost ovih perspektiva u pojedinim scenarijima (Valentinov i Iliopoulos, 2013: 116). Promatranjem zadruga kao zasebnih poduzeća eliminiraju se ostale

[32] Najčešće se koriste četiri pokazatelja za mjerenje: zaduženosti (engl. *leverage*), učinkovitosti (engl. *efficiency*), likvidnosti (engl. *liquidity*) i profitabilnosti zadružnog poslovanja (engl. *profitability*).

[33] Uobičajeno korištene financijske pokazatelje nije jednostavno za tumačiti u kontekstu zadruga koje dobit raspodjeljuju po principu *bruto marži* (engl. *gross margins*). Zbog toga zadruge često posluju s „*pozitivnom nulom*“ tj. nakon podmirenja svih troškova i potraživanja zadruge ne ostvaruju dobit ili gubitak (engl. *net zero surplus*).

[34] Računovodstvene informacije koje se uobičajeno koriste u ocjenjivanju financijske snage i uspješnosti poslovanja nisu prilagođene posebitostima i heterogenosti zadružnih sektora zbog čega je potrebno proširiti i determinirati nove indikatore za bolje razumijevanje ekonomske i financijske situacije poslovnih subjekata socijalne ekonomije.

[35] Oskudnost podataka se može pratiti kroz: (1) nedostatak dostupnih baza podataka i poteškoće u pristupu postojećim podacima i (2) kroz strukturnu raznolikost zadružnog sustava čije rezultate uobičajeno korišteni računovodstveni okviri ne mogu adekvatno izmjeriti (Costa i Carini, 2016: 373).

vrijednosti, ali i interesi koji čine sastavne premise institucijske ekonomije i socioloških istraživanja. Dosadašnje empirijske analize još uvijek nisu uspjele obuhvatiti dualnu prirodu zadruga tj. uključiti specifičnosti njene organizacijske strukture u ispunjavanju interesa i kontinuiteta članova (Soboh, 2009: 31-33). Događa se upravo suprotno, moderni trendovi birokratizacije, centralizirano odlučivanje i prevlast neoklasične teorije sve više odvajaju čitatelje od izvorne zadružne logike i uvode ih u proces promjene njenih temeljnih načela (Mooney i Gray, 2002: 15). Pregled literature i sažimanje rezultata empirijskih istraživanja potvrđuje da moderna teorija zadružnog poduzetništva sve više podliježe teoriji neoklasične ekonomske škole i klasičnim analizama financijskih pokazatelja (Sexton i Iskow, 1993).

Početkom 1980-ih godina ekonomija razmjera se pokazala neučinkovitom u prikupljanju kapitala unutar zadruge što je dovelo do „*demutualizacije*“ odnosno pretvorbe tradicionalnih oblika zadruga u modernije poslovne modele koji će uspješno sudjelovati na nacionalnim i međunarodnim tržištima (Chaddad i Cook, 2004). Autori navode da su razlozi ovih pretvorbi financijska ograničenja zadruga u obliku *ograničenih vlasničkih prava* i *nedostatka vanjskih izvora financiranja*. Teorijska i metodološka razmatranja o organizacijskom restrukturiranju zadruga su mnogobrojna. Većina članaka je napisana sa stajališta neoklasične ekonomske škole što prihvaćaju mnogi istraživači i pronalazi različite motive pretvorbe (van Dijk, 1997; Iliopoulos, 2005). Oni vjeruju da postoje dobri razlozi da ovaj trend postane još izraženiji u narednim godinama kada će internacionalizacija i konkurentnost biti još izraženija (Nilsson, 1998: 44). S time se ne slažu Mooney i Gray (2002) koji glavni razlog povećanja broja novih oblika zadruga vide u neuspjehu tržišne ekonomije da obuzda sve izraženiju težnju prema oligopolizaciji nakon završetka Drugog svjetskog rata.[36]

Mooney i Gray (2002) u izvještaju o procesima pretvorbe i restrukturiranja poljoprivrednih zadruga u SAD-a obrazlažu da znanstvena istraživanja zanemaruju neekonomske interese članova i lokalnih zajednica u kojima zadruge obitavaju. Problem nastaje kada neoklasične analize čiji je dominantni cilj maksimizirati stope povrata pokušavaju objasniti suštinu zadružne suradnje (engl. *cooperative behavior*). Osnovne hipoteze ovih modela opisuju: (1) dionike poslovanja kao individualne jedinice koje teže ostvarenju osobnih interesa, ili (2) pretpostavljaju da se dionici poslovanja nalaze u natjecateljskim odnosima. Usmjeravanje funkcije cilja na dionike ili zadrugu kao glavnu pokretačku snagu ovih modela stavlja: "… *zadružno ponašanje izvan okvira neoklasičnog načina razmišljanja.*“ (Mooney i Gray, 2002: 6). Na takav način, neoklasični modeli već od samog početka podcjenjuju zadruge i njihovo

[36] Prema Harteu (1997) životni vijek zadruge započinje kolapsom gospodarstva i samo u posebnom slučaju neuspjeha tržišne ekonomije one mogu imati beskonačan život. Jedino područje u kojem zadruge mogu živjeti je istinska tržišna ekonomija zbog čega moraju prepoznati svoje prednosti u sektoru prerade, distribucije i razbijanju uskog grla monopolizma (Mooney i Gray, 2002: 4).

svakodnevno djelovanje. Upravo zato globalna percepcija društva o zadružnim modelima poslovanja započinje slijediti deduktivnu logiku neoklasičnih istraživanja.

Rastući trend restrukturiranja poljoprivrednih zadruga tijekom devedesetih godina prošlog stoljeća u SAD-a je potaknuo mnoge pretpostavke da organizacijska struktura tradicionalnih zadruga ne odgovara trenutnim potrebama moderne poljoprivrede (agrobiznisu).[37] Iako rezultati neoklasičnih analiza sugeriraju da IOF-a postaju vlasnici poljoprivrednih zadruga, podaci iz realnog sektora ipak pokazuju drugačije. Uspješne poljoprivredne zadruge su te koje zapravo proširuju poslovanje stvaranjem strateških saveza, povezivanjem s lokalnim zadrugama, ili kupovinom imovine IOF-a (Mooney i Gray, 2002).

Analizirajući unutarnje pokazatelje financijskog poslovanja Schrader (1989) argumentira razloge strukturne reorganizacije na primjeru poljoprivrednih zadruga. Rezultati ukazuju na dvije značajke zadružnog kapitala koje su naposljetku rezultirale reorganizacijom zadružne proizvodnje u IOF-a. Prva značajka je povezana s načinom raspodjele vlasničkog kapitala. Do reorganizacije poslovanja dolazi kada se članovima zadruge umjesto knjigovodstvene vrijednosti, koja je u pravilu uvijek niža od tržišne vrijednosti, ponudi cijena koja odražava stvarnu tržišnu vrijednost kapitala (Schrader, 1989: 44).[38] Druga značajka je povezana s problemom pristupa ili osiguravanja odgovarajuće razine zadružnog kapitala. Menadžment smatra da je rast neophodan za održivost poslovanja, odnosno statičnost poslovanja dovodi do gubitka tržišne pozicije koja će tijekom vremena rezultirati krahom proizvodnje. Ovisnost o unutarnjem kapitalu koji se osigurava putem članskih ulaganja uprava zadruge smatra ograničenjem za postizanje rastućih stopa povrata (Schrader, 1989: 50). Autor zaključuje da je reorganizacija zadružnog poslovanja u IOF-a donijela veću korist članovima nego likvidiranje članskih vrijednosti kapitala. Dakle, pretpostavka o likvidaciji kapitala potvrđuje da članovi imaju racionalne motive za odobravanje prodaje ili reorganizacije poslovanja u slučajevima kada tržišna vrijednost vlasničkog kapitala prelazi knjigovodstvenu vrijednost.

---

[37] Korporacije s malim brojem dioničara (engl. *held corporation*) u američkoj literaturi označava zatvoreni tip poduzetništva u kojima manji broj dioničara raspolaže ograničenim brojem dionica. Razmjena dionica na burzama je povremenog karaktera, a ponekad se trgovanje vrijednosnim papirima odvija putem brokersko-trgovačke mreže-OTC razmjena (engl. *over-the-counter (OTC) exchanges*). To su organizacije koje nemaju poveznica sa zadružnim organiziranjem. Postupak restrukturiranja američkih zadruga podsjeća na situaciju u zadružnom sustavu RH nakon uvođenja Zakona o zadrugama (NN, br. 36/1995) i Izmjena i dopuna Zakona o zadrugama (NN, br. 12/2002).

[38] Računovodstvena pravila zahtijevaju da se imovina uvijek vrednuje po cijeni koja je niža od troškova, ili tržišne cijene, kako bi se u slučaju inflacije ili drugih tržišnih nepogodnosti spriječio porast njene tržišne vrijednosti. Tako se smanjuje mogućnost da likvidacijska vrijednost kapitala bude veća od knjigovodstvene vrijednosti. Kada zadruga ostvaruje prihode veće od prihoda koji nastaju korištenjem imovine, kapitalizirana vrijednost tih prihoda premašuje knjigovodstvenu vrijednost kapitala čak i u slučajevima kada se imovina procjenjuje na tržištu.

Prethodno istraživanje o procesu restrukturiranja zadruga je proširio Collins (1991a; 1991b) uvođenjem dviju novih pretpostavki da: (1) glavni poticaj za restrukturiranje poljoprivrednih zadruga dolazi iz korporacijskog sektora i da (2) glavni motiv za njihovo restrukturiranje nije nedostatak kapitalnih ulaganja, već da zadruge posjeduju značajan kapital koji je postao privlačan vanjskim ulagačima. Njegovi rezultati su pokazali da u nekim scenarijima razlozi restrukturiranja koje navodi menadžment zadruga nisu vjerodostojni. Njihova tvrdnja da zadruge prodaju vlastite dionice jer im je potreban kapital koji im nije dostupan kroz zadrugu nije u skladu s dokumentiranim podacima. Tvrdnja o reorganizaciji zadružnog poslovanja zbog ograničenja u likvidaciji kapitala pronalazi djelomičnu potporu u stvarnim podacima, kao i pretpostavka da način organizacije poslovanja čini uspješne zadruge lakim plijenom za IOF-a. Jedina tvrdnja koja je bila u skladu s dostupnim financijskim podacima je da zadruge nalaze izvore kapitala kada je njihovo poslovanje atraktivno za vanjske ulagače. Detaljnim pregledavanjem javnih dokumenata i dostupnih podataka o poslovanju poznatih američkih zadruga, prije i poslije restrukturiranja organizacije, on zaključuje: „… *prilično se jasno vidi da su pojedine teorijske pretpostavke o zadružnom poslovanju nastale odabirom ekonomskih interesa od strane njenih istraživača*“ (Collins, 1991b: 323-327).

Potrebno je spomenuti još jedno istraživanje koje je dobilo značajnu pozornost istraživača o zadrugarstvu. U pokušaju da odgovori mogu li velike poljoprivredne zadruge s otvorenim članstvom biti legitiman natjecatelj IOF-a na konkurentskom tržištu Rhodes (1983) analizira više scenarija. Njegovi rezultati pokazuju da u uvjetima konkurencije IOF-a mogu spriječiti stalni gubitak tržišnog udjela ako smanje marže do razine u kojoj više neće ostvarivati zaradu (engl. *zero earnings*).[39] Bez obzira koju strategiju IOF-a odaberu, zadruge će postići tržišnu dominaciju ili dati poticaj za poboljšanje otkupnih cijena. U svakom od scenarija poljoprivrednici su na kraju profitirali, ali ipak manje putem dividendi (suradnje s IOF-a). Iako se dobiveni rezultati da: „*zadruge s otvorenim članstvom mogu ostvariti tržišnu dominaciju u koncentriranim industrijama s visokim maržama čine intuitivnim, oni nisu razvijeni u teorijskom kontekstu. U stvari, neke klasične teorije pokušale su prikriti ovakve rezultate*“ (Rhodes, 1983: 1093). On dalje navodi da su zadruge pokazale sposobnost prikupljanja velikih količina kapitala i izgradnje pogona. Zadruge nemaju ništa manju sposobnost od IOF-a da uđu na određena tržišta. Koncept zadrugarstva u sebi sadrži određene poticaje, poput inovacija, od kojih se može očekivati da s vremenom stvore tržišnu prednost. Ulazak IOF-a na oligopolistička tržišta s visokim maržama najvjerojatnije će potaknuti značajno, za njih skupo, smanjenje tržišnih marži. S druge strane, poljoprivredna zadruga pod nadzorom

[39] U takvim uvjetima konkurentske zadruge ne mogu osigurati bolje ekonomske povrate za članove nego što to mogu IOF-a. Međutim, smanjujući marže da uklone konkurenciju i eliminiraju dobit zadruga IOF-a istodobno eliminiraju i vlastiti profit.

članova biti će u situaciji gotovo „*bez gubitka*“ (engl. *no-lose situation*).[40] Na kraju zaključuje: „*… da bi objasnili koncept zadružne suradnje potrebno je koristiti širu pozadinu od same teorije konkurencije, potrebno je otići dalje od ekonomije*“ (Rhodes, 1983: 1094).

Jones i Kalmi (2012) navode da ne postoje dosljedni dokazi da zadruge ostvaruju ekonomiju razmjera povećanjem prosječne veličine poslovanja. Prema njima, logično je za očekivati postojanje razlika u pouzdanosti rezultata obzirom da je literatura iznenađujuće ograničena, a postojeće analize se razlikuju u ključnim aspektima kao što je: vrsta zadruge na kojoj je provedeno istraživanje, veličina uzorka, vremensko razdoblje i priroda empirijskih metoda (Jones i Kalmi, 2012: 46). Američke analize zadružnog poslovanja najčešće koriste *export base modele* ili *input-output analize* koje uvažavaju određene specifičnosti lokalnih uvjeta (Leistritz, 2004: 249), ali bez obzira koliko mjerenja bila točna, ovi modeli nikada neće moći u potpunosti izmjeriti utjecaj zadruga na lokalna gospodarstva, zajednicu ili članove. Oni mogu izmjeriti trenutnu zaposlenost, dohotke, sustav oporezivanja i predvidjeti gospodarski utjecaj zadruga u budućnosti, ali ne mogu dati odgovor kako bi lokalne ekonomije izgledale u odsustvu zadruga, kakve vrste ušteda zadruge nude članovima i kakve koristi imaju od upotrebe novonastalih ušteda.

Svaki član zadruge ima glasačka prava koju su povezana s članstvom, a ne s brojem dionica koje posjeduje. Na temelju članstva on sudjeluje u odabiru nadzornog odbora, ali i u raspodjeli dobiti i troškova proporcionalno volumenu suradnje sa zadrugom. Važna razlika između zadruga i IOF-a je u tome što su godišnje ekonomske koristi za članove izravno povezane s razinom transakcija koje ostvaruje kao kupac, dobavljač ili radnik u suradnji sa zadrugom u tom razdoblju. Zbog toga članski udjeli (engl. *member shares*) imaju dvojaku prirodu. Članski udjeli su sredstvo za stjecanje prava kontrole i ostalih pogodnosti koje donosi članstvo.[41] S druge strane, članski udjeli su oblik vlasničkog kapitala kojim raspolažu članovi.[42] Glasačka prava i ekonomska korist od transakcija vezani su uz članstvo, a ne

[40] U situaciji kada se marže smanjuju zadruge se snalaze u pokrivanju gubitaka, dok članovi ipak profitiraju. U situaciji kada se marže ne smanjuju koristi istodobno ostvaruju zadruga i članovi.

[41] Pitanje kontrole se svodi na: *tko smije glasati* i *na kojem principu se donose odluke* (broj potrebnih glasova)? Za razliku od IOF-a, u tradicionalnim zadrugama članovi glasaju o odlukama vezanim za suradnju, izbor nadzornog odbora, odobravanje godišnjih izvješća, dogovaranje novih poslova i slično. Na taj način se osigurava da članovi imaju potpunu kontrolu (Kyriakopoulos i sur., 2004: 381).

[42] Pitanje vlasništva se svodi na: *tko može raspolagati zadružnim kapitalom*, *kako se on raspodjeljuje*, *kako zadruga otkupljuje kapital* i *kako se raspoređuje neto prihod*? U tradicionalnim zadrugama vlasništvo nad kapitalom imaju isključivo članovi. Vlasništvo je vidljivo u obliku izravnih ulaganja, neto dobiti koju zadruga zadržava, ulaganja članova obzirom na broj ili vrijednost dionica, u obliku dugoročnih zajmova ili obveznica s fiksnim naknadama za člana (Kyriakopoulos i sur., 2004: 381).

udjele članova. Članski udjeli obično imaju ograničenu prenosivost, a ako članovi odluče prekinuti suradnju sa zadrugom udjeli (dionice) se najčešće unovče.

Pojedina istraživanja su pokušala pronaći empirijske dokaze o ekonomskoj suštini dionica unutar poslovanja zadruga (López-Espinosa i sur., 2009). Ispitujući odnose između članskih obveza financiranja imovine (engl. *leverage*) i rizika poslovanja njihova analiza je potvrdila da klasifikacija dionica kao obveza ne odražava u potpunosti suštinu zadružnog vlasništva i članskog kapitala. Mogućnosti računovodstva su ograničene i potrebna su detaljnija istraživanja koja će postaviti zasebna načela za klasifikaciju financijskih instrumenata za zadruge. Novi računovodstveni standardi trebali bi se nositi s pojmom *neraspoređenog kapitala* (neto zajednička imovina) i *otkupljivim dijelom dionica* koji je u poljoprivrednim zadrugama, unutar svih uzorkovanih zemalja EU, imao svojstva vlasničkog kapitala. U tu svrhu je potrebno daljnje istražiti institucijske čimbenike, obveze članova i otkup dionica.

Ipak postoje značajni pokušaji da se promjeni pristran i neobjektivan trend u istraživanju ekonomske učinkovitosti zadružnog poslovanja. Pregled literature ukazuje na inovativne pristupe u analizama učinkovitosti, koji uz standardne financijske pokazatelje, omogućuju mjerenje učinaka zadružnih načela na razvoj poslovanja. Bruynis i sur. (2001) empirijski dokazuju da pojedine varijable uzajamnosti i povjerenja mogu imati učinak na dugovječnost, profitabilnost i povećanje obujma zadružnog poslovanja, kao i na zadovoljstvo i subjektivne koristi članova. Rezultati pokazuju da varijable *postojanja i distribucije točnih financijskih izvještaja*, *kontinuirani treninzi* i *prethodna iskustva upravitelja* imaju pozitivan utjecaj na dugovječnost, profitabilnost i povećanje obujma poslovanja. Nadalje, *prethodna iskustva upravitelja*, *kontinuirani treninzi*, *povezanost upravljačkih vještina s poslovnim aktivnostima*, te *odnos upravitelja i nadzornog odbora* imaju pozitivan utjecaj na zadovoljstvo članova, dok negativan utjecaj može imati *unajmljivanje vanjskog upravitelja*.

Lopez i Marcuello (2006) predlažu dva inovativna pokazatelja za promatranje ekonomskog ponašanja poljoprivrednih zadruga. Uz standardne financijske pokazatelje predlaže se korištenje *indeksa dodane ekonomske vrijednosti-EVA* (engl. *economic added value*) kao konzervativnije mjere učinkovitosti i korištenje tri *indeksa omjera razgradnje* (engl. *ratio decomposition indexes*) koji su bolje prilagođeni „*osjetljivom ponašanju*“ zadruga. Indeksi omjera razgradnje dobiveni su rastavljanjem klasičnih pokazatelja ekonomske učinkovitosti u više indeksa koji predstavljaju korisne instrumente za usporedbu poslovanja zadruga. Rastavljanjem ekonomske učinkovitosti u obliku omjera marže i obrtaja imovine dobivena se dva nova pokazatelja koja mjere *produktivnost kapitala* i *intenzitet kapitala*. Treći indeks omjera razgradnje dobiva se množenjem i dijeljenjem broja članova zadruge s indeksom

produktivnosti kapitala.[43] Indeks opisuje raspodjelu kapitala unutar zadruge i predstavlja dokaz o povezanosti raspodjele kapitala i ekonomske učinkovitosti zadruga. Pokazatelji omogućuju procjenjivanje tržišnih aktivnosti, usporedbu raspodjele kapitala i profitabilnosti između zadruga u kontekstu proizvodnih marži, intenziteta kapitala i produktivnosti članova. Indeksi su od iznimne važnosti jer će usporedba između zadruga kao organizacija, a ne usporedba između zadruga i IOF-a kako se to uobičajeno provodi, omogućiti vrednovanje zajedničkih resursa i popunjavanje „*praznina*“ unutar zadružnog sustava. Tek kada se takve usporedbe počnu intenzivnije provoditi moći ćemo govoriti o troškovima poslovanja zadruga odnosno o troškovima participacije članova (Lopez i Marcuello, 2006: 17). Slične izmjene standardnih ekonomskih pokazatelja predlaže Sharifi (2013). On smatra da uobičajeno korišteni financijski pokazatelji, posebice pokazatelji koji se orijentiraju na dobit, ne opisuju adekvatno zadružni način poslovanja. On predlaže osam indeksa koji će pomoći upravitelju da razvije vlastite mjere za analizu financijske uspješnosti i kretanja novčanog toka.[44]

U sektoru socijalnih zadruga također je zabilježen inovativan pristup. Costa i Carini (2016) koriste *Višestruku faktorsku analizu-MFA* (engl. *Multiple Factor Analysis*) za procjenjivanje razlika u uspješnosti poslovanja socijalnih zadruga u tri talijanske regije.[45] Korištenje MFA je omogućilo povezivanje ekonomskih i kategoričkih varijabli kao što su broj zaposlenih, godina osnutka, sektor djelatnosti i geografsko područje na kojem zadruge djeluju. Rezultati su pokazali da su socijalne zadruge u sjevernoj Italiji pozitivno reagirale na gospodarsku krizu širenjem svojeg poslovanja na nove sektore i inozemna tržišta, dok se kod socijalnih zadruga na jugu Italije i dalje očituju strukturalni nedostaci. Socijalne zadruge u sjevernoj i središnjoj Italiji u prosjeku ostvaruju veću dobit, posjeduju više imovine i zapošljavaju više radnika, dok se zadruge u južnoj Italiji suočavaju s problemima učinkovitosti i kapitalizacije. Dobiveni rezultati podupiru rezultate istraživanja Putnama (1993) koji navodi da teritorijalni dualizam u Italiji ima začetke duboko u povijesnim korijenima (vidi potpoglavlje 2.4.).

---

[43] Brojnik omjera može se tumačiti kao produktivnost članova, a nazivnik kao raspodjela kapitala među članovima. Indeks je interesantan jer pokazuje da se ekonomska učinkovitost zadruga može poboljšati ako se smanji koncentracija kapitala među članovima (Lopez i Marcuello, 2006: 20).

[44] Izmijenjeni pokazatelji opisuju: dužinu trajanja razdoblja prodaje zaliha (engl. *conversion period of inventories*), omjer isplate (engl. *payout ratio*), stope rasta kapitala (engl. *capitalization growth rate*), indeks dobiti (engl. *profit index*), stope povrata na ulaganja u lokalnu imovinu (engl. *local return on local assets*), promjenjivost zarade (engl. *earnings variability*), omjer kvalitete prihoda (engl. *income quality ratio*) i omjer pokrivenosti novčanih kamata (engl. *cash interest coverage ratio*).

[45] Uspješnost je mjerena pomoću dva indeksa koji opisuju veličinu poslovanja: ((1) *dobit/ukupan promet* i (2) *ukupan promet/ukupni operativni troškovi*) i dva indeksa koji mjere učinkovitost i kapitalizaciju zadruga ((3) *kapital/ukupna imovina* i (4) *dugotrajna imovina/ukupna imovina*).

Uspoređivanje poslovanja između poljoprivrednih zadruga neovisno o sektoru proizvodnje je od velike važnosti ako se uzme u obzir da postojeće empirijske analize koje uspoređuju zadruge i IOF-a (Lerman i Parliament, 1991; Soboh i sur., 2009; Fazzini i Russo, 2014; Soboh i sur., 2014), ili ispituju povezanost veličine zadruga s uspješnošću poslovanja imaju nedostatak konsenzusa o značaju rezultata i vrsti odnosa (Arcas i sur., 2011). Štoviše, ovakve empirijske analize samo potvrđuju da na rezultate utječu metodološki čimbenici poput prikupljanja podataka ili načina kako računamo varijable. U kontekstu poljoprivrednih zadruga relevantna literatura ukazuje na proturječne rezultate s pozitivnim, neznačajnim ili negativnim učincima. Važno je napomenuti da heterogenost i veličina uzoraka, te korištenje različitih pokazatelja za mjerenje veličine i efikasnosti poslovanja djelomično objašnjavaju različite rezultate. Tome još treba nadodati da mjerenje financijskih pokazatelja efikasnosti poslovanja zadruga predstavlja kontroverzno i nepotpuno istraženo područje.[46] U literaturi postoje istraživanja koja pokušavaju detaljnije analizirati efikasnost zadružnog poslovanja, kao i povezanost veličine zadruge s uspješnošću poslovanja (Ferrier i Porter, 1991; Singh i sur., 2001; Piesse i sur., 2005; Guzmán i Arcas, 2008; Arcas i sur., 2011). Rezultati ovih istraživanja jasno pokazuju da *Analiza omeđivanja podataka-DEA* (engl. *Data Envelopment Analysis*) može biti primjeren dodatak tradicionalnim financijskim analizama jer omogućuje mjerenje višekriterijske efikasnosti, to jest *tehničke efikasnosti*, *proizvodne efikasnosti* i *efikasnosti razmjera* (za više informacija o metodi vidi potpoglavlje 3.5.).[47]

2.3. Pregled socioloških istraživanja o zadrugarstvu

U stručnim i znanstvenim časopisima se više od sto godina vode rasprave o svojstvima zadružnog poduzetništva koje traju i danas. To ukazuje da točan karakter njene organizacije nije potpuno jasan i opće prihvaćen od strane istraživača. Početkom devetnaestog stoljeća,

[46] Mjere poput *povrata na imovinu* (ROA), *povrata na ulaganja* (ROI) ili *produktivnosti* se često koriste u analizama poslovanja zadruga. Ove pokazatelje je teško izmjeriti i protumačiti u kontekstu zadruga čiji osnovni cilj je osigurati članovima najbolju cijenu za proizvode (Kyriakopoulos i sur., 2004).

[47] Istraživanje Ferriera i Portera (1991) je pokazalo da zadruge i klasična poduzeća u sektoru mljekarstva obilježavaju tehnička i alokacijska neučinkovitost, niže stope povrata, dok prosječne vrijednosti mjera ukazuju na manju učinkovitost mljekarskih zadruga. S druge strane, istraživanje Singha i sur. (2001) pokazuje da su zadruge za preradu mlijeka u prosjeku tehnički učinkovitije i troškovno isplativije u odnosu na privatna poduzeća (engl. *cost-efficiency*). Slične rezultate su potvrdili Piesse i sur. (2005) koji dokazuju da je početna neučinkovitost bila povezana s državnom politikom koja je zadruge koristila kao instrument za provođenje vlastitih interesa. Nakon liberalizacije tržišta i ukidanja državnih subvencija dolazi do povećanja cjenovne učinkovitosti i konkurentnosti zadruga koje se bave uzgojem žitarica.

Georges Fauquet (1935) je primijetio da zadrugarstvo čine dva osnovna elementa.[48] S jedne strane, zadruge su demokratski uređene organizacije kojima rukovode njeni članovi (područje sociologije), a s druge strane zadruge slijede ekonomske interese svojih članova. Glavni argumenti mainstream ekonomista, poslovnih lidera i kreatora politika je da zadruge zbog svoje dualne prirode „*trpe pritiske*“ dvostrukog tereta zbog čega one ne mogu jednako učinkovito stvarati kapital kao što to uobičajeno čine klasična poduzeća. Stoga se zadruge mogu zanemariti jer će tijekom vremena propasti, oslabiti ili restrukturirati svoje poslovanje u tržišno uobičajene strukture. Međutim, analizom relevantne literature i podataka s terena ipak se može dobiti nešto drugačija, cjelovitija slika.

Pokušaji nametanja redukcionističkih ideja koje razdvajaju socijalnu i ekonomsku ulogu zadruge dovode do pojednostavljivanja njihove organizacijske svrhovitosti. Takvi selektivni pristupi pružaju djelomičan uvid u postignuća koje zadruge ostvaruju sto i pedeset godina. Posljedica toga je otežan pristup cjelovitom formalnom osposobljavanju budućih generacija upravitelja gdje bi se educiralo na koje se socijalne ili ekonomske zadatke usredotočiti, sugerirali kompromisi ili kako spriječiti gubitak sinergije u pojedinim tržišnim scenarijima. Na posljetku sve se svodi na želju pojedinaca za samo edukacijom i otkrivanjem kako uistinu rukovoditi zadružnom organizacijom. Društvenjaci s nelagodom prihvaćaju redukcionistički odnos neoklasičnih istraživača prema socijalnom kapitalu, povjerenju, slobodi, etici, moralu, religiji i ostalim ljudskim vrijednostima koje zadruge uspješno promoviraju. Korisniji način razmišljanja o strateškom upravljanju zadrugama treba slijediti integrirani pristup u kojem se društveni ciljevi ostvaruju kroz gospodarske aktivnosti, a članstvo predstavlja mjesto gdje se društvene i ekonomske funkcije međusobno dodiruju. Vitaliano (1977) naglašava da osnovni problem razumijevanja zadružnog poslovanja leži u uspješnoj koordinaciji ova dva područja, a njihovo suštinsko razdvajanje u svrhu analitičkih istraživanja doprinosi gubitku glavnih teoretskih niša tradicionalnog zadrugarstva. Prikazom literature o ekonomskim raspravama i obilježjima postojećih modela upozorava se na teškoće s kojima se suočavaju ekonomski analitičari koji žele razumjeti unutarnji rad zadruge. On zaključuje da moderna teorija zadružnog poduzetništva nije dosegla onu razinu na kojoj bi mogla donositi konačne sudove o unutarnjem radu zadruge, donošenju odluka, marginalnim troškovima i ostalim ciljevima postojećih modela.

Njemački ekonomski teoretičar Georg Draheim (1903.-1972.) u knjizi *Die Genossenschaft als Unternehmungstyp* (1955) raspravlja o dualnoj prirodi (dualnosti) zadruga. On navodi

[48] Georges Fauquet je doktor medicine i ratni veteran koji je u razdoblju od 1920. do 1932. godine bio prvi šef jedince za zadrugarstvo koja je djelovala u sklopu Međunarodne organizacije rada (ILO COOP). To je specijalizirana agencija Ujedinjenih naroda (UN) koja posljednjih sto godina radi na unapređenju zadružnog poduzetništva i ostalih oblika socijalne i solidarne ekonomije.

da ekonomski rezultati zadružnog poslovanja uvelike ovise o kvaliteti međuljudskih odnosa između članova. Svako planiranje i prilagođavanje nepredviđenim okolnostima na tržištu ovisi o poznavanju, povjerenju i povezanosti dionika zadružnog poslovanja putem poslovnih ugovora, ali i društvenih interakcija tj. dodira. Da bi postali isplativi dugoročni oblici suradnje zahtijevaju trajnost i u tome „*kapital povjerenja*“ kojim zadruga raspolaže postaje ključan element ekonomske učinkovitosti (Bonus, 1986: 322). Ovakva sociološka razmatranja treba povezivati s neoklasičnim pristupima u cilju objektivnijeg utvrđivanja mogućnosti holističke empirije zadružnog poslovanja. Ekonomska teorija otvorenije prilazi uvažavanju navedenih čimbenika u definiranju odnosa moći i neravnopravnosti između članova. Interdisciplinaran pristup koji uključuje socijalnu i institucijsku ekonomiju predstavlja induktivan način analiziranja koji istodobno uvažava povijesne, sociološke, geografske i kulturološke razlike u analizi dominantnih odnosa unutar zadružnog poslovanja.

U knjizi Fairbairn (2003) iznosi tri osnovne smjernice za strateško upravljanje zadrugama. Njegovi misaoni koncepti (1) *ekonomske povezanosti*, (2) *transparentnosti* i (3) *spoznaje* spajaju društvene i ekonomske, upravljačke i operativne funkcije zadruga. Njegovi koncepti su produkt rasprava i razmjena iskustava u interdisciplinarnom izučavanju zadruga na Sveučilištu u Saskatchewanu koje se smatra jednom od vodećih institucija za proučavanje zadružnog poduzetništva u svijetu. U izradi smjernica i koncepta koristio je: *teoriju igara*, *teoriju agenata*, *teoriju nove institucijske ekonomije*, *teoriju složenih sustava*, *teoriju postmoderne* i *teoriju postkolonijalne kulture*, *teoriju feminizma*, *teoriju kritičke sociologije*, *teoriju umrežavanja*, *neurološku teoriju* i *ideju o potrošačkom društvu*. U nastavku su opisana razmišljanja o tri misaona koncepta koja predlaže Fairbairn (2003):

Prvi koncept (1) *ekonomske povezanosti* govori o važnosti ispunjavanja potreba članova. Koncept polazi od osnovne pretpostavke da interesne skupine u kojima postoji uzajamnost povjerenja ostvaruju veće ekonomske rezultate za razliku od skupina dionika koje u svojem poslovanju zanemaruju čimbenike povjerenja. Zadruge koje ne usklađuju svoje poslovanje s interesima članova postaju osjetljive na nagle tržišne promjene. U konačnici to rezultira gubitkom povjerenja i podrške zbog čega upravitelj zadruge neće biti u mogućnosti izvući koristi iz suradnje sa svojim članovima. Percepcija koja se pri tome razvija utječe na razinu povezanosti i stupanj povjerenja u zadruzi. Zato upravitelj, transparentnost odlučivanja i društveni odnosi imaju važnu ulogu u stvaranju subjektivnih koristi za članove. Ako jedan dionik postigne dobar rezultat i drugi dionici ostvariti će svoj udio u ukupnom prometu. Zato je tržišnu proizvodnju potrebno prilagođavati potrebama članova, a društveno ponašanje članova usmjeravati prema poslovnim interesima zadruge. Međutim, kako zadruge povećavaju brojnost članova tako se razina povezanosti sve teže organizacijski i financijski održava. To posebno dolazi do izražaja kod starijih zadruga u kojima nepoželjni kompromisi

rezultiraju gubitkom transparentnosti koja postaje sve važniji faktor u poslovanju zadruga s dugogodišnjom proizvodnjom.

Drugi koncept (2) *transparentnosti poslovanja* ukazuje na važnost isticanja prednosti koje zadruga putem koncepta ekonomske povezanosti pruža članovima. Koncept se istodobno razmatra kao komunikacijski pristup i načelo organizacije jer nadilazi klasičnu upotrebu izvještaja, organizaciju protoka informacija i važnost međusobne komunikacije. Upravitelj će postići transparentnost ako članovima osigura potpun uvid i pravovremenu distribuciju točnih informacija. Čimbenici povjerenja, iskrenost i osobni odnosi utjecat će na povećanje brojnosti članova i poticati nove oblike suradnje.[49] Međutim, navedene unutarnje aktivnosti neće imati dugoročan pozitivan učinak ako upravitelj zadruge ne osigura vidljivost svojih aktivnosti. Zato je potrebno da članovi budu informirani o trenutnim aktualnostima u realnom sektoru i na taj način budu upoznati s aktivnostima svoje zadruga. Članovi moraju postati svjesni heterogenosti i različitosti interesa, razmišljati o budućnosti i prilagođavati se novim tržišnim trendovima jer kvaliteta uspješne transparentnosti će ovisiti o poslovnoj odgovornosti članova tijekom vremena.

Posljednji misaoni (3) *koncept spoznaje* govori o važnosti suradnje dionika, planiranja djelatnosti i proučavanja cijelog zadružnog sektora u vremenu i prostoru. Koncept uključuje kreativnost upravitelja, sistematično istraživanje, interdisciplinaran pristup i pragmatičan odabir rješenja. Misaoni proces se ne oslanja samo na individualan rad upravitelja nego uključuje i aktivnosti ostalih dionika koji moraju razviti osjećaj pripadnosti (*tko su i što rade?*) i identiteta (*u kojem smjeru se kreću?*). U tome će važnu ulogu imati razmišljanje, učenje, mašta, kreativnost i istraživanje koje predstavljaju osnovne funkcije u stvaranju mentalne slike o sektoru u kojem djeluju. Time zadruga razvija jedinstvenu organizacijsku kulturu, brend i prepoznatljivost na tržištu, a njeni dionici osjećaj pripadnosti, osobnog doprinosa i povezanosti sa zadrugom. Kognitivan model nije samo sredstvo za planiranje već djeluje i kao spojnica između zadruge i članova koji su podložni promjenama tijekom vremena.

Rezultati nekih dosadašnjih istraživanja idu u korist navedenim misaonim konceptima o spajanju društvenih, ekonomskih, upravljačkih i operativnih funkcija zadružnog poslovanja (Bruynis i sur., 2001). Njihovo empirijsko istraživanje potvrđuje proporcionalnu povezanost

[49] Transparentnost, odanost i vjernost članova može se riješiti povezivanjem zadruga u federativne strukture. Takva vrsta povezivanja ima veću podršku članova, stvara osjećaj pripadnosti i lokalnog identiteta, poslovno je fleksibilnija i organizacijski sposobnija od centraliziranog tipa zadruge u kojoj većina dionika ne razumije zadružno organiziranje u potpunosti (Mooney i Gray, 2002: 13). Ovakvim načinom organiziranja članovi zadruga imaju mogućnost vidjeti da li zadruga predstavlja neku vrstu „*crne kutije*“ koja stoji između njih i tržišta zasjenjujući signale, prijetnje i mogućnosti koje im ona pruža (Fairbairn, 2003: 19).

pokazatelja distribucije financijskih izvještaja poslovanja i stupnja obrazovanosti upravitelja s pokazateljima gospodarskog sudjelovanja članova, dugoročnosti poslovanja, novčanih prihoda i općeg zadovoljstva članstva. U uvjetima idealne transparentnosti veći stupanj povjerenja i gospodarskog sudjelovanja može se postići: *distribuiranjem cjelovitih poslovnih informacija*, *traženjem inovativnih poslovnih rješenja*, *priznavanjem pogrešaka od strane dionika*, *uočavanjem i poticanjem razvoja individualnih vještina članova*, *kažnjavanjem neposlušnog dijela članstva* ili *poticanjem zajedničkog participiranja u iznošenju mišljenja*.

Osamdesetih godina prošlog stoljeća Ben-Porath (1980) je objavio esej u nepoznatom demografskom časopisu. U potrazi za nedostajućim elementima parcijalnih ekonomskih i drugih vrsta analiza autor proučava institucijski utjecaj obitelji i domaćinstava u obavljanju neekonomskih transakcija. Iako se doprinos njegova rada očituje u teorijskom ispitivanju važnosti društvenih odnosa i ljudskog identiteta u uvjetima poslovanja, njegov esejistički stav o velikom skepticizmu ekonomske profesije prema prijedlozima uključivanja socijalnog kapitala i povjerenja u osnovne teorije ekonomije izazvalo je polemike i reakcije kod brojnih istraživača. Istraživanje je komentirao Wilson (2000) sljedećim riječima: „*... iako nije stvorio konzistentan model, dao je korisne uvide u unutrašnjost ekonomske znanosti i u način razmišljanja njenih pratioca odnosno znanstvenika.*“ (Wilson, 2000: 6).

Praktično svi udžbenici ekonomije pružaju određeni opis osnovnih institucija oko kojih je moguće organizirati proizvodnju. Zadružni modeli poduzetništva mogu se pojavljivati na raznim mjestima u ekonomskim udžbenicima. Mogu se spominjati u prikazima alternativnih oblika organiziranja, u kontekstu pitanja vlasništva ili u usporednim ekonomskim analizama. U obliku kreditnih unija zadruge djeluju u financijskom sektoru. Međutim, ove ekonomske organizacije koje imaju dugu i zanimljivu povijest, koje dominiraju u nekim sektorima i u kojima na razne načine sudjeluje stotine milijuna ljudi diljem svijeta, ostaju gotovo nevidljive u ekonomskim udžbenicima. Lynch i sur. (1989) pregledom sadržaja ekonomske literature koja se koristi na američkim i kanadskim sveučilištima zaključuju da se pažnja posvećena zadrugama znatno smanjila tijekom proteklih desetljeća, a specijalizacija u mikroekonomiju ili makroekonomiju je dodatno pogoršava situaciju.[50] Slične rezultate potvrđuje još nekoliko istraživanja. Zanemarivanje zadruga u literaturi dovodi do sustavnog ignoriranja ekonomske demokracije i nemogućnosti upoznavanja mlađih populacija s principima djelovanja ili sa

[50] Uzorak je uključivao 114 udžbenika iz područja ekonomije (55), ekonomike poljoprivrede (15), mikroekonomije (19) i makroekonomije (25). Radi se literaturi iz uvodnih kolegija koje svake godine pohađa značajan broj studenata preddiplomskog studija.

zanimljivim predavanjima o njihovom povijesnom razvoju (Hill, 2000: 293).[51] Schugurensky i McCollum (2010) kao moguće objašnjenje slabije učestalosti pojavljivanja pojmova zadruge i socijalne ekonomije u knjigama pripisuju prevladavajućem ekonomskom mišljenju da je jedina svrha poslovanja povećavati dobit dioničara. Sadržaji knjiga su od neopisive važnosti u definiraju osnovnih kontura svake znanstvene discipline i 80 do 90% nastavnog vremena ovisi o udžbenicima koji odražavaju ono što se smatra vrijednim znati. Ovakvo sustavno zanemarivanje sugerira da politika igra važnu ulogu u odlučivanju koje ili čije znanje više vrijedi, a koje se treba marginalizirati (Schugurensky i McCollum, 2010: 170).

Najobuhvatniju analizu ekonomskih udžbenika i rukopisa je proveo Kalmi (2007). On je analizirao strukturu sadržaja 24 udžbenika koja su objavljena u vremenskom razdoblju od 1905. do 2005. godine.[52] Rezultati ukazuju da literaturu s početka dvadesetog stoljeća obilježava veći broj sistemskih analiza, opsežniji teorijski uvidi, pažljivija dokumentacija i uravnotežene teorijske rasprave u odnosu na angloameričke udžbenike koji institucijske pristupe polako, ali sigurno počinju zamjenjivati s neoklasičnim analizama. Značajan pad broja rasprava o zadružnom poduzetništvu nakon završetka Drugog svjetskog rata pripisuje strukturnim promjenama unutar ekonomske strukture. Kao glavne razloge navodi prijelaz s institucijski orijentiranih analiza na neoklasične ekonomske analize, dominaciju američkog gospodarstva i angloameričkog jezika, državni intervencionalizam i pojavu „*društvenog inženjeringa*“. Autor spominje Paula A. Samuelsona, dobitnika Nobelove nagrada iz 1970. godine za rad u području neoklasične ekonomije, u kontekstu prvog autora koji je sustavno zanemario zadruge u ekonomskim udžbenicima. Njegovo poznato stajalište da „*raspodjela vlasništva zapravo nije bitna u konkurenciji tržišta*“ odražava izostavljanje zadruga s popisa poslovnih organizacija koje uključuju vlasništvo, partnerstvo i korporacije unutar poglavlja naziva Poslovne organizacije i prihodi (Kalmi, 2007: 636).

Sa svojim različitim oblicima organiziranja zadrugarstvo je postojeći primjer mogućnosti proširenja demokracije u ekonomsku domenu ljudskog života. Zadružno poslovanje može predstavljati temeljni stup za izgradnju društvene zajednice jer postavlja institucijski okvir moralnih i etičkih načela ponašanja za potencijalne sudionike. Brojna literatura i iskustva s terena pokazuju da demokratski menadžment i socijalno orijentirana poduzeća nisu samo

[51] Proučavanjem sadržaja 19 ekonomskih udžbenika autor zaključuje da gotovo polovica referenci uopće ne spominje pojam zadruge dok ih ostali udžbenici samo taksativno navode ne raspravljajući o razlozima njihovog postojanja.

[52] Uzorak je podijelio u tri skupine. Prvu skupinu čine međunarodni udžbenici koji su se u nastavi koristili u razdoblju od 1905. do 1925. godine. Drugu skupinu čine finski i skandinavski udžbenici koji su se koristili između 1925. i 1957. godine kada se finska ekonomija počinje odvajati od Njemačke povijesne škole prema neoklasičnoj ekonomiji Stockholmske škole. Posljednju skupinu čini literatura s angloameričkog govornog područja koja se na finskim sveučilištima koristi od 1957. godine.

utopijski snovi već održiva alternativa klasičnim poduzećima. Njihova sposobnost je dolazila do izražaja u vremenima ekonomskih kriza kada su se zadruge učinkovito prilagođavale špekulativnom investiranju unutar uvriježenog financijskog sustava (Schugurensky i McCollum, 2010: 169-170).

2.4. Socijalni kapital u zadružnom poduzetništvu

Literatura predlaže velik broj različitih definicija socijalnog kapitala. Socijalni kapital može se definirati kao skup kulturnih odlika koje stvaraju povjerenje i održavaju suradnju među članovima neke društvene zajednice. Socijalni kapital je odlika društvenih skupina odnosno "… *sposobnost pojedinaca da međusobno surađuju u cilju postizanja zajedničkih interesa skupine ili poslovne organizacije u kojoj obitavaju*" (Coleman, 1988: 95).[53] Značaj socijalnog kapitala vidljiv je u tome da on olakšava međusobnu interakciju i ima pozitivan utjecaj na djelotvornost poslovnih organizacija. On se može definirati kao gustoća povjerenja koja određuje spremnost pojedinca na suradnju. S ekonomskog gledišta socijalni kapital može biti potencijalno važan jer se svojstva skupine mogu proširiti na cijelo društvo (Paldam i Svendsen, 2000: 2). Socijalni kapital proizlazi iz međuljudskih odnosa i predstavlja sve ono što nas povezuje. Socijalni kapital je razvijanje simpatija i pozitivnih osjećaja od strane jedne ili više osoba prema jednoj ili više osoba. Ovakvi osjećaji mogu uključivati divljenje, brigu, empatiju i odanost koja se mogu razviti u povjerenje. Paradigma socijalnog kapitala kaže da se taj kapital može stvoriti ili koristiti interakcijom. To znači da pojedinac može koristiti kapital koji je nastao stvaranjem simpatija za traženje usluge. Međutim, ako se ti zahtjevi za uslugama nastave, socijalni kapital se smanjuje i interakcija se pretvara u iskorištavanje. Ulaganja u socijalni kapital održavaju lojalnost u društvenim odnosima i mogu olakšavati rješavanje potencijalnih nesuglasica u slučajevima kada se dogodi nešto neočekivano ili negativno.

Socijalni kapital se ne uspostavlja zakonima i političkom voljom, on nastaje proizvoljno i održava se svakodnevnim interakcijama. Njegova razina se mijenja tijekom vremena i može biti relevantan čimbenik u razvoju ekonomije, društva, umjetnosti, religije i kulture. Izgradnja socijalnog kapitala može trajati generacijama ili stoljećima (Putnam i sur., 1993), dok je s druge strane potrebno malo da se zalihe socijalnog kapitala u potpunosti potroše. Iskustva postkomunističkih zemalja istočne i srednje Europe svjedoče veličini i brzini urušavanja

[53] U teoriji društvenih odnosa Coleman objašnjava važnost povezivanja socijalnog kapitala s teorijama financijskog i ljudskog kapitala radi očuvanja zajedničkih vrijednosti lokalne zajednice. Djelovanje pojedinca je oduvijek bilo uvjetovano raznolikim društvenim kontekstima, a ne samo dostupnim financijskim kapitalom i zbog toga ga je potrebno uključivati u sustavna istraživanja.

socijalnog kapitala i sporog oporavka unutar novog ekonomskog uređenja (Chloupková, 2003; Chloupková i sur., 2003).

Socijalni kapital opisuje značajke društvenih organizacija poput: "*povjerenja, normi i mreža koje mogu poboljšati učinkovitost društva olakšavajući njeno koordinirano djelovanje*" (Putnam i sur., 1993: 167). Socijalni kapital je produktivan, olakšava spontanu suradnju i pospješuje postizanje ciljeva kojih ne bi bilo moguće postići u njegovom odsustvu. U poslovnim organizacijama može se promatrati kao čimbenik koji smanjuje transakcijske troškove (engl. *transaction costs*) i troškove praćenja (engl. *monitoring costs*).[54] Siisiäinen (2000) navodi da takva vrsta kapitala ima višestruki „*učinak množenja*“ na druge oblike kapitala i neophodna je u objašnjenju zašto isti iznos ekonomskog i društvenog kapitala može dati različite stupnjeve dobiti. Povjerenje skraćuje vrijeme i čuva energiju potrebnu za provođenje skupih oblika kontrole poput propisanih ugovora, prikupljanja informacija i nadzora poslovanja. Zalihe socijalnog kapitala stvaraju dobru reputaciju koja privlači kvalificirano osoblje, stimulira prodaju dionica po višoj cijeni, dobivanje povoljnijih kredita i uklanja problem manjeg plasmana robe (engl. *free riding problem*) čime se povećava ekonomska učinkovitost zadružnog poslovanja (Nilsson i sur., 2012: 188). Dobar primjer je danski zadružni pokret u kojem su demokratski procesi krajem devetnaestog stoljeća doveli do stvaranja povjerenja i smanjenja transakcijskih troškova u korist poljoprivrednika koji proizvode mlijeko (Svendsen i Svendsen, 2000). Proces izgradnje socijalnog kapitala u ruralnoj Danskoj se odvijao u nekoliko faza. Prva faza razvoja bila je potaknuta ekonomskim impulsima koji su se izgradili u okruženju povjerenja, otvorenosti, demokracije i ekonomske odgovornosti. U tome su važnu ulogu igrali seoske škole i učitelji koji su putem praktične nastave širili osnovne principe po kojima danas posluju zadruge diljem svijeta. U takvom okruženju došlo je do uspostavljanja prvih društvenih mreža i izgradnje zaliha socijalnog kapitala (faza citogeneze). Izgradnja socijalnog kapitala nastavljena je u drugoj fazi u kojoj dolazi do povećanja koncentracije društvenih mreža i značajnog povećanja produktivnosti (faza mitoze). Uspostavljena je uspješna komunikacija na lokalnoj, regionalnoj i nacionalnoj razini usprkos međunarodnim ekonomskim krizama i početnom vladinom skepticizmu prema zadružnim mljekarama. U trećoj fazi dolazi do gubitka povjerenja i slabljenja komunikacije nakon što je danska mljekarska proizvodnja centralizirana i monopolizirana (faza erozije). To je rezultiralo drastičnim padom broja zadruga, a dotadašnji elementi suradnje poput otvorenog članstva, demokratskog odlučivanja, poslovne odgovornosti i

[54] Socijalni kapital i povjerenje se u literaturi često promatra kao javno dobro, za razliku od ljudskog i fizičkog kapitala koji su često smatrani privatnim dobrom (Paldam i Svendsen, 2000: 4).

povjerenja svode su na formalnu ekonomsku obvezu između proizvođača i organizacije.[55] Međutim, u posljednjih četrdesetak godina ponovno dolazi do izgradnje socijalnog kapitala ponajprije pod utjecajem novih ideja koje počinju dominirati u seljačkim zajednicama. Novi ciklus stvaranja socijalnog kapitala obilježavaju međuljudski odnosi i stope reciprociteta, za razliku od socijalnog kapitala iz 19. stoljeća koji se temeljio i izgradio na suradničkim radnim odnosima. Uspostavljano povjerenje postalo je važno višenamjensko „*ljepilo*“ koje olakšava provođenje samoorganiziranih aktivnosti u ruralnim krajevima. Danski zadružni pokret je primjer kako demokratski način gospodarskog razvoja može istodobno ubrzati ekonomski rast poljoprivrede i pozitivno utjecati na izgradnju socijalnog kapitala, ali i povjerenja koje „*podmazuje društvo*“ (Putnam, 1993: 161).

Suradnju je lakše ostvariti u društvima koja su naslijedila zalihe društvenog kapitala u obliku normi uzajamnosti ili mreža građanskih inicijativa (Putnam i sur., 1993: 167). Mnoga bivša komunistička društva imala su nisku razinu građanske tradicije i prije pojave komunizma, da bi totalitarna vlast samo nastavila s iskorištavanjem preostalih zaliha socijalnog kapitala. Paldam i Svendsen (2000) navode da su totalitarni režimi igrali važnu ulogu u uništavaju zaliha socijalnog kapitala. Putnam (1993) tvrdi da postoji korelacija između dužine trajanja diktature i uništavanja povjerenja i suradnje. Tamo gdje nema društvenih normi uzajamnosti i građanskih inicijativa vjerojatnije je za očekivati da će demokratičnost i gospodarski razvoj biti zamijenjeni nemoralnim familijarizmom, klijentelizmom, bezakonjem, neučinkovitom vladom i stagnacijom gospodarstva (Putnam i sur., 1993: 183). Proces izgradnje socijalnog kapitala treba promatrati kao dugotrajni društveni proces koji traži „*lagani dodir od strane vlade*“ jer svaki pokušaj treće strane da potakne izgradnju socijalnog kapitala može biti kontraproduktivan (Paldam i Svendsen, 2000: 16). Utjelovljen u obliku normi i mreža građanskih inicijativa socijalni kapital je osnovni preduvjet učinkovitosti javnih institucija i gospodarskog razvoja. Isto kao što odvijač (fizički kapital) ili fakultetsko obrazovanje (ljudski kapital) povećava individualnu i kolektivnu produktivnost tako i društveni kontakt utječe na produktivnost pojedinaca i grupa (Putnam, 2000: 19).

Dosadašnji pokušaji pronalaženja operativnih rješenja za implementaciju pokazatelja socijalnog kapitala u ekonomske transakcije više su vodili paralizi nego analizi ekonomike poslovanja. Socijalni kapital, kao i sva materijalna imovina, ima svoju ekonomsku vrijednost

[55] Oko 250.000 poljoprivrednika je odlučilo napustiti dotadašnja zanimanja i zaposliti se u obližnjim gradovima. Usporedno s time dolazi do pada broja OPG-a s 200.000, koliko ih je bilo u 1960. godini, na 70.000 sredinom 1990-ih. Početkom 1930-ih poslovalo je oko 1.700 mljekara, da bi 1997. godine njihov broj pao ispod 20. Ekonomija razmjera i konkurencija su doveli do centralizacije i učinkovitije proizvodnje mliječnih proizvoda. Međutim, nakon što se oduzme gubitak društvenog kapitala postaje upitno da li je neto dobitak uistinu ostvario pozitivnu vrijednost (Svendsen i Svendsen, 2000: 80).

koja varira ovisno o vrstama ulaganja. On se može prenositi iz jedne organizacije u drugu putem grupnih integracija zaposlenika i njihovih odnosa (Wilson, 2000: 3-4). Socijalni kapital nije isto što i ljudski kapital. Dok ljudski kapital u sebi sadrži određene vještine i znanja koja su ugrađena u pojedince, socijalni kapital se stvara u matricama i mrežama društvenih odnosa. Međutim, obje vrste kapitala moguće je promatrati kao varijable zaliha i povećavati ih putem ulaganja (engl. *stock variables*). Putnam (1993) predlaže jednostavno operativno rješenje za empirijska mjerenja socijalnog kapitala korištenjem pokazatelja *povjerenja*, *stopa reciprociteta*, *povezanosti organizacija* i ostalih sastavnica socijalnog kapitala.[56] On je uspoređivanjem rezultata sa svojih terenskih istraživanja uočio postojanost razlika u gustoći dragovoljnih organizacija između sjevera i juga Italije. To smatra jednim od razloga zašto sjever Italije ima veći stupanj gospodarskog rasta. Početak stvaranja društveno-gospodarske nejednakosti između sjevera i juga Italije objašnjava postojanjem različitih geografsko-povijesnih čimbenika između dviju pokrajina. Društveno političko djelovanje na jugu Italije nije išlo u korist jačanja povjerenja, povezanosti i interakcija unutar društva i upravo to smatra glavnim razlozima slabije gospodarske razvijenosti juga Italije.

Da bi se proces izgradnje povjerenja mogao u potpunosti razumjeti potrebno je razlikovati različite vrste i razine povjerenja unutar zadružnih organizacija (Szabó, 2010). Najčešća podjela je na *afektivno* i *kognitivno povjerenje* pri čemu je prva vrsta povjerenja više subjektivne i emocionalne prirode, dok se druga vrsta povjerenja temelji na racionalnim odlukama i empirijskim dokazima. Pozivajući se na relevantnu literaturu Wilson (2000) klasificira tri razine povjerenja koje opisuju raznolik sustav povjerenja odnosa u agrobiznis sektoru (engl. *weak*, *semi-strong* i *strong form trust*). On povjerenje definira kao imovinu koja se razvija s vremenom i koja zajedno sa socijalnim kapitalom osigurava koheziju s ostalim upravljačkim mehanizmima kako bi se stvorila unutarnja i vanjska organizacijska učinkovitost. Povjerenje smanjuje tržišnu nesigurnost, olakšava upravljanje nepredviđenim situacijama i stvara dragocjene vremenske resurse važne za logistiku postizanja poslovnih ciljeva (Wilson, 2000: 3).

Jedno od prvih istraživanja koje sistematično ispituje razlike između povjerenja među članovima i povjerenja članova prema upravi zadruge dolazi iz Danske (Hansen i sur., 2002). Na primjeru dviju poljoprivrednih zadruga ispitan je utjecaj kognitivne i afektivne dimenzije povjerenja na: *uspješnost poslovanja*, *ponašanje članova*, *stupanj zadovoljstva* i

[56] Sastavnice socijalnog kapitala su: povjerenje, uzajamnost (obostranost), demokracija, stope gospodarske suradnje, stope volontiranja, norme reciprociteta, osjećaj pripadnosti, gustoća dragovoljnih organizacija, povjerenje prema vladi. Unutar zadruga socijalni kapital proizlazi iz kvalitete odnosa između članova, tijela zadruge, ili zadruga i državnih institucija.

odluku o nastavku suradnje.[57] Rezultati pokazuju da komunikacija s drugim članovima ne predstavlja važan faktor za članove koji su prostorno udaljeniji od uprave zadruge. U takvim zadrugama procjena pouzdanosti članova prema drugim članovima i upravi zadruge temeljit će se više na objektivnim činjenicama, a manje na raspoloženju i osjećajima. S druge strane, kod članova koji su manje prostorno udaljeni afektivno povjerenje odnosno osjećaji koje ostvaruju prilikom suradnje s dionicima bit će izraženiji. Pronalazeći matematičke veze između pojedinih tipova povjerenja i socijalne kohezije zaključuju da: „*... povjerenje među članovima i povjerenje članova prema upravi zadruge predstavlja važne prediktore socijalne kohezije. Socijalna kohezija je mjera jakosti želje članova zadruge da ostanu dio zadružnog poslovanja i prihvate odgovarajuće obveze koje idu uz to.*“ (Hansen i sur., 2002: 54-55).

Kako se internacionalizacija poljoprivredno-prehrambene industrije nastavljala tako su zadruge postajale sve izloženije jačanju konkurencije. Kako bi postignule konkurentnost na tržištu zadruge započinju sa strategijama vertikalne i horizontalne integracije, odnosno pomicanjem naprijed ili unatrag u lancu vrijednosti, odnosno širenjem veličine poslovanja. Usporedno s ovakvim razvojem događaja, primijećeno je da lojalnost i povjerenje članova nestaje i da ponašanje velikih zadruga počinje ličiti ponašanju IOF-a. Istraživanje provedeno u Švedskoj na primjeru jedne zadruge u sektoru ratarstva pokazuje na povezanost veličine članstva i organizacijske složenosti sa zadovoljstvom članova (Nilsson i sur., 2009). Rezultati analize pokazuju da članovi koji smatraju da je zadruga organizacijski velika i složena imaju poteškoća u razumijevanju njenih operacija. Stoga ova skupina članova pokazuje nezadovoljstvo zadrugom kao trgovinskim partnerom i organizacijom članova, postaje skeptična i pokazuje manje povjerenja prema vodstvu. Štoviše, ova skupina članova ne vjeruje da zadruga može restrukturiranjem proizvodnje poboljšati kontrolu članova. Osim gubitka povjerenja i zadovoljstva ova skupina članova je smanjila svoju uključenost u poslovanje zadruge. Istraživanje Fenga i sur. (2016) potvrđuje na primjeru tri poljoprivredne zadruge da zalihe socijalnog kapitala negativno koreliraju s veličinom poslovanja. Ova istraživanja ukazuju na velike promjene koje se dešavaju posljednjih nekoliko desetljeća unutar švedskog zadružnog sustava koji počinje usvajati neoklasične trendove američkih poljoprivrednih zadruga.

Istraživanje Österberga i Nilssona (2009) ukazuje da poslovno uspješniji članovi imaju nizak stupanj povjerenja prema rukovodstvu zadruge, kao i slabiju percepciju o vlastitom utjecaju

[57] Afektivno povjerenje je subjektivne prirode i uključuje emocije, osjećaje i raspoloženje pojedinca prema drugim pojedincima, skupinama ili organizacijama. Kognitivno povjerenje je objektivne prirode i posljedica je razumnog i sistematičnog procesa koji se oslanja na objektivne podatke i podražaje.

na upravljanje zadrugom.[58] Varijabla dobi ne mora nužno objašnjavati pitanje predanosti članova, ali ukazuje da stariji članovi imaju izraženiji kritički način razmišljanja, pozitivnije stavove prema demokratičnosti, aktivniji su u radu skupštine i imaju manje povjerenja prema upravi zadruge. Upravni odbor može računati na podršku članova, sve dok članovi smatraju da su imali dobru priliku utjecati na odluke. Iskustvo članova koji su bili dio nadzornog ili upravnog odbora u prethodnim mandatima nemaju jasno izražene stavove o povjerenju prema tijelima zadruge. Upravo to ukazuje na činjenicu da članovi promatraju svoje zadruge podjednako važno, i kao socijalne, i kao ekonomske institucije.

Ollila i sur. (2011) proučavaju odnose između tri dimenzija socijalnog kapitala unutar zadružnog poslovanja. Tročlanu kategorizaciju socijalnog kapitala su prikazali prostorno-simbolički u obliku hijerarhije.[59] Obilježja članova i društvene odnose unutar zadruge analiziraju proučavanjem načina kako dolazi do pretvorbe između dimenzija socijalnog kapitala. Eksplorativna faktorska analiza (EFA) je izdvojila dva faktora, a klaster analiza dvije skupine članova. Prvi faktor opisuje tradicionalne zadružne vrijednosti, odnose među članovima (*bonding*) i odnose između članova i uprave zadruge (*bridging social capital*). Rezultati ukazuju na međusobnu povezanost dvije dimenzije socijalnog kapitala i važnost svih oblika međuljudskih odnosa unutar zadruge na konačnu odluku članova o nastavku suradnje sa zadrugom. Tako stvoren socijalni kapital „*premošćuje*“ društvene razlike među dionicima koji su prostorno udaljeni ili nisu fizički povezani obiteljskim vezama. Na taj način dragovoljne organizacije pomažu u stvaranju socijalne kohezije, doprinose ekonomskom razvoju pojedinca i podizanju konkurentnosti čitavog društva (države). Drugi faktor je ekonomske naravi i opisuje dinamične poslovne odnose unutar zadruge (engl. *linking social capital*). Članovi koji njeguju tradicionalne zadružne vrijednosti (Faktor 1) konkurenciju vide u lokalnim poljoprivrednicima koji nisu članovi zadruga ili članovima koji svoju robu prodaju privatnim poduzećima. Druga skupina članova koja slijedi čisto ekonomske interese (Faktor 2) konkurenciju vide u svim proizvođačima, češće se žale i skloniji su plasmanu robe putem drugih distribucijskih kanala (engl. *free rider problem*).

---

[58] Osim ekonomskih ciljeva upravitelj zadruge mora brinuti i o socijalnim ciljevima članova. Usluge su u zadrugama važnije od tržišnih cijena i često je slučaj da upravitelj zadruge sljedeći interese manjih poljoprivrednika, većine u skupštini, zanemaruje interesa velikih poljoprivrednika.

[59] Prva dimenzija socijalnog kapitala zasnovana je na osjećajima i nastaje unutar ideološko jakih skupina koje njeguju bliske odnose poput na primjer članova zadruga (engl. *bonding social capitol*). Druga dimenzija socijalnog kapitala se formira između socijalno udaljenijih aktera kao na primjer između upravitelja i članova zadruge. Ova dimenzija socijalnog kapitala opisuje ulogu zadruge kao socijalne ili poslovne organizacije (engl. *bridging social capitol*). Posljednja dimenzija socijalnog kapitala opisuje poslovne odnose i obveze unutar zadruga, ali i kolegijalnost između članova zadruga ili drugih dionika (engl. *linking social capital*).

Nilsson i sur. (2012) predlažu teorijski okvir za procjenjivanje razine socijalnog kapitala u velikim tradicionalno organiziranim poljoprivrednim zadrugama. Teorijski okvir je nastao kao potreba za sprječavanjem gubitka zaliha socijalnog kapitala prilikom provođenja vertikalnih ili horizontalnih integracija koja su tijekom nekoliko zadnjih desetljeća rezultirale poslovnim neuspjesima unutar danskog zadružnog sustava. Unutar zadruga je došlo do razdora između članova i uprave, te gubitka povjerenja što je rezultiralo slabijom interakcijom članova, članova i uprave zadruge, manjim plasmanom, padom reputacije, slabljenjem demokratskog odlučivanja i poteškoćama u rješavanju problema kolektivnog djelovanja. Njihov teorijski okvir daje smjernice upraviteljima zadruga kako rukovoditi socijalnim i financijskim kapitalom u provođenju zacrtanih poslovnih aktivnosti. Teorijski okvir polazi od pretpostavke da dvije vrste kapitala postoje u različitim omjerima unutar organizacije i da je u postizanju poslovnih aktivnosti financijski kapital moguće u određenoj mjeri, ali ne u potpunosti, pretvoriti (zamijeniti) u socijalni kapital i obrnuto.[60] Tako će upravitelj zadruge biti u mogućnosti jedan dio financijskih ulaganja usmjeriti u promidžbu zadružnih proizvoda, a drugi dio u razvoj komunikacije i izravne prodaje s ciljanim skupinama potrošača.

Motivacija za stvaranjem interdisciplinarnih pristupa koji će konceptualno pomiriti istraživače bila je potaknuta globalnim procesom „*demutualizacije*“ koji se počeo širiti unutar zadružnog sektora nakon završetka drugog svjetskog rata.[61] Ovaj proces restrukturiranja tradicionalnih oblika zadruga smatra se najradikalnijim načinom pretvorbe demokratske strukture u tradicionalnu autokratsku ili dioničarsku strukturu poslovanja. Dok se poslovna praksa u tradicionalnim poduzećima regulira cijenama ponude i potražnje za traženim proizvodima, u zadrugama poslovanje reguliraju zalihe socijalnog kapitala, kohezija grupe i uzajamnost odnosa između dionika. Uspoređujući zadružno poslovanje s tržišnim uvjetima Valentinov (2004) zaključuje da: „*zadružno poslovanje određuju sociološki čimbenici na istovjetan način kao što tržište reguliraju ekonomski čimbenici. Zadružna načela u provođenju demokratičnosti njenog poslovanja imaju isti značaj kao što tržišna cijena ili vlasnička struktura imaju značaj u klasičnim trgovačkim društvima*“ (Valentinovu, 2004: 15). Učinkovito i predvidivo djelovanje zadruga i njenih članova nastaje kao „*plod dovršenog procesa socijalizacije, odnosno usvajanja zadružnih normi od strane dionika*“ (Meštrović i

[60] Teorijski okvir se temelji na Bourdieu-ovom (1984) konceptu koji kaže da je socijalni kapital: "*… sastavljen od društvenih obveza koje se u određenim uvjetima mogu pretvarati u ekonomski kapital i institucionalizirati u uzvišenoj formi.*" Njegov koncept socijalnog kapitala se temelji na principima *sociologije sukoba* koja polazi iz perspektive da između aktera postoji određeni sukob interesa.

[61] Proces se odnosi na mijenjanje vlasničkih prava i reorganizaciju zadružne strukture u smjeru isključivo ekonomskih interesa zadruge. Proces „*demutualizacije*“ je na području Sjeverne Amerike najčešće praćen izlaskom novonastalih zadružnih organizacija na burzu radi akumuliranja vanjskog kapitala (Chaddad i Cook, 2004: 358). Pojam se u literaturi naziva „*kapitalizacija zadruga*“.

Štulhofer, 1998: 88). To predstavlja interese različitih teorijskih pristupa u određivanju važnih pokazatelja socijalnog kapitala. Socijalni kapital je osnovni resurs svih organizacija koje rukovode svojim poslovanjem po zadružnim načelima.

Kvaliteta uređenosti ljudskih odnosa između dionika zadruge ovisi o vrsti komunikacije, fleksibilnosti poslovanja, brzini donošenja odluka, unutarnjoj koordinaciji ljudskim i ekonomskim resursima. U tome važnu ulogu imaju zadružna načela kao upravljački instrument koji svoje djelovanje usmjerava jačanju kvalitete međuljudskih odnosa i stvaranju kolektivnog načina razmišljanja u izradama novih perspektiva kapitalizacije zadruga i stvaranja poslovnih rezultata. Ekonomski i socijalni kapital se razlikuju u tehničkim mogućnostima akumuliranja. Jedinice ekonomskog kapitala se mogu neograničeno puta zbrajati, a veći konačan iznos njihovog zbroja u pravilu predstavlja preferirano ekonomsko stanje (npr. niža kamatna stopa, kvalitetnija oprema, veći broj usluga). Međutim, kontinuiran rast broja članova u zadrugama ne mora nužno slijediti proporcionalno povećanje socijalnog kapitala. Razlog tome je sve teže održavanje neformalnih oblika komunikacije između sve većeg broja članova. Socijalni kapital u pravilu pokazuje veću osjetljivost na promjene od ekonomskog kapitala i svaka nemogućnost uprave da nastavi s ulaganjima u socijalni kapital rezultirati će potrošnjom njegovih zaliha. Na slici 2.3. je prikazana povezanost kretanja ekonomskog i socijalnog kapitala unutar zadruge ovisno o veličini članstva.

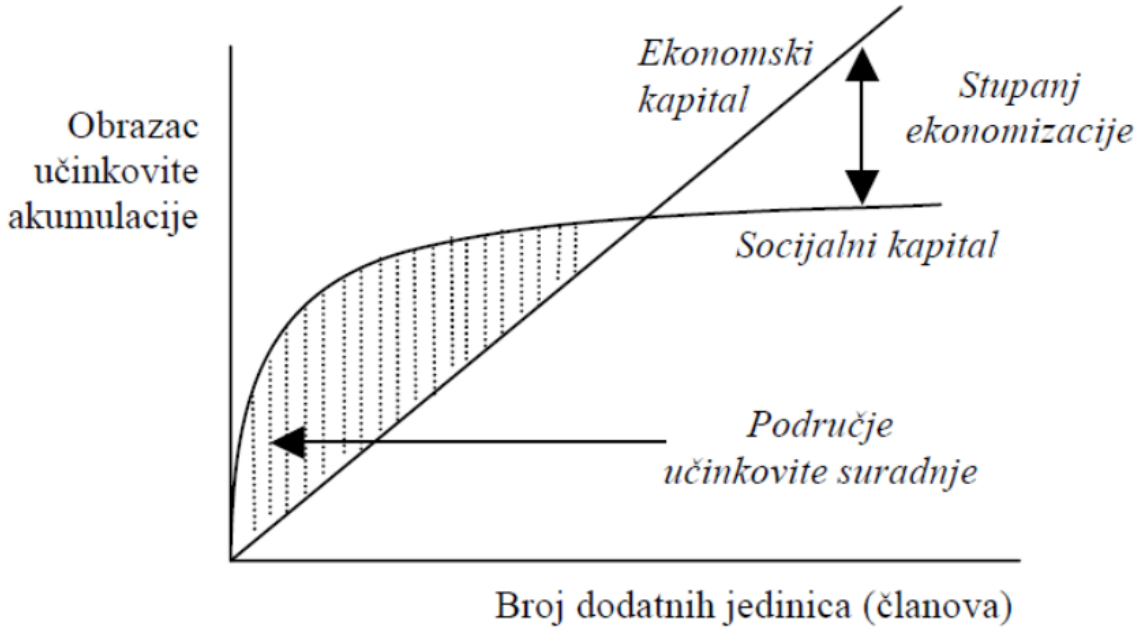

Slika 2.1. Usporedni integrativni učinci ekonomskog i socijalnog kapitala (Valentinov, 2004).

Iz grafikona je vidljivo da obrazac nakupljanja socijalnog kapitala pokazuje super-aditivna svojstva u početnim fazama poslovanja što zadrugama daje prednost nad drugim oblicima poslovanja (engl. *superadditive property*). S nastavkom povećanja broja članova obrazac nakupljanja socijalnog kapitala se počinje mijenjati i njegova sub-aditivna svojstva sve više dolaze do izražaja (engl. *subadditive property*). Zasjenjeno područje u grafikonu predstavlja skup organizacijskih mogućnosti gdje stope povrata na ulaganja u socijalni kapital premašuju stope povrate ulaganja jednakih iznosa u druge oblike kapitala. U tom skupu proizvodnih mogućnosti sklonosti upravitelja zadruge da pokrene proces kapitalizacije i restrukturiranja zadruge nisu razumne, niti teorijski opravdane za očekivati. Izvan zasjenjenog skupa proizvodnih mogućnosti sklonosti upravitelja da pokrene kapitalizaciju i restrukturiranje zadruge postaju teorijski opravdane i vjerojatne su za očekivati. U točki gdje se krivulje ekonomskog i socijalnog kapitala međusobno sijeku dolazi do jednakosti ekonomskog i socijalnog kapitala unutar zadruge (točka ekvilibrija).[62] Predloženi teorijski okvir ne može utvrditi stupanj jednakosti između ekonomskog i socijalnog kapitala, ali pruža dobar uvid kako povećanje volumena poslovanja korelira s gubitkom socijalnog kapitala i sve većom uporabom hijerarhijskih oblika upravljanja.

Teorija socijalnog kapitala je izazovan i relevantan konceptualni alat za agroekonomske istraživače. Zanemarivanje upravljačkog mehanizma koji se nalazi u pozadini ove teorije umanjuje razumijevanje donošenja odluka unutar zadružnih organizacija koje karakterizira složen sustav odnosa između članova, zaposlenika, kooperanata i upravitelja. Kao potpora poslovnim ciljevima povjerenje može imati važnu ulogu u držanju ovih odnosa na okupu. Da bi se u potpunosti razumio postupak donošenja odluka, potrebno je udvostručiti napore u terenskom prikupljanju podataka na razini poduzeća. Anketni upitnici i osobni intervjui su umjetnost koja polako nestaje u agroekonomskoj profesiji. Upravitelji zadruga trebaju detaljan uvid u strateško ponašanje svojih konkurenata i zahtijevaju dobro razumijevanje tržišta, često do najniže razine susjedstva ili kućanstva. U tome im može pomoći prikupljanje primarnih podataka pomoću anketnih upitnika ili intervjua. Osobni razgovori podrazumijevaju stvaranje osobnih kontakata, a osobni kontakti dovode do razvijanja društvenih interakcija i potencijalne izgradnje povjerenja. Postojanje povjerenja utjecati će na kvalitetu podataka, a u konačnici i na kvalitetu ekonometrijskih modela. Prikupljanje podataka korištenjem ovakvih metoda oduvijek je razlikovalo agroekonomske istraživače od klasičnih ekonomskih istraživača. U buduća istraživanja treba uključivati vremenska ograničenja koja će preciznije bilježiti stvarnost svakodnevnog poslovanja od uobičajenih

[62] Točka ekvilibrija predstavlja graničnu točku u kojoj se koncept tradicionalnog zadrugarstva gubi u sjeni globalizacije novih oblika zadružnog poslovanja (vidi Chaddad i Cook, 2004).

bezvremenskih modela optimizacije. Takvi modeli koji proučavaju ekonomsku učinkovitost u različitim vremenskim okvirima i istodobno uključuju povjerenje kao ulazni podatak stvaraju objektivniji ekonometrijski okvir za opisivanje postupka optimizacije zadružnog poslovanja. Stavljanje naglaska na socijalni kapital i povjerenje „*izgraditi će važan intelektualni put za naše kolege, klasične ekonomske istraživače, koji su pojedini agroekonomski istraživači prevalili mnogo više/prije, od drugih, u današnje doba*“ (Wilson, 2000: 11).

2.5. Zadrugarstvo u svijetu i Republici Hrvatskoj

2.5.1. Ekonomski doprinos zadružnog poduzetništva u Europi i svijetu

Najinteresantniji podaci o utjecaju zadrugarstva u nacionalnim i svjetskim ekonomijama dolaze upravo iz najrazvijenijih dijelova svijeta. U Europi socijalna ekonomija doživljava pravi procvat devedesetih godina nakon pada Berlinskog zida kada Europa počinje pridavati pažnju trećem sektoru socijalne ekonomije. Noviji podaci i *Izvješće o doprinosu zadruga u prevladavanju kriza-2012/2321(INI)* (European Parliament, 2012) pokazuju da je danas u EU aktivno 160.000 zadruga koje su u vlasništvu 123 milijuna članova i zapošljavaju 5,4 milijuna ljudi. Samo u Francuskoj, 21.000 zadruga zapošljava jedan milijun ljudi ili oko 3,5% radno aktivnog stanovništva.

Trend jačanja društvene svijesti ne zaobilazi niti velika svjetska gospodarstva poput SAD-a i Kanade. U Japanu je 91% poljoprivrednika uključeno u zadružno poslovanje i ostvaruju godišnji promet u iznosu od 90 milijardi američkih dolara. Zadružni sektor SAD-a broji oko 30.000 zadruga koje otvaraju dva milijuna radnih mjesta i vode brigu o 350,8 milijuna članova. Američke zadruge posjeduju imovinu u vrijednosti od $3 trilijuna, ostvaruju više od $500 milijardi prihoda i isplaćuju plaće radnicima u iznosu $25 milijardi (NCBA, 2015). U ruralnim područjima zadruge opslužuju električnu energiju za 42 milijuna ljudi i generiraju 42% ukupne proizvodnje električne energije SAD-a (2010). U Brazilu (2011) zadruge za socijalnu skrb pružaju medicinske i stomatološke usluge za 17,7 milijuna ljudi ili oko 10% ukupne populacije. U Obali Bjelokosti (2002) zadruge su uložile $26 milijuna za izgradnju škola, seoskih cesta i klinika za novorođenčad (ICA, 2014).

Sektor poljoprivrednih zadruga postiže značajne ekonomske rezultate u cijelom svijetu. U 2010. godini američke poljoprivredne zadruge imale su 28% tržišnog udjela u prehrambenoj industriji i poljoprivredi. Zadruge u Argentini ostvaruju više od 20% ukupnog izvoza pšenice, dok na Novom Zelandu zadružno poduzetništvo generira 3% BDP-a, pokriva 95% domaćeg tržišta i 95% izvoza mliječnih proizvoda na međunarodno tržište. U svijetu 28% od ukupnog broja zadruga s godišnjim prometom većim od $100 milijuna dolazi iz sektora poljoprivrede i prehrambene industrije. U *Top 300 najvećih zadruga u svijetu*, čak 100 zadruga posluje u sektoru poljoprivrede i šumarstva i ostvaruju godišnju prodaju u iznosu od $471,15 milijardi.

2.5.2. Pregled zakonodavstva i razvoj zadrugarstva u RH

Početkom tranzicijskog razdoblja u Hrvatskoj je bilo registrirano oko 2.200 tzv. socijalističkih zadruga u državnom vlasništvu. Na osnovi preuzetog Zakona o zadrugarstvu iz bivše SFR Jugoslavije, zadruge su 1991. godine izdvojene od ostalih državnih poduzeća kao zasebni poslovni entiteti. Pri tome, nisu donijeti operativni propisi o pretvorbi i reguliranju povrata zadružne imovine, niti o načinima njihova upravljanja i poslovanja. Taj se zakon uglavnom nije primjenjivao i sve do sredine devedesetih godina zadrugarstvo RH se nalazi u pravnom vakuumu.[63] Razlog tome je što se tada zadruge u većini političke i stručne javnosti počinju percipirati kao relikt napuštenog komunističkog režima i u pokrenutom procesu privatizacije tretiraju se kao društva kapitala. U tom razdoblju oko 45% zadruga je likvidirano, a preostale nastavljaju poslovno djelovati, ali bez poštivanja međunarodne zadružne prakse i načela.

Početna faza procesa reafirmacije i vraćanja izvornom zadrugarstvu u Hrvatskoj započinje donošenjem prvog Zakona o zadrugama (NN, br. 36/1995).[64] Zakon je bio nedorečen u odredbama i nije precizno regulirao pravno-financijska pitanja i postojanje zadružne revizije. Zadruge se formalno-pravno priznaju kao poslovni subjekti koji uživaju posebnu zaštitu od države u obavljanju registrirane djelatnosti, ali su iz zakona izuzete stambene (SZ) i štedno-kreditne zadruge (ŠKZ).[65] Odredba zakona o minimalno tri fizičke osobe koje mogu osnovati

[63] U procesu pretvorbe socijalističkih zadruga je donijeta Uredba o zabrani raspolaganja zadružnom imovinom (NN, br. 16/1993) kako bi se zaštitila zadružna imovina od nelegalnog prisvajanja.

[64] Izvorno zadrugarstvo na prostoru sadašnje RH ima dugu tradiciju koja datira od sredine 19. stoljeća kada su po uzoru na zemlje zapadne Europe osnovane prve zadruge. Prve zadruge u RH bile su obrtnička zadruga u Pitomači (1862.) i poljoprivredna zadruga na otoku Korčuli (1864.). U razdoblju između dva svjetska rata djelovalo je 1.325 zadruga (Mataga, 2009).

[65] Izmjenama prvog zakona, 2001. godine, briše se odredba o izuzeću stambenih zadruga, a štedno-kreditne zadruge se počinju regulirati posebnim Zakonom o štedno-kreditnim zadrugama (NN, br. 047/1998). Međutim, 2006. godine donošenjem Zakona o kreditnim unijama (NN, br. 141/2006) one pravno nestaju iz zadružnog sustava. Veći dio ŠKZ je likvidiran, a ostale su preoblikovane u kreditne

zadrugu (članak 3) je potaknula osnivanje obiteljskih (pseudo) zadruga.[66] S vremenom se pokazalo da je Vlada nesvjesno potaknula osnivanje zadruga čija je jedina namjena bila korištenje također nejasno definirane državne skrbi (Nedanov i sur., 2012: 213). Koristeći sredstva državne potpore, za osnivanje i izradu poslovnih planova, mnoge novoosnovane zadruge nisu niti započele s poslovanjem. Postojeće zadruge su prema zakonu, bile dužne do kraja godine donijeti i uskladiti svoju poslovnu dokumentaciju u skladu s novim zakonom. Međutim, zakon nije precizno regulirao zaštitu zadružne imovine u slučaju prestanka rada zadruge (članak 23) zbog čega u praksi dolazi do situacija u kojima male interesne skupine počinju prisvajati zadružnu imovinu za osnivanje privatnih poduzeća (Mataga, 2009). Zbog toga u razdoblju primjene prvog zakona dolazi do značajnog pada broja zadruga i osipanja članstva. U Tablici 2.1. su kronološki prikazane sve izmjene u zadružnoj legislativi i kretanje socioekonomskih pokazatelja prije i nakon implementacije relevantnih zakonskih rješenja.

Godine 2002. zakon se mijenja i nadopunjuje u cilju rješavanja pravnih propusta i praznina prvog zakona (NN, br. 12/2002). Izmjene su omogućile da uz fizičke osobe i pravni subjekti mogu sudjelovati u osnivanju zadruge. Posebnim člankom se precizira da će država poticati osnivanje i razvojne projekte zadruga i čitavog sustava (članak 3).[67] Određuje se osnivanje krovne organizacije *Hrvatskog saveza zadruga* (HSZ) i njegova nadležnost u zastupanju i promoviranju zadružnih interesa. Međutim, pristupanje zadruga u HSZ je bilo obvezno i time se nije poštivalo načelo dragovoljnosti. Nažalost, i druge odredbe u izmjenama zakona su pogodovale nastavku urušavanja temeljnih vrijednosti zadrugarstva RH. Najočitiji nedostaci su brisanje odredbe o „*zajedničkom vlasništvu zadružne imovine*“ i neprecizno reguliranje isplate ostvarenog udjela u zadružnoj imovini članovima koji izlaze iz zadruge, što je u praksi dovodilo do poslovnih malverzacija (članak 15).[68] Još jedan nepovoljan segment odnosi se na članak 22 koji navodi da: „*ako u roku od jedne godine, nakon likvidacije zadruge, imovina te zadruge ne bude prenesena u vlasništvo novoosnovane zadruge iste djelatnosti ona postaje državno vlasništvo*“, a o njenoj budućoj namjeni nema riječi. Ovako definiran članak je potaknuo već spomenute nelegalne radnje manjih interesnih skupina i savršen je primjer

unije (KU) koje se danas nalaze u nadležnosti Hrvatske narodne banke (HNB). U RH je aktivno 18 KU, 3 KU se nalaze u stečaju, a 11 KU je u postupku likvidacije (stanje na datum 17. studenog 2020).

[66] To su zadruge koje koristeći zadružno ime uživaju razne pogodnosti i podrške, ali u praksi djeluju kao privatna poduzeća malih grupa ljudi (Antonić, 2007).

[67] Posebna državna skrb se očitovala u novčanim naknadama u iznosu od 5.000 do 100.000 kuna (Matijašević, 2009: 162). U razdoblju od 2000.-2007. godine dolazi do osnivanja 571 zadruge (rast od 61% bez ŠKZ) od kojih mnoge nisu niti započele s djelovanjem (Tratnik i sur., 2011).

[68] Ovaj propust su koristile interesne skupine pojedinaca (klike) koje su namjerno svojim aktivnostima poticale na osipanje članstva radi osobnih interesa i prisvajanja zadružne imovine.

sustavnog urušavanja zadrugarstva u RH. Također, u zakonu je bila propisana obaveza da zadruge moraju svake tri financijske godine biti podvrgnute postupku *skraćene zadružne revizije* (članak 20). Revizijom se trebala kontrolirati provedba i potrošnja sredstava državne financijske potpore i riješiti problem *pseudo zadruga*, ali se u praksi ona nije primjenjivala. Nedorečenosti i pravne praznine u zakonu, s jedne strane su potaknule prividan razvoj zadružnog sustava. U desetak godina njegove primjene, broj zadruga i broj članova se više nego udvostručio, a povećan je i broj zaposlenih u zadrugama za 35%. S druge strane, ove izmjene i dopune zakona izazivaju brojne sumnje u ispravnost i poznavanje tematike od strane stručnjaka koji su ga kreirali, jer ne samo da izmjene nisu uspjele riješiti nedostatke prvog zakona, nego su čak otvorile prostor za daljnju degradaciju i urušavanje zadrugarstva u RH (Mataga, 2009: 210).

Tablica 2.1. Pregled zakonodavstva i promjene u zadružnom sektoru (1995.-2014.)

Pravni akti:	Stavke zakona (regulirane/neregulirane)	Posljedice (pozitivne/negativne)	Socio-demografski pokazatelji:	Godine	
				1995	**2001**
Zakon o zadrugama (NN, br. 36/1995)	➢ minimalno 3 osnivača: samo fizičke osobe ➢ nije regulirana zadružna revizija	✓ pojava *pseudozadruga* ✓ privatizacija zadružne imovine	**Broj zadruga:** **Broj članova:** **Broj zaposlenika:**	1.212 20.650 5.090	713 14.428 3.103
				2002	**2010**
Izmjene i dopune Zakona o zadrugama (NN, br. 12/2002)	➢ minimalno 3 osnivača: fizičke i pravne osobe ➢ regulirana ograničena revizija ➢ osnivanje HSZ	✓ nastavak pojavljivanja *pseudozadruga* ✓ zlouporaba državne potpore za osnivanje zadruga ✓ bolja promocija zadruga	**Broj zadruga:** **Broj članova:** **Broj zaposlenika:**	713 11.940 3.212	1.699 25.587 4.329
				2011	**2012**
Zakon o zadrugama (NN, br. 34/2011)	➢ minimalno 7 osnivača ➢ regulirana zadružna ulaganja ➢ nije regulirana zadružna revizija	✓ rješavanje problema *pseudozadruga* ✓ poboljšanje ekonomske održivosti ✓ nepridržavanje zadružnih načela	**Broj zadruga:** **Broj članova:** **Broj zaposlenika:** **Broj kooperanata:**	2,060 28,866 4,246 20,271	1,069 18,767 2,680 19,825
				2013	**2014**
Izmjene i dopune Zakona o zadrugama (NN, br. 125/2013; 76/2014)	➢ reguliranje novčanih kazni zbog nepoštivanja zadružnih načela ➢ osnivanje HCZP	✓ djelomična primjena zadružnih načela u praksi ✓ jačanje institucijske potpore	**Broj zadruga:** **Broj članova:** **Broj zaposlenika:** **Broj kooperanata:**	1,169 19,485 2,734 20,292	1,222 19,596 2,759 20,271

Izvor: Narodne novine-NN (autorska obrada podataka).

Hrvatska je donošenjem novog Zakona o zadrugama (NN, br. 34/2011) ušla u proces harmonizacije zadružne legislative u skladu s europskim i svjetskim iskustvima. Novi zakon zadruge definira kao posebne oblike pravnih i gospodarskih subjekata, te dodatno regulira posebnosti pojedinih vrsta kao što su radničke (RZ) i socijalne zadruge (SOCZ). Uvažavaju se međunarodna zadružna načela i propisuje njihova primjena. Najveća promjena odnosi se na povećanje minimalno potrebnog broja članova osnivača s tri na sedam što otklanja dugogodišnji problem obiteljskih (pseudo) zadruga (članak 6). Zaštićuje se imovina zadruge koja se u slučaju stečaja nakon podmirenja svih vjerovnika, prenosi na jedinice lokalne samouprave koje su je dužne upotrijebiti za razvoj zadrugarstva (članak 47).[69] Regulira se obveza zadruga da najmanje 5% svoje dobiti izdvajaju u obaveznu pričuvu, a 30% za planiranje budućeg razvoja. Na taj način nastoji se povećati njihova ekonomska održivost i trajnost (članak 37). Zakonom je predviđeno da vanjski investitori (ne članovi) mogu novčano ulagati u zadrugu, ali i dalje oni nemaju nikakva prava u poslovnom odlučivanju (članak 32). Iako to nije u duhu tradicionalnog zadrugarstva, vanjske investicije povećavaju razinu operativnog kapitala (engl. *risk capital*) i održivost zadružnog poslovanja. Prema Mooneyu i Greyu (2002) ovaj članak bi trebao osigurati dokapitalizaciju, ubrzati horizontalno i vertikalno povezivanje zadruga te ojačati njihovu tržišnu konkurentnost, a da zadruge pri tome zadrže poslovnu neovisnost. Zakon je nadopunjen stavkama o nadzoru i novčanim kaznama za nepoštivanje zadružnih načela (članak 15) i stavkama o ovlastima upravljačkih tijela HSZ (članci 13 i 14, NN, br. 125/2013). Godinu dana kasnije novim Izmjenama zakona (NN, br. 76/2014) ove odredbe su ukinute. Izmjenama zakona su smanjena obavezna izdvajanja za osiguranje trajnosti i razvoj poslovanja, s 30% na 20%, čime se nastoji olakšati investiranje (članak 4). Utemeljuje se *Hrvatski centar za zadružno poduzetništvo* (HCZP) da kao pravni nasljednik HSZ nastavi s jačanjem zadružnog sektora i zadrugama osigura konkurentnije mjesto u državnoj potpori (članak 7).[70]

Uspostavom normativnog i institucijskog okvira prema međunarodnim standardima, sređuje se i objektivizira brojčano stanje u zadružnom sustavu RH. Dio aktivnih zadruga s manjim brojem od propisanog broja osnivača, se međusobno združuje ili pripaja većim zadrugama, a iz evidencije se brišu sve neaktivne i sa zakonom neusklađene zadruge.[71] U vrlo kratkom

[69] Zakon je razgraničio imovinu zadruge od imovine zadrugara. Imovinu zadrugara čini novčani iznos koji je svaki član zadruge unio u zadrugu kod osnivanja ili pristupanja zadruzi nakon osnivanja.

[70] Zadnjim izmjenama zakona HCZP se ukida i njegovu zadaću preuzima „*ministarstvo nadležno za poduzetništvo i obrt*“ (članak 11, NN, br. 114/2018). Time su zadruge izgubile krovnu instituciju što svjedoči sustavnom urušavanju institucijske potpore zadrugama u RH.

[71] Donijet je Pravilnik o evidenciji zadruga, zadružnih saveza i ostalih članova HSZ (NN, br. 56/2012). Zadruge su dužne krajem svake godine dostaviti evidencijski list s podacima o upisu u sudski

razdoblju od primjene novog zakona (2011.- 2014.) broj zadruga u RH se gotovo prepolovio, smanjen je ukupan broj zadrugara za 32%, a broj zaposlenih za čak 35%. U tablici 2.2. su prikazane brojčane promjene osnovnih socio-demografskih pokazatelja unutar zadružnog sustava za razdoblje od 2011. do 2016. godine.

U samo tri godine najviše se smanjio broj zadruga u prerađivačkom (65%) i poljoprivrednom sektoru (44%), a kao posljedica toga u tim sektorima dolazi do najvećeg pada broja članova. Istodobno, u nepoljoprivrednom sektoru dolazi do najmanjeg pada broja zadruga i članova, ali taj sektor u prosjeku ima manji broj članova (15) u odnosu na poljoprivredno-prehrambeni sektor (17).[72] U svim zadružnim sektorima, osim u ribarskom, evidentno je i smanjenje broja zaposlenih. Iz ovog podataka se može zaključiti da zadružno poduzetništvo još uvijek nije prepoznato kao moguće rješenje za smanjenje visoke stope nezaposlenosti (19,6%). Prema podacima, više od polovice zadruga nema zaposlenu osobu što može negativno utjecati na realizaciju poslovnih interesa (59%). Navedeno se posebno odnosi na zadruge poljoprivredno-prehrambenog sektora koje svoju strategiju usmjeravaju prema izdvojenom i osjetljivom segmentu tržišta. Zapošljavanjem stručnjaka ili menadžera olakšalo bi se planiranje uspješnije proizvodnje, distribucija, određivanje cijena i prodaja proizvoda (4P splet), te administriranje u skladu sa zakonskim propisima.

Jedino je broj kooperanta, uz manje oscilacije, ostao nepromijenjen tijekom istog razdoblja. Poljoprivredne i prerađivačke zadruge u prosjeku bilježe veći broj kooperanata u odnosu na broj članova. Suradnja s kooperantima pospješuje zadružno poslovanje, ali potencijalno vodi prema „*demutualizaciji*“ zadruga, posebice u uvjetima nelikvidnosti i manjka investicija (Chaddad i Cook, 2004).[73] Istodobno „*privatizacijom*“ zadruga i napuštanjem tradicionalne organizacijske strukture, smanjuju se ekonomski učinci zadruga na razvoj lokalnih područja (Simmons i sur., 2010). Članovi zadruga su za razliku od kooperanta najčešće koncentrirani unutar određene lokalne zajednice gdje privatno i poslovno obitavaju zbog čega imaju više poveznica i razloga da utječu na razvoj lokalnih krajeva.

---

registar, o kategorizaciji djelatnosti prema Nacionalnoj klasifikaciji djelatnosti (NKD-2007), broju zaposlenih, članova i kooperanata. Podaci o broju kooperanata evidentiraju se od 2011. godine.

[72] Zadruge nepoljoprivrednog sektora se bave djelatnostima: građevinarstva (83), trgovine (124), turizma i ugostiteljstva (73). Preostale 194 zadruge spadaju u kategoriju uslužnih djelatnosti i pružaju administrativne, računovodstvene, informatičke, obrazovne usluge, socijalnu skrb, usluge prijevoza i skladištenja, posredovanje u nekretninama, te usluge umjetnosti, zabave i rekreacije.

[73] S aspekta vlasništva Chaddad i Cook (2004) analiziraju pojavu novih oblika zadruga koje nastaju radi prilagodbe globalnoj konkurenciji. Oni identificiraju tri osnova tipa: *zadruge s entitetima koji traže kapital* (engl. *Cooperatives with Capital-Seeking Entities*), *zadruge s udjelima investitora* (engl. *Investor-Share Cooperatives*) i *investicijski usmjerena poduzeća* (engl. *Investor-Oriented Firms*).

Tablica 2.2. Socio-demografski pokazatelji razvijenosti zadružnih sektora (2011.-2016.)

	2011		2012		2013		2014		2015		2016		Indeks
	broj N	udio %	broj N	udio %	broj N	udio %	broj N	udio %	broj N	udio %	broj N	udio %	2016/2011 %
I Poljoprivredne zadruge													
Broj zadruga	887	43.06	429	40.13	472	40.38	497	40.57	531	40.78	495	40.77	55.81
Broj članova	13.786	47.76	7.959	42.41	8.151	41.83	8.197	41.02	8.061	37.56	7.580	37.01	54.98
Broj zaposlenih	2.092	49.27	1.372	51.19	1.341	49.05	1.314	48.04	1.240	45.19	1.208	46.86	57.74
Broj kooperanata	12.624	62.28	12.648	63.80	12.661	62.39	12.624	62.28					
II Ribarske zadruge													
Broj zadruga	61	2.96	37	3.46	41	3.51	40	3.27	42	3.23	39	3.21	63.93
Broj članova	798	2.76	633	3.37	600	3.08	598	2.99	645	3.01	582	2.84	72.93
Broj zaposlenih	91	2.14	85	3.17	140	5.12	122	4.46	157	5.72	158	6.13	173.63
Broj kooperanata	177	0.87	147	0.74	177	0.87	177	0.87					
III Prerađivačke zadruge													
Broj zadruga	306	14.85	176	16.46	202	17.28	107	8.73	221	16.97	205	16.89	66.99
Broj članova	3.548	12.29	2.576	13.73	2.898	14.87	2.064	10.33	3.100	14.44	2.937	14.34	82.78
Broj zaposlenih	554	13.05	349	13.02	383	14.01	298	10.90	451	16.44	430	16.68	77.62
Broj kooperanata	3.182	15.70	3.079	15.53	3.276	16.14	3.182	15.70					
IV Nepoljoprivredne zadruge													
Broj zadruga	806	39.13	427	39.94	454	38.84	581	47.43	508	39.02	475	39.13	58.93
Broj članova	10.734	37.19	7.599	40.49	7.836	40.22	9.126	45.66	9.656	44.99	9.384	45.81	87.42
Broj zaposlenih	1.509	35.54	874	32.61	870	31.82	1.001	36.60	896	32.65	782	30.33	51.82
Broj kooperanata	4.288	21.15	3.951	19.93	4.178	20.59	4.288	21.15					
UKUPNO cijeli zadružni sektor (I + II + III + IV)													
Broj zadruga	2.060		1.069		1.169		1.225		1.302		1.214		58,93
Broj članova	28.866		18.767		19.485		19.985		21.462		20.483		70,96
Broj zaposlenih	4.246		2.680		2.734		2.735		2.744		2.578		60,72
Broj kooperanata	20.271		19.825		20292		20.271						

Izvor: Izračun autora na temelju službenih podataka dobivenih od strane Hrvatskog centra za zadružno poduzetništvo (HCZP) i Financijske agencije (FINA).

Glavno obilježje sektora hrvatskog zadrugarstva su brojčano male zadruge koje u prosjeku zapošljavaju svega 2 djelatnika (16 članova u prosjeku). Također, 2 relevantna pokazatelja nerazvijenosti zadrugarstva u RH su neznatan udio stanovnika u ukupnom članstvu (0,5%) i minoran udio aktivnog stanovništva među zaposlenicima u zadrugama (0,1%).

2.5.3. Financijski pokazatelji uspješnosti zadružnog sustava RH

Osnovni motiv zadružnog organiziranja je postići prednosti koje donosi ekonomija razmjera. Osim smanjenja prosječnih fiksnih troškova, ekonomija razmjera omogućava učinkovitije provođenje nabavnih, distribucijskih i marketinških aktivnosti koje stvaraju bolje financijske učinke. Međutim, poslovni rezultati u poljoprivredno-prehrambenom sektoru nisu dokazali sinergijske učinke zadružnog djelovanja u razdoblju od 2009. do 2013. godine.

Ukupna vrijednost imovine zadružnog sustava je iznosila krajem 2013. godine 291 milijun EUR-a, što je u prosjeku 238 tisuća EUR-a po zadruzi. Zadruge u poljoprivrednom sektoru raspolažu prosječnom imovinom od 315 tisuća EUR-a po zadruzi, što je dvostruko više od prosječne imovine zadruga u nepoljoprivrednom sektoru (152 tisuće EUR). Nova zakonska regulativa je uvjetovala smanjenje broja zadruga i ukupne bilančne imovine zadružnog sustava za 3,5% u promatranom razdoblju. Najveće smanjenje vrijednosti imovine bilježe poljoprivredne zadruge (-17%), a najveće povećanje ribarske zadruge (153%) i to poglavito zbog ulaganja i novoosnovanih zadruga. Ribarske zadruge s udjelom aktive u ukupnom zadružnom sustavu sudjeluju sa 6,5%. U promatranom razdoblju nepoljoprivredne zadruge su povećale vrijednost imovine za 18%, ali je njihova ukupna imovina gotovo dvostruko manja od poljoprivrednih zadruga.

Promatrano razdoblje je obilježeno velikim padom ukupnih prihoda za čak 13%. U najvećem postotku su smanjeni prihodi prerađivačkih zadruga (34%), dok su ribarske zadruge jedine ostvarile rast prihoda (201%). Da bi amortizirale pad prihoda, zadruge su smanjile rashode koji su na razini zadružnog sustava u 2013. godini bili 14% niži u odnosu na 2009. godinu. To se posljedično odrazilo na ukupni financijski rezultat čitavog zadružnog sustava koji je u promatranom razdoblju bio pozitivan. U Tablici 2.3. je prikazan financijski rezultat i godišnji indeksi kretanja dobiti, imovine i produktivnosti zadruga po sektorima. Najuspješnije su bile zadruge nepoljoprivrednog sektora koje su ostvarile rast dobiti za 4,4 milijuna EUR-a, za razliku od zadruga poljoprivrednog sektora koje od 2010. godine kontinuirano povećavaju gubitak. Unutar tog sektora ribarske zadruge u čitavom razdoblju povećavaju neto dobit dok su poljoprivredne i prerađivačke zadruge od 2011. godine poslovale s gubitkom.

Tablica 2.3. Financijski rezultat ukupnog zadružnog sektora u RH (2009. - 2013.)

	Imovina		Dobit (ili gubitak)		Produktivnost	
	2013 EUR	Δ2009-2013 %	2013 EUR	Δ2009-2013 %	2013 EUR	Δ2011-2013 %
Agro-food zadruge (I + II + III)	203.036.579	-10,5	(-1.895.034)	-557,3	15.646	24,9
I Poljoprivredne	153.638.193	-17,3	(-1.704.547)	-282	15.182	19,9
II Ribarske	19.064.368	153,3	444.923	489,4	51.308	99
III Prerađivačke	30.334.018	-9,7	(-635.410)	6,4	7.158	-20,6
Nepoljoprivredne zadruge	88.176.896	17,7	4.889.919	944,2	6.133	11,1
UKUPNO:	**291.213.475**	**-3,5**	**2.994.885**	**239,3**	**11.302**	**13,9**

Izvor: Izračun autora na temelju poslovnih podataka dobivenih od strane Financijske agencije (FINA).

U promatranom razdoblju produktivnost hrvatskog zadružnog sustava se povećala za 14%. Nepoljoprivredne zadruge postižu bolje financijske rezultate, ali bilježe nižu produktivnost u odnosu na zadruge poljoprivredno-prehrambenog (agro-food) sektora. Veća produktivnost zadruga u poljoprivredno-prehrambenom sektoru nije izravna posljedica rasta tržišne vrijednosti proizvoda, već smanjenja ukupnog broja članova. Na razini zadružnog sustava je ostvarena zadovoljavajuća ekonomičnost obzirom da je u svim godinama koeficijent ekonomičnosti bio veći od jedan (1). Od 2009. godine nepoljoprivredne zadruge bilježe rast koeficijenta ekonomičnosti jer su unatoč padu prihoda za 20%, smanjile troškove za 27%. S druge strane, poljoprivredne zadruge ostvaruju manje prihode u odnosu na rashode i dolazi do smanjenja koeficijenta ekonomičnosti (E < 1).

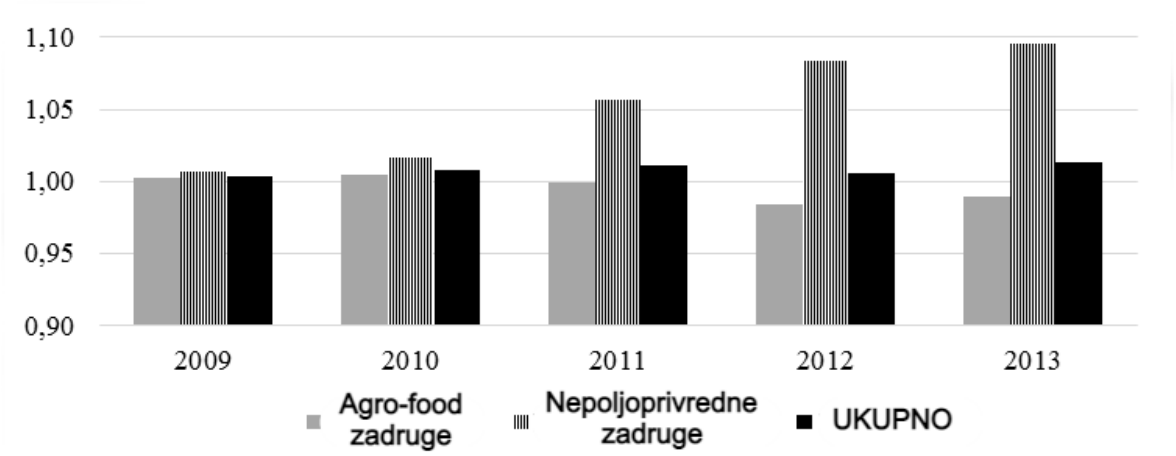

Slika 2.2. Omjer prihoda i troškova po zadružnim sektorima (2009.-2013.).

Stopa povrata na imovinu (engl. *Return on Assets-ROA*) je jedan od najvažnijih pokazatelja profitabilnosti koji ukazuje na sposobnost ukamaćivanje imovine koja se koristi u zadružnom poslovanju. U razdoblju promatranja prinos na imovinu zadružnog sustava kretao se između 0,29% i 1,03%. Prema pokazatelju, profitabilnost poljoprivrednog zadružnog sektora pada, dok u zadrugama nepoljoprivrednog sektora stope povrata kontinuirano rastu.[74] U skladu s prethodnim financijskim pokazateljima, ribarske zadruge sa stopama povrata na imovinu od 2,3% u 2013. godini, predstavljaju najprofitabilniji dio poljoprivrednog zadružnog sustava.

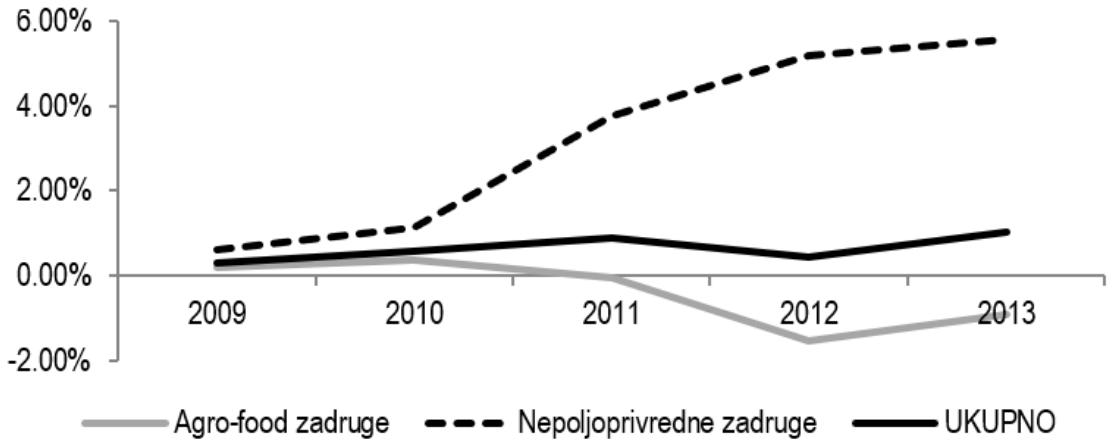

Slika 2.3. Povrat imovine (ROA) po zadružnim sektorima (2009.-2013.).

Predočena financijska analiza ne pruža cjeloviti uvid u poslovnu (ne)uspješnost zadružnog sustava,[75] ali ukazuje na veću poslovnu „*osjetljivost*“ zadruga u poljoprivrednom sektoru na promjene u zakonskoj legislativi, ali i na nepovoljne gospodarske trendove u RH. To se očituje u smanjenju njihove aktive, u negativnim vrijednostima financijskog rezultata i padu ekonomičnosti. Izuzetak su ribarske zadruge čije poslovanje dodatno reguliraju posebni zakonski pravilnici koji precizno propisuju obavezu objedinjenih uvjeta prodaje robe preko zadruge i definiraju mjere državne potpore za razvoj ovih zadruga.[76] Zakonskom obavezom

[74] U 2012. i 2013. godini nepoljoprivredne zadruge su bile znatno profitabilnije (ROA je iznad 5%) u odnosu na prehrambenu industriju gdje je vrijednost ROA u 2013. godinu iznosila 0,97%.

[75] Mateos-Ronco i Lajara-Camilleri (2014) navode da računovodstveni standardi koji se uobičajeno koriste u analizama ocjenjivanja financijske uspješnosti poslovanja nisu prilagođeni posebitostima i heterogenosti zadružnih sektora. Zato je potrebno proširiti i determinirati nove pokazatelje koji će bolje razumijevati ekonomske i financijske situacije poslovnih subjekata socijalne ekonomije.

[76] Prema Pravilniku o ribarskim zadrugama (NN, br. 048/2010), članovi nakon osnivanja zadruge, moraju u prvoj godini plasirati najmanje 20% svoje ukupne proizvodnje/ulova preko ribarske zadruge, a u drugoj i narednim godinama najmanje 80%. Nadalje, ribarskim zadrugama se od 2010. godine

o prodaji robe putem zadruge učinkovito je riješen problem pasivnog članstva (engl. *free rider problem*) i održivost zadružnog poslovanja, što potvrđuju ostvareni financijski rezultati u sektoru ribarstva. Navedena pravna rješenja su dobar primjer transparentnosti zadružnog poslovanja koji favorizira aktivno sudjelovanje članova i korištenje poreznih olakšica bez mogućnosti zlouporabe. Ovakva rješenja treba primijeniti i u drugim zadružnim sektorima.

dodjeljuju više vrsta financijskih potpora do 90% ukupnog iznosa prihvatljivih troškova (za izgradnju, modernizaciju, adaptaciju i opremanje objekata, za kupnju vozila-hladnjača i drugo).

3. METODOLOGIJA ISTRAŽIVANJA

3.1. Izvori podataka i metode istraživanja

U prikupljanju podataka o broju zadruga, članova, zaposlenika i kooperanata koristila se službena evidencija HCZP. Podjela poljoprivrednih zadruga prema sektoru poslovanja i poslovnim obilježjima je određena u skladu s Nacionalnom klasifikacijom djelatnosti-2007 (NKD-2007). Kao glavni izvor financijskih podataka o poslovanju poljoprivrednih zadruga koristila se službena evidencija Financijske agencije (FINA) za razdoblje od 2009. do 2013. godine. Za potrebe izrade doktorskog rada se koristila dostupna dokumentacija iz područja zadružnog poduzetništva, kao i relevantni znanstveni i stručni sekundarni izvori podataka.

Korištena metodologija se svodi na upotrebu klasične deskriptivne statistike i primjenu složenijih multivarijatnih analiza. Od matematičko statističkih metoda u višekriterijskom modelskom pristupu koji omogućava razvijanje hibridnog empirijskog modela korištene su: *Konfirmatorna faktorska analiza* (CFA), *Analiza omeđivanja podataka* (AOMP) i *Metoda potencijala* (MP). U ostvarivanju postavljenih istraživačkih ciljeva koristila se softverska podrška-programski jezik R (R Core Team, 2021).

3.2. Postupak izrade anketnog upitnika i prikupljanje podataka

Primarni podaci o zadrugama i njenim članovima su prikupljeni na terenu pomoću metode anketiranja. U izradi anketnog upitnika korištena su praktična iskustva *The World Values Survey-WVS* mreže (WVS, 2021).[77] Anketni upitnik je izmijenjen i prilagođen za potrebe našeg istraživanja na Zavodu za agrarnu ekonomiku i ruralni razvoj Agronomskog fakulteta Sveučilišta u Zagrebu. Pitanja za mjerenje konstrukta socijalnog kapitala su kreirana na osnovi preliminarnog istraživanja. U prvom koraku je korištenjem standardiziranih WVS anketa i pregledom literature oblikovana prva anketa s velikim brojem mogućih pitanja za mjerenje konstrukata socijalnog kapitala. U drugom koraku je provedeno pilot istraživanje i testiran je značaj anketnog upitnika na uzorku od 11 članova poljoprivredne zadruge *Stella*.

[77] WVS (2021) je međunarodni istraživački projekt odnosno mreža politologa, sociologa, psihologa, antropologa i ekonomista koja je u sedam navrata (od 1981. godine do 2020. godine), na više od 100 zemalja i na 90% ukupne svjetske populacije ispitivala promjenu javnog mijenja prema ljudskim vrednotama. Ispitivan je utjecaj javnog mišljenja na društveno-politički život unutar država. Anketni upitnik se koristi u istraživanjima o kretanju „*zaliha*“ socijalnog kapitala (Meštrović i Štulhofer, 1998).

Nakon završnih izmjena krenulo se s prikupljanjem podataka. U zadnjem koraku je iz daljnje obrade uklonjeno 29 nekorektno ispunjenih anketnih upitnika. Konačni rezultati empirijskog istraživanja se temelje na 202 važeća anketna upitnika.

Anketni upitnik sadrži 49 pitanja (42 pitanja zatvorenog i 7 pitanja otvorenog tipa). Prema sadržaju anketna pitanja su podijeljena u pet tematskih cjelina koja prikupljaju informacije o *motivima pristupa* (**dio A**), *uzajamnosti i povjerenju* (**dio B**), *percepciji prema organizaciji* (**dio C**), *razumijevanju zadružnih načela* i podatke o *trenutnim i budućim aktivnostima* (**dio D**). Svojim sadržajem upitnik daje detaljan uvid u način i volumen poslovanja, kao i u osnovne proizvodne kapacitete zadruge i dionika čime se omogućava dubinska analiza suradnje (vidi Prilog 8.1.). Posljednja grupa pitanja prikuplja podatke o demografskim i socioekonomskim obilježjima ispitanika (**dio E**). Većina zatvorenih pitanja su nominalnog tipa (odgovori ne čine skalu) ili intervalnog tipa (skala s vrijednostima od 1 do 5).

Kao instrument za prikupljanje podataka koristili smo skalu za mjerenje stupnja usvojenosti zadružnih načela (engl. *Likert scale*). Za potrebe empirijske analize je odabrana skala od 59 čestica (engl. *Likert items*) koja mjeri razine usvojenosti zadružnih načela od strane dionika poslovanja. Svaka čestica (pitanje) je odmjerena na skali Likertova tipa od 1 (uopće se ne slažem) do 5 (u potpunosti se slažem). Za mjerenje pouzdanosti mjerne skale koristili smo Cronbach Alpha test koji je potvrdio unutarnju konzistentnost svih čestica u mjernom instrumentu (Cronbach $\alpha = 0{,}856$).[78]

3.3. Uzorkovanje i uzorak istraživanja

Uzorak istraživanja čine poljoprivredne zadruge s pretežitom primarnom proizvodnjom žitarica (više od 50% ukupne proizvodnje) i njeni članovi. Prikupljanje anketnih podataka je provedeno krajem 2017. godine na području pet kontinentalnih županija Slavonije, Baranje i zapadnog Srijema.[79] Prema razredima NKD-2007. determiniran je uzorak koji čine poljoprivredne zadruge u sektoru žitarica (osim riže), mahunarki i uljanih sjemenki (razred 01.11). Uzorak čine svi dionici zadružnog poslovanja, tj. aktivni članovi, uprava, zaposlenici

[78] Cronbach koeficijent provjerava internu analizu konzistentnosti i pouzdanosti ispravljenih čestica u ukupnoj korelaciji i između pojedinih čestica u korelacijskoj matrici. Koeficijent alfa je smjernica za identificiranje adekvatne razine pouzdanosti istraživačkih instrumenata za prikupljanje podataka.

[79] Terensko istraživanje je provedeno na području Brodsko-posavske, Osječko-baranjske, Požeško-slavonske, Virovitičko-podravske i Vukovarsko-srijemske županije. Anketiranje je provedeno kao pojedinačni ili skupni intervjui na skupštinama, radionicama i edukacijama lokalnih poljoprivrednih zadruga, a ispitanicima su pitanja prethodno prezentirana, pročitana i detaljno objašnjena.

i kooperanti. Prema podacima HCZP (stanje 15. travnja 2015.) u pet županija RH aktivno je ukupno bilo 170 poljoprivrednih zadruga, od čega je 56 zadruga djelovalo u sektoru proizvodnje žitarica (33%). Zbog nepostojanja cjelovite i pouzdane evidencije, uzorak za provedbu istraživanja je odabran metodom prigodnog uzorka. Terensko prikupljanje podataka je provedeno na 23 poljoprivredne zadruge što predstavlja 41% ukupnog broja poljoprivrednih zadruga koje se bave uzgojem žitarica u pet promatranih županijama. Ukupno je anketirano 202 ispitanika što je oko 3% ukupnog broja svih dionika koji sudjeluju u radu poljoprivrednih zadruga koje uzgajaju žitarice. U odnosu na sve zadruge u sektoru proizvodnje žitarica uzorkovane zadruge okupljaju ukupno 460 članova (50%), zapošljavaju 271 djelatnika (58%) i surađuju s 3.789 kooperanata (67%).[80] Od navedenih brojki ukupno je uzorkovano (anketirano) 162 člana (%), 32 zaposlenika (%) i 8 kooperanata (%).

Razlog odabira prigodnog uzorka je bio uvjetovan specifičnom naravi problema koji smo željeli istražiti. Zadruge u proizvodnji žitarica imaju bolje financijske pokazatelje i najbrojnije su čineći udio od 60% vrijednosti poljoprivredne proizvodnje svih zadruga u RH (Tratnik i sur., 2007). Također, odbrani tip zadruge obilježava najveći udio članova, zaposlenika i kooperanata u cijelom zadružnom sustavu. Detaljan prikaz veličine uzorka i njegova usporedba s poljoprivrednim zadružnim sektorom za svaku od pet županija je prikazana u Tablici 3.1. Najmanji broj anketa je prikupljen u Požeško-slavonskoj i Virovitičko-podravskoj županiji (26), a najveći broj anketa je prikupljen u Vukovarsko-srijemskoj županiji (88). Iz preostale dvije županije dolazi podjednak broj anketa.[81]

[80] Vrijednosti varijabli broja članova (915), zaposlenika (466) i kooperanata (5.682) svih zadruga koje poslovno djeluju u sektoru žitarica su prikazane na dnu četvrtog stupca Tablice 3.1.

[81] U Osječko-baranjskoj županiji je prikupljeno 38 anketa, a u Požeško-slavonskoj županiji 45 anketa.

Tablica 3.1. Veličina uzorka i poljoprivrednog zadružnog sektora na području pet županija

	SEKTOR POLJOPRIVREDE		UZGOJ ŽITARICA		UZORAK ISTRAŽIVANJA			
	N_P	%	$N_Ž$	%	N_I	N_I/N_P %	$N_I/N_Ž$ %	N_I/N_I %
I. BRODSKO-POSAVSKA ŽUPANIJA:								
Broj zadruga:	22	12,94	6	10,71	3	13,64	50,00	100,00
Broj članova:	196	9,34	63	6,89	25	12,76	39,68	100,00
Broj zaposlenika:	136	23,57	128	27,47	1	0,74	0,78	100,00
Broj kooperanata:	154	2,21	154	2,71	0	0,00	0,00	100,00
Ukupno dionika:	**486**	**5,04**	**345**	**4,88**	**26**	**5,35**	**7,54**	**100,00**
II. OSJEČKO-BARANJSKA ŽUPANIJA:								
Broj zadruga:	65	38,24	19	33,93	7	10,77	36,84	100,00
Broj članova:	859	40,94	333	36,39	33	3,84	9,91	100,00
Broj zaposlenika:	137	23,74	95	20,39	4	2,92	4,21	100,00
Broj kooperanata:	1.582	22,71	1.361	23,95	1	0,06	0,07	100,00
Ukupno dionika:	**2.579**	**26,74**	**1.789**	**25,33**	**38**	**1,47**	**2,12**	**100,00**
III. POŽEŠKO-SLAVONSKA ŽUPANIJA:								
Broj zadruga:	5	2,94	4	7,14	4	80,00	100,00	100,00
Broj članova:	86	4,10	54	5,90	38	44,19	70,37	100,00
Broj zaposlenika:	20	3,47	12	2,58	6	30,00	50,00	100,00
Broj kooperanata:	9	0,13	5	0,09	1	11,11	20,00	100,00
Ukupno dionika:	**115**	**1,19**	**71**	**1,01**	**45**	**39,13**	**63,38**	**100,00**
IV. VIROVITIČKO-PODRAVSKA ŽUPANIJA:								
Broj zadruga:	28	16,47	9	16,07	4	14,29	44,44	100,00
Broj članova:	222	10,58	84	9,18	26	11,71	30,95	100,00
Broj zaposlenika:	26	4,51	11	2,36	0	0,00	0,00	100,00
Broj kooperanata:	608	8,73	121	2,13	0	0,00	0,00	100,00
Ukupno dionika:	**856**	**8,88**	**216**	**3,06**	**26**	**3,04**	**12,04**	**100,00**
V. VUKOVARSKO-SRIJEMSKA ŽUPANIJA:								
Broj zadruga:	50	29,41	18	32,14	6	12,00	33,33	100,00
Broj članova:	735	35,03	381	41,64	40	5,44	10,50	100,00
Broj zaposlenika:	258	44,71	220	47,21	21	8,14	9,55	100,00
Broj kooperanata:	4.614	66,23	4.041	71,12	6	0,13	0,15	100,00
Ukupno dionika:	**5.607**	**58,15**	**4.642**	**65,72**	**67**	**1,19**	**1,44**	**100,00**
UKUPNO (I + II + III + IV + V):								
Broj zadruga:	170	100,00	56	100,00	23	13,53	41,07	100,00
Broj članova:	2.098	100,00	915	100,00	162	7,72	17,70	100,00
Broj zaposlenika:	577	100,00	466	100,00	32	5,55	6,87	100,00
Broj kooperanata:	6.967	100,00	5.682	100,00	8	0,11	0,14	100,00
Ukupno dionika:	**9.643**	100,00	**7.063**	100,00	**202**	**2,09**	**2,86**	**100,00**

Izvor: Izračun autora na temelju službenih podataka FINA-e i HCZP (stanje na datum 13. travnja 2015. godine).

U Tablici 3.2. su prikazana socioekonomska obilježja ispitanika i njihovih poljoprivrednih gospodarstava. Rezultati opisne statistike su pokazali da je muški spol koji u uzorku broji 172 ispitanika (85%) zastupljeniji u odnosu na 30 ispitanica ženskog spola (15%). Prigodni uzorak čine radno sposobne osobe čija se dob kreće u rasponu od 25 do 83 godine, a prosječna dob ispitanika u uzorku je 48 godina (med = 49). Skupina mladih poljoprivrednika sadrži 34 ispitanika (17%), a skupina starijih poljoprivrednika sadrži 168 ispitanika (83%).[82] Prema strukturi obrazovanja, na razini čitavog uzorka 142 ispitanika ima završenu srednju školu (71%), 41 ispitanik je završio višu srednju školu ili fakultet (20%), a 19 ispitanika ima završeno osam razreda osnovne škole (9%). U skupini mladih poljoprivrednika, svi ispitanici imaju završenu barem srednju školu od čega 23 ispitanika ima srednju stručnu spremu (68%), a 11 ispitanika ima višu stručnu spremu ili fakultetsko obrazovanje (32%). U skupini starijih poljoprivrednika dominiraju ispitanici sa srednjom stručnom spremom (71%), a zatim slijede ispitanici s višom stručnom spremom ili fakultetom (18 %) i osnovnim obrazovanjem (11%). Obzirom na spolnu pripadnost, u ženskom dijelu uzorka 23 ispitanice imaju srednju stručnu spremu (77%), 5 ispitanica je završilo osnovnu školu (17%) i 2 ispitanice imaju višu stručnu spremu ili fakultetsko obrazovanje (6%). U muškom dijelu uzorka, čak 119 ispitanika ima srednjoškolsku razinu obrazovanja (69%), 39 ispitanika ima višu stručnu spremu ili završen fakultet (23%), dok 14 ispitanika ima osnovnu razinu obrazovanja (8%).

Na razini uzorka prevladavaju proizvođači koji raspolažu s većim površinama obradivog zemljišta.[83] Većina od 126 ispitanika raspolaže s više od 5 hektara zemljišta (62%), dok 76 ispitanika ima manje od 5 hektara zemljišta (38%). Rezultati pokazuju da se 112 ispitanika bavi ratarstvom (55%), 52 ispitanika mješovitom proizvodnjom (26%), 17 ispitanika se bavi stočarstvom (8%), 14 ispitanika voćarstvom (7%) i 7 ispitanika povrtlarstvom (4%). Ako se promatra po sektorima, ispitanici s najvećim površinama bave se ratarskom proizvodnjom gdje 61 ispitanik ima više od 10 hektara zemljišta (54%), 32 ispitanika ima između 3 i 10 hektara (29%), a 19 ispitanika ima manje od 3 hektara zemljišta (17%). Poljoprivrednici koji posjeduju veće površine zemljišta prevladavaju i u sektoru voćarstva gdje 6 ispitanika ima od 10 do 20 hektara (43%), 5 ispitanika ima između 3 i 10 hektara (36%), dok 3 ispitanika ima manje od 1 hektara obradivog zemljišta (21%). U sektoru stočarstva 8 ispitanika ima od 3 do 10 hektara (47%), 6 ispitanika ima više od 10 hektara (35%) i 3 ispitanika ima manje

[82] Dokumenti EU mlade poljoprivrednike definiraju kao radno sposobne osobe starije od 18 i mlađe od 40 godina (European Commision, 2016). Samo 11% poljoprivrednih gospodarstava u zemljama EU su rukovođene od strane mlađih poljoprivrednika. Na negativan trend *senilizacije* u poljoprivredi pokušava se utjecati pružanjem izravne financijske pomoći za pokretanje proizvodnje, dohodovnim potporama i drugim pogodnostima poput edukacije i osposobljavanja (engl. *young farmer payments*).

[83] Prema Popisu poljoprivrede iz 2003. godine prosječna veličina poljoprivrednog gospodarstava u RH iznosila je 2,9 hektara, dok prema podacima EUROSTAT-a prosječna veličina iznosi 5,6 hektara.

od 3 hektara zemljišta (18%). Među ispitanicima koji se bave mješovitom proizvodnjom 30 ispitanika ima od 3 do 10 hektara (58%), 17 ispitanika ima manje od 3 hektara (33%) i 5 ispitanika ima više od 10 hektara zemljišta (9%). Najmanje je zastupljeno povrtlarstvo kojim se bave najsitniji proizvođači. U tom sektoru 4 ispitanika ima male parcele s površinama veličine od 1 do 3 hektara (57%), 2 ispitanika ima između 5 i 10 hektara (29%), a samo 1 ispitanik ima više od 20 hektara zemljišta (14%).

Iz analize je vidljivo da su poljoprivrednici s većim površinama zemljišta skloniji povećanju proizvodnje i uzimanju novih površina pod zakup u odnosu na ispitanike koji raspolažu manjim površinama. Na razini cijelog uzorka 112 ispitanika ima zemlju u zakupu (55%), a 90 ispitanika nema zemlje u zakupu (45%). Kako raste površina zemljišta s kojom ispitanici raspolažu tako raste i udio ispitanika koji imaju zemlju pod zakupom. Unutar skupine ispitanika koji raspolažu s maksimalno 3 ha zemljišta samo 19 ispitanika je uzelo zemlju u zakup (41%), unutar skupine ispitanika koji raspolažu s 3 do 10 ha zemljišta 43 ispitanika ima zemlju u zakupu (56%), dok unutar skupine ispitanika koji raspolažu s više od 10 ha zemljišta 50 ispitanika ima dodatnog zemljišta pod zakupom (63%). Može se zaključiti da su poljoprivrednici s većom proizvodnjom skloniji riziku i poduzetnički su više orijentirani. Hi-kvadrat test je potvrdio postojanje značajne povezanosti između veličine zemljišta u vlasništvu ispitanika i uzimanja dodatnog zemljišta pod zakup ($\chi^2(5) = 17{,}659$, $p = 0{,}003$).[84]

Uzorak istraživanja čine iskusni proizvođači koji se poljoprivrednom proizvodnjom bave duži niz godina. Čak 122 ispitanika aktivno djeluje u poljoprivrednom sektoru duže od 10 godina (60%), dok 66 ispitanika djeluje manje od 10 godina (33%). Potrebno je napomenuti da je 14 ispitanika odgovorilo da se poljoprivrednom proizvodnjom počelo baviti tek od trenutka ulaska u zadrugu (7%). Na razini uzorka, 111 ispitanika je registrirano kao poljoprivrednik u stalnom radnom odnosu (50%), 30 ispitanika nisu registrirani poljoprivrednici (30%), dok se 26 ispitanika i dalje bavi poljoprivredom unatoč mirovini (26%).[85] Najveći broj ispitanika, čak 162, su članovi zadruge (80%), 32 ispitanika poslovno surađuje sa zadrugom (16%), a 8 ispitanika je zaposleno u zadruzi (4%). Na razini uzorka, 117 ispitanika sudjeluje u radu zadruge od početka (58%), a 85 ispitanika se naknadno uključilo u njeno poslovanje (42%).

[84] Dobivena vrijednost hi-kvadrat statistike ($\chi^2(5) = 17{,}659$) je veća od granične vrijednosti hi-kvadrat distribucije kontigencijske tablice koja ima 6 redaka i 2 stupca ($\chi^2(5) = 16{,}750$, $p = 0{,}005$).

[85] Čak 35 ispitanika je navelo da se bave djelatnostima poput pčelarstva, ribarstva, domaćinstva i dr.

Tablica 3.2. Sociodemografska obilježja dionika uzorkovanih poljoprivrednih zadruga

Varijable	Socioekonomska obilježja ispitanika	UKUPNO		Brodsko-posavska		Osječko-baranjska		Požeško-slavonska		Virovitičko-podravska		Vukovarsko-srijemska	
		F N	Udio %	F N	Udio %	F N	Udio %	F N	Udio %	F N	Udio %	F N	Udio %
Spol	Muški	172	85,15	24	11,88	33	16,34	44	21,78	18	8,91	53	26,24
	Ženski	30	14,85	2	0,99	5	2,48	1	0,50	8	3,96	14	6,93
Dob	Mladi poljoprivrednici (< 40 god.)	34	16,83	3	1,49	11	5,45	5	2,48	5	2,48	10	4,95
	Stariji poljoprivrednici (> 40 god.)	168	83,17	23	11,39	27	13,37	40	19,80	21	10,40	57	28,22
Stupanj obrazovanja	Osnovna škola	19	9,40	4	1,98	1	0,50	4	1,98	5	2,48	5	2,48
	Srednja škola	142	70,30	20	9,90	24	11,88	36	17,82	13	6,44	49	24,26
	Viša škola ili fakultet	41	20,30	2	0,99	13	6,44	5	2,48	8	3,96	13	6,44
Vrsta proizvodnje	Ratarstvo	112	55,45	15	7,43	28	13,86	15	7,43	10	4,95	44	21,78
	Povrtlarstvo	7	3,47	5	2,48	2	0,99	0	0,00	0	0,00	0	0,00
	Voćarstvo	14	6,93	0	0,00	1	0,50	9	4,46	3	1,49	1	0,50
	Stočarstvo	17	8,41	0	0,00	4	1,98	7	3,47	3	1,49	3	1,49
	Mješovita proizvodnja	52	25,74	6	2,97	3	1,49	14	6,93	10	4,95	19	9,41
Aktivno bavljenje poljoprivredom	Od ulaska u zadrugu	14	6,93	0	0,00	3	1,49	3	1,49	2	0,99	6	2,97
	Manje od 5 godina	21	10,40	1	0,50	2	0,99	7	3,47	3	1,49	8	3,96
	Od 5 do 10 godina	45	22,28	6	2,97	9	4,46	10	4,95	5	2,48	15	7,43
	Od 10 do 20 godina	54	26,73	10	4,95	11	5,45	11	5,45	5	2,48	17	8,42
	Više od 20 godina	68	33,66	9	9,41	13	6,44	14	6,93	11	5,45	21	10,40
Veličina vlastitog zemljišta	Manje od 1 hektara	22	10,89	0	0,00	2	0,99	8	3,96	4	1,98	8	3,96
	Od 1,1 do 3,0 hektara	24	11,88	7	3,47	6	2,97	1	0,50	5	2,48	5	2,48
	Od 3,1 do 5,0 hektara	30	14,85	4	1,98	3	1,49	6	2,97	8	3,96	9	4,46
	Od 5,1 do 10,0 hektara	47	23,27	11	5,45	8	3,96	7	3,47	5	2,48	16	7,92
	Od 10,1 do 20,0 hektara	37	18,32	3	1,49	10	4,95	11	5,45	3	1,49	10	4,95
	Više od 20 hektara	42	20,79	1	0,50	9	4,46	12	5,94	1	0,50	19	9,41
Radni odnos	Ne poljoprivrednik	30	14,85	4	1,98	8	3,96	5	2,48	5	2,48	8	3,96
	Poljoprivrednik	111	54,95	16	7,92	16	7,92	29	14,36	6	2,97	44	21,78
	Umirovljenik	26	12,87	4	1,98	6	2,97	4	1,98	6	2,97	6	2,97
	Ostalo	35	17,33	2	0,99	8	3,96	7	3,47	9	4,46	9	4,46
Uloga u zadruzi	Član zadruge	162	80.20	25	12,38	33	16,34	38	18,81	26	12,87	40	19,80
	Kooperant	32	15.84	1	0,50	4	1,98	6	2,97	0	0,00	21	10,40
	Zaposlenik	8	3.96	0	0,00	1	0,50	1	0,50	0	0,00	6	2,97
Osnivanje zadruge	Sudjelovao	118	58,42	24	11,88	23	11,39	31	15,35	20	9,90	20	9,90
	Nije sudjelovao	84	41,58	2	0,99	15	7,43	14	6,93	6	2,97	47	23,27
Ukupan broj ispitanika i po županijama:		**202**	**100,00**	**26**	**12,87**	**38**	**18,81**	**45**	**22,28**	**26**	**12,87**	**67**	**33,17**

Izvor: Izračun autora na temelju prikupljenih anketnih podataka.

3.4. Metode za izradu modela optimizacije zadružnog poslovanja

Određivanje stupnja usvojenosti zadružnih načela u modelu optimizacije zadružnog poslovanja nad prikupljenim podacima je provedeno korištenjem sljedećih statističkih metoda:

1. Analiza omeđivanja podataka-AOMP (engl. *Data Envelopment Analysis-DEA*);
2. Konfirmatorna faktorska analiza-CFA (engl. *Confirmatory Factor Analysis-CFA*) i
3. Metoda potencijala-MP (engl. *Potential Method-PM*).

3.5. Analiza omeđivanja podataka-AOMP

3.5.1. Pregled literature o razvoju i primjeni Analize omeđivanja podataka

Metoda od samog početka bilježi značajan zamah i postaje važan matematički instrument za uspoređivanje efikasnosti i produktivnosti poslovanja organizacija, sektora, poduzeća, regija i zemalja. U literaturi je zabilježeno više tisuća teorijskih i primijenjenih znanstvenih priloga, a broj empirijskih radova i dalje eksponencijalno raste. Emrouznejad i Yang (2018) navode da je AOMP ušla u fazu potpune zrelosti sredinom devedesetih godina prošlog stoljeća. Već krajem 1995. godine objavljeno je više od 800 članaka, da bi do 2001. godine bilo registrirano više od 1.800 radova (Gattoufi i sur., 2004). Tijekom zadnja četiri desetljeća (1978-2016) publicirano je više od 10.300 članaka, a samo u posljednje četiri godine publicirano je na godišnjoj razini u prosjeku više od 1.000 radova.[86] Raznovrsnost literature svjedoči o korisnosti AOMP u mjerenjima efikasnosti opskrbnih lanaca, transporta i javne politike. Najnovija istraživanja su iz područja ekološke efikasnosti, mjerenja emisije plinova ugljičnog dioksida, održivog razvoja i zaštite okoliša. Ispituju se mogućnosti njene upotrebe u vrednovanju komponenata efikasnosti (engl. *benchmarking*) i procjenjivanju obilježja proizvodnih mogućnosti bez upotrebe distribucije vjerojatnosti (engl. *bootstraping*). Primjena AOMP postaje neizostavna karika u računovodstvu (Lee, 2009), bankarstvu (Kumar i Gulati, 2008), ruralnom razvoju (Vennesland, 2005), sektoru poljoprivrede (Galanopoulos i sur., 2006) i šumarstva (Viitala i Hänninen, 1998).

[86] Istraživanje nije obuhvatilo oko 2.200 rukopisa koji su objavljivani kao radni dokumenti, poglavlja knjiga ili sažeci konferencija. Dokumenti poput doktorskih disertacija i internih rukopisa koji nisu bili napisani na engleskom jeziku također nisu bili uključeni u analizu (Emrouznejad i Yang, 2018: 4-5).

Prve primjene AOMP u Hrvatskoj se javljaju tijekom druge faze razvoja (1995.-2003.) kada je metoda već potpuno usvojena od strane istraživača diljem svijeta (Rabar, 2010). Primjenjuje se u bankarstvu (Neralić, 1996), poljoprivredi (Bahovec i Neralić, 2001), zdravstvu (Rabar, 2010) i ocjenjivanju regionalne efikasnosti (Rabar, 2013), ali i drugim područjima kao što su industrijski sektor i turizam. Brojne primjene su u području šumarstva, gdje je u razdoblju od 2006. do 2011. godine, skupina autora objavila čitav niz znanstvenih radova.

U mjerenjima ekonomske efikasnosti zadruga dominira upotreba neparametrijskih metoda koje se koriste u uvjetima kada uzročno posljedični odnosi ili oblik proizvodne funkcije nisu prethodno poznati.[87] Guzmán i Arcas (2008) pokazuju da mjerenje efikasnosti pomoću AOMP može biti koristan dodatak klasičnim financijskim analizama koje na temelju računovodstvenih pokazatelja donose necjelovite zaključke o efikasnosti zadružnog poslovanja i zanemaruju pogodnosti koje donosi članstvo. Ova metoda se pokazuje učinkovitom u mjerenjima utjecaja različitih razmjera inputa na prihode zadružnog poslovanja (Arcas i sur., 2011), u usporedbama efikasnosti i granične proizvodnje između zadruga i investicijski usmjerenih poduzeća (Ferrier i Porter, 1991; Soboh i sur., 2014).

Nema sumnje da će AOMP biti važno područje i u budućim istraživanja posebice u mjerenjima efikasnosti poslovanja koje obilježava složenija organizacijska struktura s više ulaznih i više izlaznih podataka. Široka mogućnost upotrebe i razvoj računalnih programa unazad desetak godina olakšala je primjenu metode, doprinijela njenom metodološkom sazrijevanju, povećanju baze podataka i omogućila kronološku usporedbu rezultata između novih i postojećih studija (Emrouznejad i sur., 2008: 155-156). Također, tradicionalni regresijski modeli izračune temelje na modelima koji analiziraju utjecaj više ulaznih podataka na jednu proizvodnju, dok AOMP modeli imaju mogućnost istodobnog analiziranja više izlaznih i ulaznih podataka (Cooper i sur., 2007: 115). Također, AOMP dopušta da korišteni podaci mogu biti izraženi u različitim mjernim jedinicama, a njihovu međusobnu povezanost nije potrebno prethodno poznavati. Za razliku od metoda koje se temelje na pristupu maksimalne vjerodostojnosti, AOMP u aproksimacijama tehnoloških pretpostavki i procjenama mjera efikasnosti koristi linearno programiranje (Bogetoft i Otto, 2011: 82).[88] U

[87] Neparametrijske metode koriste matematičko programiranje u procjenjivanju proizvodnih funkcija i zbog toga se češće koriste u analizama efikasnosti. Nasuprot njima, parametrijske metode koriste statističke metode u ekonometrijskim procjenama proizvodnih funkcija. Ovi pristupi se razlikuju u pretpostavkama koje donose o korištenim podacima, ekonomskom ponašanju jedinica odlučivanja i mogućnostima pristupa da prepoznaju slučajne pogreške u podacima (Coelli i sur., 2005: 7).

[88] Procjenjivanje mjera efikasnosti se temelji na načelu *minimalne ekstrapolacije* tj. donošenju zaključaka o minimalnom uzorku koji uvažava tehnološke pretpostavke o skupu proizvodnih mogućnosti (engl. *minimal extrapolation principle*). Prva *pretpostavka o raspoloživosti podataka* propisuje odbacivanje nepotrebnih inputa i outputa iz skupa proizvodnih mogućnosti (engl. *free*

takvim uvjetima, pitanja optimizacije postaju jednostavni istraživački problemi linearnog programiranja koji uspješno analiziraju aktivnosti poslovanja (engl. *activity analysis*), promjene intenziteta stopa povrata (engl. *scale efficiency*), odabir strategije najmanjih troškova ili proizvodnje u cilju maksimiziranja ukupnih novčanih prihoda (engl. *allocative efficiency*).

Ispitivanje efikasnosti zadružnog poslovanja primjenom AOMP do dosada nije bio predmet rasprava ili istraživanja u RH, ali i na širim prostorima. Zbog toga naše empirijsko istraživanje predstavlja izvorni istraživački rad o stanju i mogućnostima zadružnog poduzetništva u sektoru poljoprivrede nakon raspada poljoprivrednih kombinata i bivše SFR Jugoslavije.

3.5.2. Osnove mjerenja (ne)efikasnosti u Analizi omeđivanja podataka

Analiza omeđivanja podataka (engl. *Data Envelopment Analysis-DEA*) je neparametrijska metoda za mjerenje relativne efikasnosti kompleksnih jedinica (DMU) u kojima nije jasno izraženo koji ulazni podaci (inputi), i u kojoj mjeri, sudjeluju u stvaranju izlaznih podataka (outputa). Ova metoda koristi linearno programiranje u procjenjivanju relativne efikasnosti jedinica odlučivanja koje koriste iste ulazne podatke (resurse) u stvaranju izlaznih podataka (učinaka).[89] Donositelji odluka se razlikuju prema razini resursa kojima raspolažu i razini aktivnosti unutar proizvodnog ciklusa.

Neparametrijska analitička metoda se temelji na konceptu Farellove (1957) granice relativne efikasnosti čija osnova predstavlja zamjenu za krivulju proizvodne funkcije kakvu koriste parametrijske metode.[90] Stupanj neučinkovitosti računao se na temelju euklidske

---

disposability assumption), dok *pretpostavka konveksnosti* navodi da je prosječni ponder izvedivih planova proizvodnje također izvedivo rješenje (engl. *convexity assumption*). Varijante treće pretpostavke ukazuju na povezanost promjenjivosti stopa povrata i razmjera proizvodnje (engl. *return to scale assumption*), dok posljednja *pretpostavka aditivnosti* propisuje da je zbroj izvedivih proizvodnji ostvarivo rješenje (engl. *additivity assumption*), ali se zbog svoje složenosti i težine provedbe najmanje koristi u mjerenjima efikasnosti (Bogetoft i Otto, 2011: 85-90).

[89] U hrvatskoj literaturi DEA se prevodi kao metoda Analize omeđivanja podataka (AOMP ili AOP), dok DMU prevodimo kao jedinice odlučivanja ili donositelje odluka (engl. *decision making units-DMU*). Pojam jedinice odlučivanja (DO) odnosi se na bilo koji entitet čiju sposobnost pretvaranja ulaznih podatka (ulaza, inputa) u izlazne podatke procjenjujemo (izlaze, outpute).

[90] Farrellov koncept polazi od tri osnovne pretpostavke: (1) Na krivulji jednake granične proizvodnje nalaze se najefikasnije jedinice za procjenu, dok su relativno neefikasne jedinice smještene ispod izokvante krivulje. (2) Granična funkcija je djelomično linearna i konveksna krivulja koja nema pozitivan nagib i predstavlja najbolju proizvodnu praksu. (3) Svaka promjena izlaza uzrokuje istu proporcionalnu promjenu ulaza (engl. *constant return to scale*). Negativan nagib izokvante često se

udaljenosti između omjera ulazno-izlaznih podataka kod neefikasnih i efikasnih DMU smještenih na graničnoj krivulji. Također, Farrell predlaže novi pristup analiziranja aktivnosti koji koncept produktivnosti zamjenjuje sa širim pojmom efikasnosti zbog čega njegove mjere postaju primjenjive u svim oblicima proizvođačkih organizacija. Time je uklonio ograničenja metoda koje nisu mogle kombinirati višestruke ulazne podatke u izračunavanju tehničke i cjenovne efikasnosti (model s jednim izlazom). Koncept ove makroekonomske teorije bio je osnova za razvoj AOMP kao metodologije za procjenu efikasnosti.

Njegov koncept su proširili Charnes i sur. (1978), a dodatno nadogradili Banker i sur. (1984). Prva skupina autora (1978) je predstavila ulazno orijentirani model koji je istodobno obuhvaćao više ulaznih i više izlaznih podataka (CCR model), dok je druga skupina autora (1984) nadogradila CCR model s mogućnošću razdvajanja tehničke efikasnosti na čistu tehničku efikasnost i efikasnost povrata (BCC model). Pri tome je osnovna pretpostavka kod BCC modela da promjena ulaznih podataka ne rezultira proporcionalnom promjenom izlaznih podataka (engl. *variable return to scale*).

Na temelju ostvarenih izlaznih podataka i korištenih ulaznih podataka, za svaku usporedivu DMU u skupu proizvodnih mogućnosti, računa se relativna mjera efikasnosti po uobičajeno korištenoj formuli:[91]

$$efikasnost = \frac{linearna\ kombinacija\ outputa\ s\ nepoznatim\ koeficijentima}{linearna\ kombinacija\ inputa\ s\ nepoznatim\ koeficijentima} \qquad (3.1.)$$

Učinkovite DMU određuju granicu proizvodnih mogućnosti i njihove mjere efikasnosti ostvaruje vrijednost jedan ($\theta^* = 1$).[92] One ne predstavljaju univerzalno rješenje nego najbolju moguću praksu kojem teže neefikasne DMU unutar skupa mogućnosti. Neefikasne DMU nalaze se ispod granice proizvodnih mogućnosti i ostvaruju vrijednosti indeksa efikasnosti u rasponu od nula do jedan ($0 \leq \theta^* < 1$). Stupanj (ne)efikasnosti računa se uspoređivanjem indeksa efikasnosti promatrane DMU s indeksom efikasnosti DMU koje su smještene na

izostavlja u literaturi, ali se podrazumijeva jer u protivnom povećanje primjene ulazno-izlaznih čimbenika rezultira smanjenjem proizvodne efikasnosti (Farrell, 1957: 255-256).

[91] Indeks efikasnosti je relativna mjera koja u omjer stavlja ponderirane ulazne i izlazne podatke za svaku DMU. Mjera ovisi o vrsti i broju DMU, ali i o strukturi, broju inputa i outputa uključenih u analizu.

[92] U ekonomskom kontekstu *granica proizvodnih mogućnosti* ili *granica efikasnosti* (engl. *efficient frontier*) predstavlja najveću moguću razinu proizvodnje koju može ostvariti svaka DMU s raspoloživim ulaznim podacima. Ili, minimalnu količinu resursa koja se mora utrošiti ako promatrana DMU želi zadržati određenu razinu proizvodnje.

granici efikasnosti. Metoda omogućava usporedbu mjera tehničke i cjenovne efikasnosti i koristi se kao kriterij za rangiranje DMU unutar promatranog skupa.

Na slici 3.1. je prikazan skup proizvodnih mogućnosti kojeg čini šest poljoprivrednih zadruga {P_1, P_2, P_3, P_4, P_5, P_6} i granice efikasnosti na primjeru dva CCR modela. Na lijevoj strani slike je prikazan CCR model s jednim ulazom i jednim izlazom, dok je na desnoj strani slike prikazan izlazno usmjereni CCR model s jednim ulazom i dva izlaza. U nastavku su navedeni i objašnjeni osnovni pojmovi, vrste i principi mjerenja efikasnosti. Na primjeru dva modela dana je kratka interpretacija rezultata u svrhu boljeg razumijevanja metode.

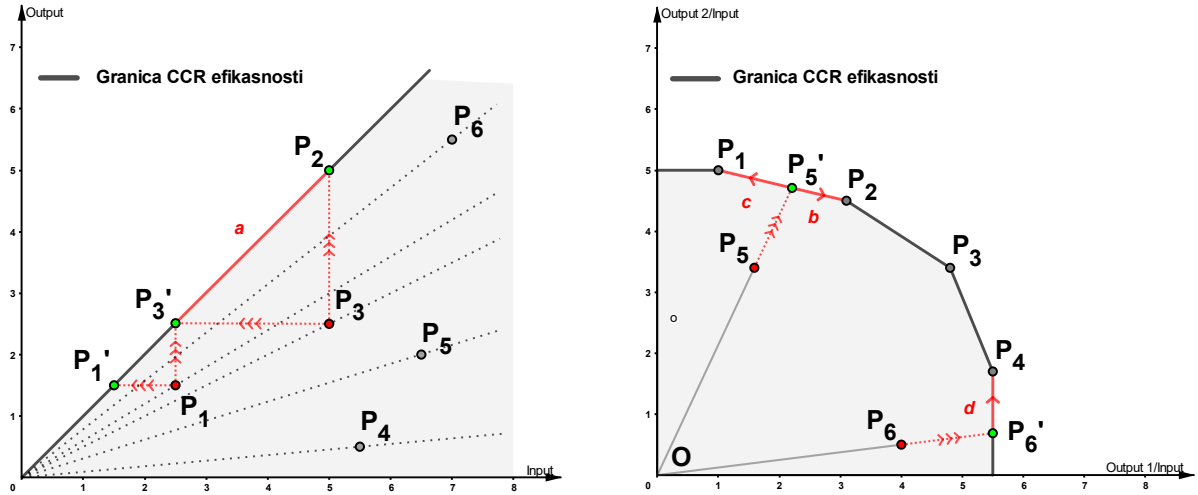

Slika 3.1. Granica efikasnosti za skup poljoprivrednih zadruga u dva različita CCR modela.

U lijevom grafu gornje slike nagibi pravaca koji povezuju zadruge s ishodištem koordinatnog sustava jednaki su omjeru njihovih izlaznih i ulaznih podataka odnosno rješenju formule (3.1.). Najveći nagib u promatranom skupu ima pravac koji povezuje ishodište koordinatnog sustava i zadrugu P_2. Taj pravac se naziva granica proizvodnih mogućnosti i ukazuje da zadruga P_2 ima najefikasniju proizvodnju ($\theta^* = 1$) koja za ostale zadruge predstavlja mjerilo u traženju poboljšanja. Efikasnost ostalih zadruga u skupu mjeri se njihovim odstupanjem od granice efikasnosti. Pomoću formule (3.1.) može se izračunati relativna efikasnost za svaku zadrugu, a uspoređivanje njihovih indeksa efikasnosti s indeksom efikasnosti zadruge P_2 omogućuje rangiranje zadruga u promatranom skupu:

$$0 \leq \frac{Izlaz\ P_j / Ulaz\ P_j}{Izlaz\ P_2 / Ulaz\ P_2} \leq 1 \qquad (3.2.)$$

Iz nejednadžbe (3.2.) se dobiva sljedeći poredak zadruga (u odnosu na zadrugu P_2):

$$1 = \mathbf{P_2} = 0{,}8 > \mathbf{P_1} = 0{,}75 > \mathbf{P_6} = 0{,}667 > \mathbf{P_3} = 0{,}625 > \mathbf{P_5} = 0{,}5 > \mathbf{P_4} = 0{,}4$$

Zadruga P_3 ostvaruje 62,5% razine efikasnosti koju postiže zadruga P_2.[93] Zadruga P_3 može ostvariti tehničku efikasnost ako smanji potrošnju resursa i zadrži postojeću razinu proizvodnje (projekcija u točku P_3'), ili ako poveća razinu proizvodnje uz postojeću potrošnju resursa (projekcija u točku P_2). Bilo koja točka na *odsječku a* predstavlja idealnu priliku za poboljšanje efikasnosti zadruge P_3, uz pretpostavku, da ne smije povećati potrošnju resursa odnosno da ne smije smanjiti razinu proizvodnje. Na isti način ostale zadruge u skupu mogu ostvariti tehničku efikasnost (P_1, P_4, P_5, P_6).

U CCR modelu s jednim ulazom i dva izlaza (desna strana) granica efikasnosti je krivulja koja povezuje zadruge P_1, P_2, P_3 i P_4. Za razliku od prethodnog modela niti jedna zadruga na granici efikasnosti ne može poboljšati jednu od svojih proizvodnji bez negativnog utjecaja na drugu proizvodnju.[94] Zadruge P_5 i P_6 su identificirane kao neefikasne, a prostor u kojem se nalaze i koji je omeđen granicom efikasnosti nazivamo skupom proizvodnih mogućnosti (engl. *production possibility set*). Neefikasne zadruge mogu postići tehničku efikasnost projekcijama na granicu proizvodnih mogućnosti (P_5' i P_6'). Točka P_5' je konveksna kombinacija zadruga P_1 i P_2 koje predstavljaju referentnu skupinu (engl. *reference set*) i poželjnu razinu proizvodnje za zadrugu P_5. Daljnjim kretanjem po krivulji zadruga P_5 može postići jednu od dvije poželjne razine efikasnosti. Pri tome zadruga P_5 mijenja proporcije svojih proizvodnji uz istodobno zadržavanje iste razine potrošnje resursa (*odsječak b* i *odsječak c*).

Relativna efikasnost zadruge P5 računa se iz omjera OP5/OP5' = 0,75 odnosno zadruge P6 iz omjera OP6/OP6' = 0,8.[95] Dobivene vrijednosti ukazuju na prisutnost neefikasnosti u obje vrste proizvodnje. Budući da je funkcija cilja CCR modela usmjerena prema povećanju

---

[93] Prikaz efikasnosti kao odnosa izlaza i ulaza omogućuje korištenje različitih mjernih jedinica bez utjecaja na ocjenjivanje i odabir relativno efikasnih DMU. Ovo svojstvo se naziva *invarijantnost mjerenja* (engl. *unit invariance*) i predstavlja važnu komponentu u području inženjeringa i znanosti.

[94] Navedena tvrdnja vrijedi kod izlazno usmjerenih modela. Kod modela koji su usmjereni minimiziranju ulaza vrijedi da povećanje potrošnje prvog ulaza rezultira smanjenjem potrošnje ostalih ulaza. Orijentacija funkcije cilja kod AOMP modela objašnjena je u potpoglavlju 3.5.7. (str. 76).

[95] Omjer je radijalna mjera i predstavlja odnos dviju mjera udaljenosti. Odabir mjera udaljenosti nije jedinstven, a u našem slučaju koristi se mjera euklidske udaljenosti. Budući da se omjer formira u obliku odnosa udaljenosti između ishodišta koordinatnog sustava i mogućih proizvodnji vrijednosti se kreću u rasponu od 0 do 1.

izlaza lakše je interpretirati recipročne vrijednosti omjera OP_5'/OP_5 = 1,33 i omjera OP_6/OP_6' = 1,25. Iz toga slijedi da zadruga P_5 treba povećati proizvodnju oba izlaza za 33%, a zadruga P_6 za 25% ako žele postići tehničku efikasnost. Drugim riječima, udio njihovih dviju proizvodnji mora ostati nepromijenjen u ukupnoj proizvodnji zadruge.

Sve gore navedeno odnosi se na mjeru *tehničke efikasnosti* (engl. *technical efficiency*) koja se postiže projekcijom na granicu efikasnosti bez promjena proporcija ostvarenih izlaza. Druga vrsta efikasnosti javlja se u situacijama kada se samo za pojedine ulaze ili izlaze utvrdi neefikasno ponašanje. Ovu mjeru zovemo *mješovita efikasnost* i javlja se u AOMP modelima s više ulaza ili više izlaza. Uklanjanje ove mjere neefikasnosti rezultira mijenjanjem proporcija pojedinih ulaza u proizvodnji ili mijenjanjem proporcija pojedinih proizvodnji u ukupnoj proizvodnji (engl. *output* i *input mix inefficiency*).

Navedene mjere (ne)efikasnosti mogu se objasniti na primjeru zadruge P_6 u desnom grafu na gornjoj slici 3.1. Zadruga postiže tehničku efikasnost projekcijom na granicu efikasnosti (P_6'). Projekcija zadruge na granicu efikasnosti rezultira povećavanjem razina njenih dviju proizvodnji, a da istodobno ne dolazi do promjena njihovih proporcija u ukupnoj proizvodnji zadruge.[96] Međutim, poboljšanje tehničke efikasnosti ne uklanja sve nedostatke u proizvodnji zadruge koja se ne nalazi na efikasnom dijelu granice efikasnosti. Usporedba točaka P_6' i P_4 ukazuje na manjkavosti u proizvodnji drugog izlaza. Povećanjem razine proizvodnje drugog izlaza, uz zadržavanje iste razine proizvodnje prvog izlaza i uz isti utrošak ulaza, zadruga uklanja posljednje nedostatke mješovite neefikasnosti (*segment d*).

Mjere tehničke i mješovite neefikasnosti odnose se na fizičke aspekte proizvodnje poput neadekvatnog korištenja radne snage ili sirovina. Mjere ukazuju na suštinske nedostatke i mogu se opravdano ukloniti bez potrebe uvođenja novih podataka poput cijena i troškova pojedinih proizvodnji. Ostale mjere neefikasnosti koje povezujemo s kretanjima po granici efikasnosti su objašnjena u potpoglavlju 3.5.8. (str. 78). Takva kretanja se promatraju u cilju postizanja efikasne ekonomije razmjera, te poboljšanja u rukovođenju troškovima ili dobiti.

3.5.3. Model s nepromjenjivim stopama povrata (CCR model)

Osnovna ideja Cooper, Charnes i Rhodesovog modela je pomoću deriviranih pondera ulaznih (u_r) (r = 1, ..., s) i izlaznih podataka (v_i) (i = 1, ..., m) izračunati virtualne vrijednosti

[96] To potvrđuju vrijednosti omjera koordinata točke P_6 (4/0,5 = 8) i njene projekcije P_6' (5,5/0,6875 = 8,0).

outputa i inputa za svaku jedinicu odlučivanja (DMU$_o$) ($o \in \{j = 1, \dots, n\}$).[97] Promjenjive vrijednosti pondera ulazno-izlaznih podataka dobivaju se rješavanjem sljedećeg problema razlomljenog programiranja (Cooper i sur., 2007: 23):

$$(FP_o) \qquad \max \theta = \frac{u_1 y_{1o} + u_2 y_{2o} + \cdots + u_s y_{so}}{v_1 x_{1o} + v_2 x_{2o} + \cdots + v_m x_{mo}} \tag{3.3.}$$

uz uvjete ograničenja

$$\frac{u_1 y_{1j} + \cdots + u_s y_{sj}}{v_1 x_{1j} + \cdots + v_m x_{mj}} \leq 1 \qquad j = 1, \dots, n; \tag{3.4.}$$

$$v_1, v_2, \dots, v_m \geq 0; \tag{3.5.}$$

$$u_1, u_2, \dots, u_s \geq 0. \tag{3.6.}$$

U razlomljenom programu (3.3.) efikasnost je definirana kao: „*omjer ponderiranih outputa i inputa čija maksimalna vrijednost za svaku jedinicu odlučivanja mora biti manja ili jednaka broju jedan*“ (Charnes i sur., 1978: 430). Proširenu nelinearnu formulaciju moguće je korištenjem Charnes-Cooperove transformacije u obliku multiplikatora zamijeniti sljedećim ekvivalentnim linearnim programom:[98]

$$(LP_o) \qquad \max \theta = \mu_1 y_{1o} + \cdots + \mu_s y_{so} \tag{3.7.}$$

uz uvjete ograničenja

[97] Za svaku DMU računaju se najpogodniji ponderi koji pogoduju maksimiziranju omjera inputa i outputa, uz uvjet da vrijednosti ne smiju biti negativne (ograničenja 3.5. i 3.6.) i veće od 1 (3.4.). Ponderi se mogu unaprijed odrediti (nepromjenjivi) ili derivirati izravno iz podataka (promjenjivi) što rezultira izbjegavanjem pretpostavki i izračuna koji su uobičajeni za nepromjenjive pondere (Cooper i sur., 2007: 13).

[98] Transformacija se provodi normaliziranjem brojnika ili nazivnika ograničenja razlomljenog programa (3.4.) pod pretpostavkom da su ponderi inputa ili outputa različiti od nule (engl. *nonzero assumption*), a vrijednosti inputa ili outputa pozitivni brojevi. Ako obje strane ograničenja dijelimo s nazivnikom zbroj pondera inputa postaje ograničenje linearne funkcije koja iznosi jedan, dok funkcija cilja maksimizira vrijednosti pondera outputa (izlazno usmjeren model). Normalizacija brojnika podrazumijeva ograničenja zbroja pondera outputa na vrijednost jedan i minimiziranje pondera inputa u funkciji cilja linearnog modela (ulazno usmjeren model). Obzirom na način formulacije, optimalne vrijednosti izlazno usmjerenih modela recipročne su optimalnim vrijednostima ulazno usmjerenih modela.

$$v_1 x_{1o} + \cdots + v_m x_{mo} = 1; \tag{3.8.}$$

$$\mu_1 y_{1j} + \cdots + \mu_s y_{sj} \leq v_1 x_{1j} + \cdots + v_m x_{mj} \qquad j = 1, \dots, n; \tag{3.9.}$$

$$v_1, v_2, \dots, v_m \geq 0; \tag{3.10.}$$

$$\mu_1, \mu_2, \dots, \mu_s \geq 0. \tag{3.11.}$$

Postupak transformacije je reverzibilnog karaktera pod navedenim pretpostavkama zbog čega su optimalna rješenja i rezultati LP_o funkcije jednaki optimalnim vrijednostima FP_o funkcije ($u = \mu^*$, $v = v^*$ i $\theta = \theta^*$). Optimalne vrijednosti postavljenih problema programiranja (3.1.) i (3.7.) neovisni su o mjernim jedinicama i omogućuju usporedbu mjera efikasnosti kada se u proizvodnji sličnih outputa koriste slični inputi (teorem nepromjenjivosti jedinica). Navedena FP_o (3.4.-3.6.) i LP_o (3.8.-3.11.) ograničenja osiguravaju da vrijednosti omjera virtualnih outputa i inputa ne budu veće od jedan što predstavlja gornju granicu i optimalnu vrijednost linearne funkcije cilja θ^*. Optimalna rješenja linearnog programiranja su θ^*, v^*, u^*, gdje v_i i u_r predstavljaju vektore pondera koji maksimaliziraju omjere ulaznih i izlaznih podataka DMU_o koje procjenjujemo.[99] Jedinice odlučivanja su učinkovite ukoliko je $\theta^* = 1$ i postoji barem jedan optimalan ponder koji ostvaruje pozitivne vrijednosti ($v^* > 0$ i $\mu^* > 0$).[100] U protivnom, kažemo da su DMU_o neučinkovite ako je $\theta^* < 1$, ili $\theta^* = 1$ i postoji barem jedan ponder čija je vrijednost jednaka nuli za svako optimalno rješenje LP_o ($v^* = 0$ ili $\mu^* = 0$).

Nakon određivanja pripadajućih pondera i relativne efikasnosti, slijedi druga faza u kojoj se određuje referentni skup relativno efikasnih jedinica odlučivanja.[101] Izračunavanjem CCR projekcije dobiva se količina inputa i outputa koje je potrebno smanjiti/povećati ukoliko neefikasna jedinica odlučivanja želi doći na izokvantu granice efikasnosti. U slučajevima kada je DMUo CCR-neefikasna ($\theta^* < 1$) postoji barem jedna DMU čiji optimalni ponderi (v^*, μ^*) dovode u ravnotežu lijevu i desnu stranu ograničenja (3.9.), a u protivnom dolazi do

[99] Vrijednosti pondera v_i^* i u_r^* ne pokazuju samo mjeru relativnog doprinosa za svaku jedinicu inputa *i* i outputa *r* u procjeni DMU_o, nego i u kojoj mjeri doprinose ukupnoj vrijednosti θ^* (Cooper i sur., 2007: 25).

[100] Ako žele zadržati efikasnu razinu proizvodnje DMU ne mogu smanjiti niti jedan input, a da pri tome ne povećaju unos preostalih inputa, odnosno takve DMU ne mogu povećati razinu jednog outputa, a da pritom ne povećaju unos inputa ili smanje razinu proizvodnje ostalih izlaznih podataka.

[101] Referentni skup predstavlja skupinu efikasnih DMU kojima se dodjeljuju neefikasne DMU koje bi ovisno o korištenom modelu trebale mijenjati razmjere inputa ili outputa po primjeru DMU.

povećanja optimalne vrijednosti funkcije cilja θ^*. Skupinu ograničenja u ravnotežni možemo matematički prikazati na sljedeći način ($j \in \{1, \dots, n\}$):

$$E'_o = \left\{ DMU_j : \sum_{r=1}^{s} u_r^* y_{rj} = \sum_{i=1}^{m} v_i^* x_{ij} \right\} \tag{3.12.}$$

Navedeni skup CCR-efikasnih DMU nazivamo referentnom skupinom (engl. *reference set*) ili skupinom ravnopravnih sudionika (engl. *peer group*). Njegovo postojanje podrazumijeva i postojanje neučinkovitih DMU$_o$ koje definiraju referentni podskup (E_o), a izokvantu krivulje koja ih obavija nazivamo granicom efikasnosti. Prije konačne analize rezultata referentnog podskupa E_o potrebno je pronaći dualni model linearne funkcije (3.7.) koji zbog manjeg broja ograničenja pojednostavljuje rješavanje linearnih problema, a uvođenje dopunskih varijabli omogućuje lociranje izvora neefikasnosti i pronalazak novih optimalnih rješenja u slučaju promjene parametara modela (Taha, 2006: 156; Cooper i sur., 2007: 52).

3.5.4. Dualni model linearne funkcije koja minimizira ulazne podatke

Prema teoremu dualnosti svaki linearni model ima svoju dualnu alternativu problema koju obilježava ista razina efikasnosti i optimalna vrijednost funkcije cilja kao i njenu prvobitnu formulaciju.[102] Dualnu formulaciju linearnog modela koji minimizira ulazne podatke možemo matematički prikazati (Cooper i sur., 2007: 43-46):[103]

$$(DLP_o) \qquad \min \theta \tag{3.13.}$$

[102] Dva su linearna problema toliko usko povezana da optimalno rješenje osnovnog problema automatski pruža optimalno rješenje drugom. Kada vrijednosti funkcije cilja osnovnog i dualnog modela nisu jednake kažemo da DMU nema stabilnu (optimalnu) razinu proizvodnje. Kod definiranja dualnih formulacija dolazi do promjena smjera optimizacije, vrsti ograničenja i orijentacije varijabli po standardnim pravilima (Taha, 2006: 151-155). Modeli se razlikuju po broju ograničenja koja u osnovnom modelu određuje broj DMU, a u dualnom modelu broj inputa i outputa. Dualna formulacija je računalno preciznija jer izračunavanje relativne efikasnosti više ovisi o broju ograničenja, a manje o broju varijabli (Ramanathan, 2003: 51).

[103] Vrijedi i obrnuto, rješenje dualne formulacije izvedene iz modela koji minimizira ulazne podatke nazivamo izlazno orijentirani program. Važno je napomenuti da nastavak primjene teorema dualnosti na dualnoj formulaciji programa (3.13.) ponovno dovodi do formuliranja prvobitnog modela (3.3.).

uz uvjete ograničenja

$$\theta x_o - X\lambda \geq 0; \tag{3.14.}$$

$$Y\lambda \geq y_{o;} \tag{3.15.}$$

$$\lambda \geq 0. \tag{3.16.}$$

Za razliku od osnovnog modela koji u izračunavanje efikasnosti uključuje vektore pondera inputa i outputa (engl. *multiplier form*), njegova dualna formulacija u tu svrhu koristi vektore pondera jedinica odlučivanja (engl. *envelopment form*). Postavljena ograničenja osiguravaju da u slučajevima kada je optimalna vrijednost funkcije cilja manja od 1 ($\theta^* < 1$) vrijednosti dualnih varijabli ($X\lambda$, $Y\lambda$) nadmašuju vrijednosti inputa i outputa (θx_o, y_o). Oduzimanjem njihovih vrijednosti definiraju se dopunske varijable (engl. *slack*) koje opisuju viškove inputa ($s^- \in R^m$) i nedostatke outputa ($s^+ \in R^s$), a čije vektore prikazujemo kao:[104]

$$s^- = \theta x_o - X\lambda \qquad \text{i} \qquad s^+ = Y\lambda - y_o \tag{3.17.}$$

Za lociranje viškova ulaznih (s^{-*}) i nedostataka izlaznih podataka (s^{+*}) potrebno je u prvom koraku minimalizirati vrijednost funkcije cilja (θ) dualnog linearnog modela (3.13.), a zatim u drugom koraku pronaći maksimalnu vrijednost zbroja između dopunskih varijabli s^{-*} i s^{+*}. Postupak se provodi uz pretpostavku da funkcija cilja u prvom koraku ostvaruje optimalnu vrijednost ($\theta = \theta^*$). Njihov zbroj predstavlja optimalno rješenje drugog koraka (engl. *max-slack solution*), a kada je zbroj jednak nuli kažemo da jedinice odlučivanja učinkovito koriste sve raspoložive inpute ($s^{-*} = 0$) i pritom ne ostvaruje manjak proizvodnje ($s^{+*} = 0$) (engl. *zero-slack activity*).

Međutim, potpuna interpretacija razina intenziteta efikasnosti ovisi o rezultatima prvog i drugog koraka dualnog programiranja. Za jedinicu odlučivanja kažemo da je CCR-efikasna ako istodobno ne bilježi višak inputa ili manjak outputa ($s^{-*} = 0$, $s^{+*} = 0$), a njena funkcija cilja ostvaruje optimalnu vrijednost ($\theta^* = 1$).[105] U protivnom govorimo o CCR-neefikasnosti

[104] Dopunske varijable koriste se za pretvaranje nejednadžbi ograničenja u odgovarajuće jednadžbe i njihove vrijednosti ne smiju biti negativne za svako izvedivo rješenje u skupu proizvodnih mogućnosti ($s^- \geq 0$ i $s^+ \geq 0$). Pri čemu pozitivne vrijednosti podrazumijevaju višak inputa ili manjak outputa (engl. *nonzero*), a vrijednosti nula tehničku efikasnost poslovanja.

[105] U literaturi se ova mjera potpune efikasnosti često naziva *jaka* ili *Pareto-Koopmansova efikasnost* (engl. *strong* ili *Pareto-Koopmans efficiency*) i podrazumijeva situacije u kojima nije moguće povećati efikasnost korištenja inputa ili outputa bez smanjenja efikasnosti korištenja drugih inputa ili outputa.

jedinica odlučivanja i razlikujemo dvije vrste. Slabija *tehnička* ili *radijalna efikasnost* (engl. *technical* ili *radial efficiency*) opisuje situaciju kada funkcija cilja ne postiže optimalnu vrijednost ($\theta^* < 1$) unatoč tome što jedinice odlučivanja ne bilježe višak inputa ili manjak outputa. U takvim situacijama moguće je istodobno smanjiti unos svih inputa bez promjene njihovih udjela do određene razine ($1 - \theta^*$) koja predstavlja donju granicu u postavljenom skupu proizvodnih mogućnosti. Sva naredna smanjenja povezana s pozitivnim vrijednostima dopunskih varijabli dovode do promjene udjela inputa. Drugi stupanj neefikasnosti koji je povezan s optimalnom vrijednosti funkcije cilja ($\theta^* = 1$) i dopunskim varijablama čije se vrijednosti razlikuju od nula nazivamo *neefikasnost razmjera* (engl. *mix inefficiencies*).[106]

Rješavanjem dualnih modela i uvođenjem dopunskih varijabli moguće je pristupiti konačnoj analizi referentnog skupa neefikasnih jedinica odlučivanja (E_o) koji je definiran na temelju rezultata prvog i drugog koraka dualnog programiranja (Cooper i sur., 2007: 47):

$$E_o = \{DMU_j \mid \lambda_j^* > 0\} \; (j \in \{1, \dots, n\}) \tag{3.18.}$$

Pri čemu optimalna rješenja izražavamo kao:

$$\theta^* x_o = \sum_{j \in E_o} x_j \lambda_j^* + s^{-*}; \tag{3.19.}$$

$$y_o = \sum_{j \in E_o} y_j \lambda_j^* - s^{+*} \tag{3.20.}$$

Navedeni odnosi pokazuju da razina efikasnosti (x_o, y_o) DMU$_o$ može biti povećana ukoliko se vrijednosti njihovih inputa proporcionalno umanje za vrijednost omjera θ^* i uklone viškovi ulaznih podataka (s^{-*}), ili s druge strane, ukoliko vrijednostima izlaznih podataka pridodamo

[106] Ova se razina efikasnosti u literaturi još naziva *slaba* ili *Farrellova efikasnost* (1957) koji je uvođenjem bodova na beskonačnost (engl. *points at infinity*) pokušao implementirati Pareto-Koopmansovu definiciju optimalnih rješenja u svoj koncept, ali ga nije uspio postaviti u izvedivom obliku. Njegov pristup zanemaruje prisutnost *slack varijabli* i ne koristi *teorem dualiteta* koji pruža pristup simplex i drugim metodama za efikasno povezivanje takvih problema (Cooper i sur., 2004: 10).

vrijednosti manjkavosti proizvodnje (s^{+*}). Poboljšanja ($\hat{x}_o, \hat{y}_o$) su u skladu s interpretacijom rezultata dualnog programiranja i njihovi odnosi mogu se prikazati CCR-projekcijom:[107]

$$\hat{x}_o = x_o - \Delta x_o = \theta^* x_o - s^{-*} \leq x_o \tag{3.21.}$$

$$\hat{y}_o = y_o + \Delta y_o = y_o + s^{+*} \geq y_o \tag{3.22.}$$

3.5.5. Dualni model linearne funkcije koja maksimizira ulazne podatke

Sve do sada navedeno odnosi se uglavnom na dualne modele čiji je cilj minimiziranje ulaznih podataka uz istodobno zadržavanje unaprijed zadane razine proizvodnje izlaznih podataka. Interpretacija mogućih viškova inputa i manjkova outputa kod dualnih modela čija je funkcija cilja usmjerena maksimalizaciji outputa provodi se na isti način kao i kod ulazno usmjerenih modela (3.13.). Međutim, razlike ipak postoje i proizlaze iz načina formulacije zbog čega su optimalne vrijednosti njihovih funkcija cilja međusobno recipročne vrijednosti ($\eta^* = 1/\theta^*$).[108] Njihove poveznice vidljive su kada govorimo o optimalnim vrijednostima dopunskih varijabli čiji se međuodnosi mogu matematički prikazati kao: $t^{-*} = s^{-*}/\theta^*$ i $t^{-*} = s^{+*}/\theta^*$. Iz toga možemo zaključiti da je izlazno usmjereni model efikasan za bilo koju DMU, ako i samo ako, je njena procjena poslovanja efikasna i po rezultatima ulazno usmjerenog modela. Moguća poboljšanja ($\hat{x}_o, \hat{y}_o$) DMU$_o$ u izlazno usmjerenim modelima izražavamo:

$$\hat{x}_o \Leftarrow x_o - t^{-*} \qquad \text{i} \qquad \hat{y}_o \Leftarrow \eta^* y_o + t^{-*} \tag{3.23.}$$

3.5.6. Model s promjenjivim stopama povrata (BCC model)

Od samog početka razvoja AOMP predložena su razna proširenja CCR modela među kojima je svakako najznačajniji Banker, Charnes, Cooperov model (1984). Njegov značaj je vidljiv u proširenju koncepta stopi povrata (engl. *return to scale*) koji je u literaturi klasične ekonomije do tada uobičajeno bio proučavan samo u slučajevima s jednim outputom.[109]

---

[107] Charnes i sur. (1978) koriste „*formulu CCR projekcije*“ za procjenu DMU_o kako bi dokazali da $\hat{x}_o \leq x_o$ i $\hat{y}_o \geq y_o$ odgovaraju koordinatama točaka na granici efikasnosti.

[108] Optimalna vrijednost funkcije cilja izlazno usmjerenih modela opisuje stopu povećanja outputa (η^*), dok optimalna vrijednost funkcije cilja ulazno usmjerenih modela izražava stopu smanjenja inputa (θ^*). Drugim riječima, svako dodatno smanjenje ulaznih podataka (θ^*) dovodi do sve manjeg rasta proizvodnje (η^*) odnosno svako smanjenje inputa dovodi do manje efikasnosti DMU.

[109] Neka α predstavlja proporcionalno povećanje inputa, a β rezultat proporcionalnog povećanja jednog outputa. Stope povrata se povećavaju kada proporcionalno povećanje svih inputa rezultira

Cooper i sur. (2004) navode da BCC model pruža uvid u suštinu koncepta ekonomije obujma i mogućnost proučavanja djelovanja menadžmenta u uvjetima različitih stopa povrata pomoću AOMP. Zbog toga se još naziva *modelom promjenjivih (varijabilnih) stopa povrata*. Za razliku od CCR modela čija je granica efikasnosti linearni pravac, kod BCC modela granicu efikasnosti opisuju djelomično linearna i konkavna obilježja koja proizlaze iz osnovne pretpostavke o varijabilnim stopama povrata na razmjer proizvodnje (vidi sliku 3.2.). Upravo iz tog razloga, ulazni i izlazni BCC modeli koriste različite projekcije i daju različite rezultate u kontekstu stopi povrata.

Osnovna razlika između CCR i BCC modela leži u uvjetu $\sum_{j=1}^{n} \lambda_j = 1$ koji zajedno s izrazom $\lambda_j \geq 0,\ \forall j$ nameće stanje konveksnosti u ograničenjima BCC modela.[110] Ulazno usmjereni BCC model procjenjuje efikasnost jedinica odlučivanja rješavanjem osnovnog linearnog programa (Cooper i sur., 2007: 91):

$$(BCC_o) \qquad \min \theta_{BCC} \tag{3.24.}$$

uz uvjete ograničenja

$$\theta_{BCC} x_o - X\lambda \geq 0 \tag{3.25.}$$

$$Y\lambda \geq y_o \tag{3.26.}$$

$$e\lambda = 1 \tag{3.27.}$$

$$\lambda \geq 0 \tag{3.28.}$$

Njegovu dualnu formulaciju ($DBCC_o$) možemo prikazati:

$$(DBCC_o) \qquad \max z = uy_o - u_o \tag{3.29.}$$

uz uvjete ograničenja

---

više nego proporcionalnim povećanjem jednog outputa ($\beta > \alpha$), a smanjuju se kada proporcionalno povećanje svih inputa rezultira manjim od proporcionalnog povećanja jednog outputa ($\beta < \alpha$).

[110] U ulazno usmjerenim BCC modelima navedeni uvjet $\sum_{j=1}^{n} \lambda_j = 1$ može se još zapisati kao $e\lambda = 1$, pri čemu *e* označava vektor redaka čiji elementi postižu vrijednost jedan, a λ vektor stupaca čije vrijednosti elemenata nisu negativne. Isto vrijedi i kod izlazno usmjerenih BCC modela s dodatnim ograničenjem $\sum_{j=1}^{n} \mu_j = 1$.

$$vx_o = 1 \tag{3.30.}$$

$$-vX + uY - u_o e \leq 0 \tag{3.31.}$$

$$v \geq 0, u \geq 0, \qquad u_o \text{ nema ograničenja} \tag{3.32.}$$

Posljedica dodatnog ograničenja $e\lambda = 1$ vidljiva je u prisutnosti slobodne skalarne varijable u_o (v_o u izlazno usmjerenom modelu) koja je neodređenog predznaka i može poprimiti bilo koju numeričku vrijednost unutar dualnog BCC modela (engl. *free in sign*). Njena prisutnost omogućuje procjenu učinaka promjenjivih stopa povrata na volumen poslovanja.[111]

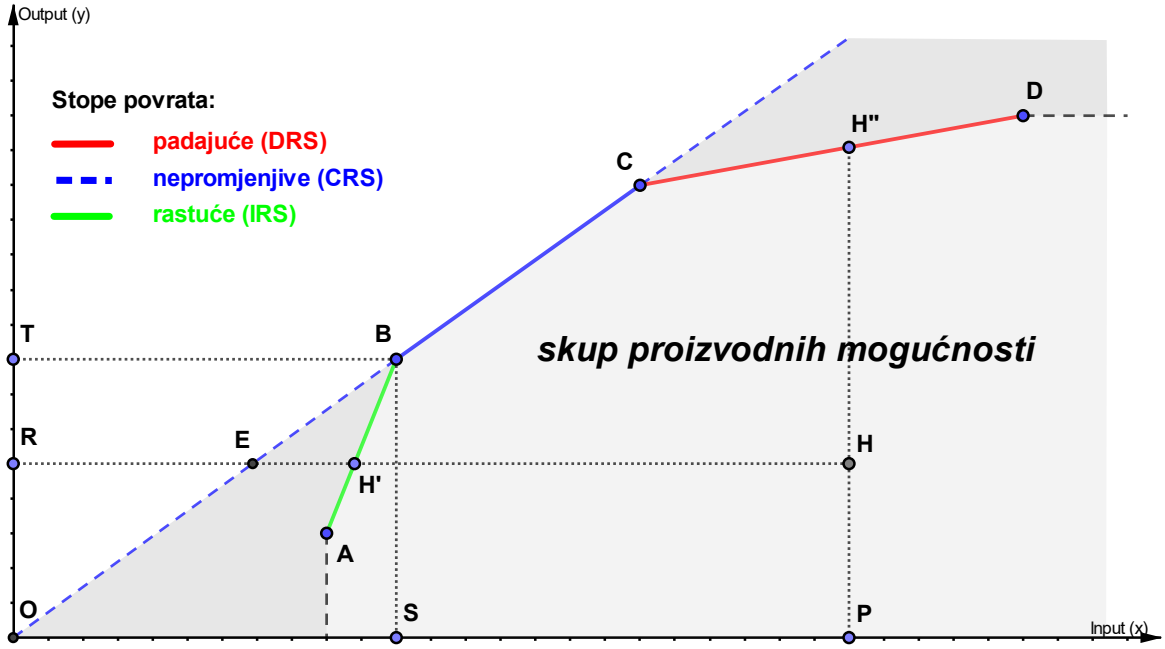

Slika 3.2. Granice efikasnosti i skupovi proizvodnih mogućnosti CCR i BCC modela.

Optimalne vrijednosti funkcije cilja BCC modela (θ^*_{BCC}) veće su od optimalnih vrijednosti funkcije cilja CCR modela (θ^*_{CCR}) čiji skup proizvodnih mogućnosti sadrži podskup izvedivih mogućnosti BCC modela (slika 3.2.).[112] Zbog toga su neefikasne jedinice odlučivanja u BCC

[111] Optimalne vrijednosti slobodnih varijabli (u_o^* i v_o^*) koriste se u prepoznavanju stopi povrata. Ukoliko sve u_o^* u točkama poboljšanja ($\hat{x}_o$, $\hat{y}_o$) postižu negativne vrijednosti govorimo o rastućim ($u_o^* < 0$), a u protivnom o padajućim stopama povrata ($u_o^* > 0$). Konstantne stope povrata prevladavaju u situacijama kada je u točkama poboljšanja barem jedna optimalna vrijednost $u_o^* = 0$ (Cooper i sur., 2004: 46).

[112] U ulazno usmjerenim modelima možemo procijeniti BCC-efikasnost DMU_H na temelju omjera segmenata RH'/RH, dok se njegova CCR-efikasnost dobiva iz omjera RE/RH i u pravilu postiže

modelu bliže granici efikasnosti i lakše ostvaruju poboljšanja u odnosu na neefikasne jedinice u CCR modelu bez obzira na odabrano usmjerenje modela. Navedeno ne vrijedi za DMU koje se nalaze na granici efikasnosti između točaka B i C gdje je $\theta^*_{BCC} = \theta^*_{CCR}$.

Linijski segment između točaka B i C, Banker (1984) smatra područjem s najproduktivnijim stopama povrata (engl. *most productive scale size-MPSS*).[113] Pri čemu srednju produktivnost mjeri nagibom linije OC koji je veći od nagiba bilo koje druge linije koja polazi od ishodišta koordinatnog sustava i siječe skup proizvodnih mogućnosti. Unatoč istim ograničenjima, ulazno i izlazno usmjereni BCC modeli koriste drugačije projekcije na granicu efikasnosti što rezultira različitim stopama povrata na razmjer poslovanja. U ulazno usmjerenim modelima projekcija neefikasne DMU_0 (točka H) na linijski segment AB (točka H') rezultira poboljšanjem efikasnosti uz povećanje stopi povrata, dok u izlazno usmjerenim modelima njena projekcija na linijski segment CD (točka H'') dovodi do postizanja efikasnosti ali uz smanjenje stopi povrata. Za više informacija o usmjerenosti AOMP modela i orijentaciji funkcije cilja vidi poglavlje 3.5.7. (str. 76).

Unatoč postojanju tehničkih razlika između dva AOMP modela postupak definiranja referentnih skupina (E_o), tumačenje rezultata slack varijabli (s^{-*} i s^{+*}) i mogućih poboljšanja ($\hat{x}_o$,$\hat{y}_o$) provodi se na isti način kao kod CCR modela (vidi Cooper i sur., 2007: 91-94).

3.5.7. Usmjerenost ili orijentacija AOMP modela

Definiranje orijentacije funkcije cilja ima važnu ulogu u utvrđivanju iskoristivosti kapaciteta i mogućnosti poboljšanja tehničke efikasnosti. Modeli u AOMP mogu biti *izlazno usmjereni* (engl. *output oriented*) ili *ulazno usmjereni* (engl. *input oriented*). Ulazno usmjereni modeli imaju za cilj minimizirati upotrebu ulaza uz zadržavanje iste razine izlaza. U takvim uvjetima DMU je relativno neefikasna ako može zadržati istu razinu proizvodnje unatoč smanjenju potrošnje jednog inputa i da istodobno ne povećava potrošnju preostalih inputa. Neefikasna jedinica postaje efikasna ako smanjenje potrošnje ulaza ne mijenja izlaze. Izlazno usmjereni

manje vrijednosti. U izlazno usmjerenim modelima koriste se vrijednosti na y-osi u određivanju BCC-efikasnosti DMU_H iz omjera PH''/PH, dok se njegova CCR-efikasnost izračunava kao recipročna vrijednost neefikasnosti u ulazno usmjerenim CCR-modelima ($1/(RE/RH)$).

[113] U tom području DMU postižu maksimalnu srednju produktivnost uz određenu kombinaciju inputa i outputa i uz prisutnost nepromjenjivih stopa povrata. U takvim uvjetima možemo procijeniti neefikasnost točke H u odnosu na bilo koju DMU (npr. točka B) koja postiže MPSS ($h_H = (OR/RH)/(OT/TB)$) i razliku u veličinama njihovih stopa povrata $k = OR/OT$. Procjenjivanje srednje produktivnosti je korisno u ispitivanjima specifičnih obilježja proizvodnji koje se međusobno razlikuju u nekoliko segmenata (Banker, 1984: 41-43).

modeli imaju za cilj maksimizirati razinu izlaza s raspoloživim ulazima. U takvim uvjetima DMU je relativno neefikasna ako je moguće povećati razinu proizvodnje bilo kojeg izlaza bez povećanja potrošnje ulaza i smanjenja proizvodnje ostalih izlaza. Iz toga slijedi da neefikasna DMU postaje efikasna povećanjem svojih izlaza.

Na gornjoj slici 3.2., jasno se vidi da orijentacija funkcije cilja određuje smjer projekcije na izokvantu granice efikasnosti. U BCC modelima koji su usmjereni smanjenju potrošnje ulaza efikasnost se postiže vodoravnom projekcijom (točka H'), a u BCC modelima koji su usmjereni povećanju izlaza okomitom projekcijom na granicu efikasnosti (točka H'').

Za CCR modele postoji veza između optimalnih rješenja ulazno i izlazno usmjerenih modela. Kod CCR modela smjer granice efikasnosti ostaje nepromijenjen bez obzira na usmjerenost modela, samo je pravac projekcije različit. Na lijevoj strani slike 3.3. se nalazi ulazno usmjeren CCR model s dva ulaza, a na desnoj strani slike ulazno usmjeren CCR model s dva izlaza.

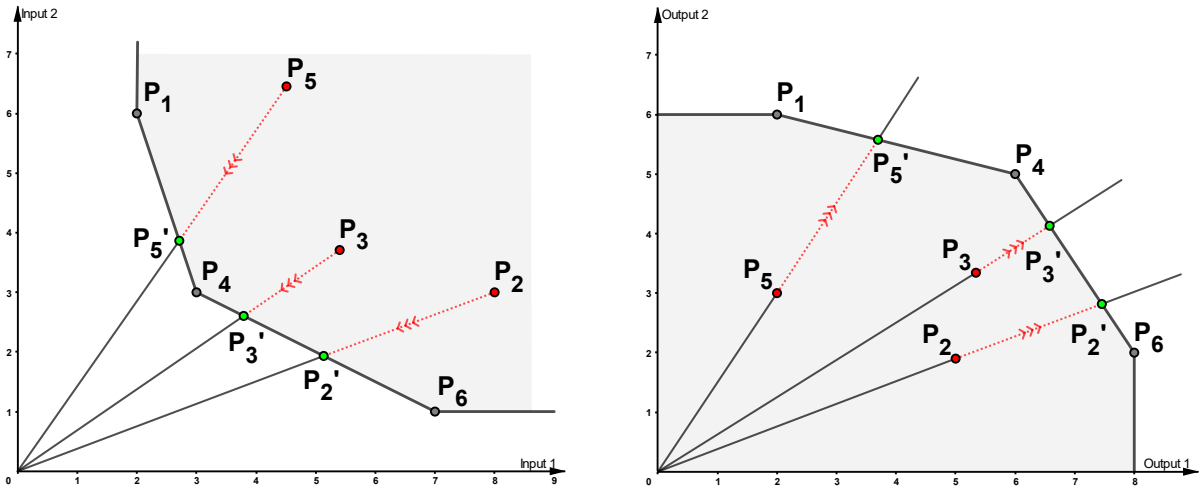

Slika 3.3. Granice efikasnosti u ulazno (lijevo) i izlazno usmjerenom CCR modelu (desno).

U ulazno usmjerenom CCR modelu granica efikasnosti je konveksna krivulja okrenuta prema ishodištu koordinatnog sustava. U cilju minimiziranja ulaza, projekcije neefikasnih DMU se kreću prema ishodištu koordinatnog sustava. U izlazno usmjerenom CCR modelu granica efikasnosti je konkavna krivulja, a povećanje izlaza postiže se projekcijom neefikasnih DMU u suprotnom smjeru od ishodišta koordinatnog sustava.

Pored ove dvije osnovne orijentacije postoji skupina modela koji nemaju striktno usmjerenu funkciju cilja i u literaturi se nazivaju *kombinirani* ili *neusmjereni modeli*. U ovu skupinu

pripadaju i modeli koji koriste ne radijalne mjere efikasnosti kao što su *aditivni modeli* ili *modeli koji se oslanjaju na slack varijable* (engl. *additive models* i *slacks-based models*). Kod ovakvih modela se razmatra mogućnost istodobnog povećanja izlaza i smanjenja ulaza u cilju postizanja efikasnosti. Međutim, kada je svrha istraživanja jedino postići efikasnost poslovanja tada ovakvi modeli, neovisno o orijentaciji funkcije cilja, daju iste rezultate u kontekstu tehničke i mješovite efikasnosti.

Modeli koji su teorijski objašnjeni u prethodnim poglavljima su konstruirani da minimiziraju ulazne podatke potrebne za proizvodnju tražene količine izlaza. U našem istraživanju su korišteni izlazno usmjereni CCR i BCC model.

3.5.8. Definiranje sličnosti i razlika između dva osnovna AOMP modela

Najčešće korišteni modeli za mjerenje relativne efikasnosti su CCR i BCC modeli koji su nazvani prema inicijalima imena autora. Modeli koriste radijalan pristup koji prilikom mjerenja efikasnosti zanemaruje ne proporcionalne varijable ulaznih i izlaznih podataka.[114] Razlika između dva modela je u temeljnoj pretpostavki o načinu transformacije ulazno-izlaznih čimbenika. Modeli se razlikuju u primjeni koncepta *nepromjenjivosti podataka* (engl. *translation invariance*).[115] Za razliku od CCR modela koji nema sposobnost mijenjanja ograničenja, BCC model ima djelomičnu sposobnost da promijeni izvorne podatke za određena ograničenja.

Upotreba optimalne funkcije cilja kao važne mjere efikasnosti koja ovisi o koordinatnom sustavu također predstavlja važno područje koja treba razmatrati kod odabira modela (Cooper i sur., 2007: 116). U tablici 3.3. su prikazani argumenti koje je potrebno uvažavati kod odabira osnovnih AOMP modela. Odabir modela predstavlja jedan od osnovnih problema koji treba razmotriti, uključujući i odabir više različitih AOMP modela i metoda, te usporedba rezultata i korištenje znanja stručnjaka kako bi se testirao možebitan utjecaj na rezultate istraživanja. Smith (1997) navodi smjernice za odabir i definiranje AOMP modela kako bi se uklonio nered koji stvaraju alternativne pojedinosti i različiti rezultati neprikladno

[114] U AOMP koriste se radijalne i ne radijalne vrste mjerenja koje se razlikuju u načinu prikazivanja obilježja ulaznih ili izlaznih podataka. Radijalne varijable podložne su proporcionalnim, a ne radijalne varijable ne proporcionalnim promjenama koje utječu na konačne rezultate u procjeni efikasnosti.

[115] Koncept nepromjenjivosti podataka se bavi lateralnim prilagodbama ograničenja kako bi se omogućilo postizanje uvjeta konveksnosti ili pretvaranje negativnih vrijednosti u pozitivne vrijednosti. Na taj način se omogućuje provođenje AOMP koja pretpostavlja da su izvorni podaci ne negativni (Cooper i sur., 2007: 89, 97). Novo dobiveni model koji nastaje pretvaranjem izvornih vrijednosti ulaznih ili izlaznih podataka ima ista (optimalna) rješenja kao njegov izvorni slučaj.

odabranih modela. Oslanjanje na rezultate jednog modela može biti rizično ukoliko u prethodnim istraživanjima nismo uspjeli prepoznati značajke granice proizvodnje.

Tablica 3.3. Sažeti prikaz obilježja CCR i BCC modela

	Model	CCR-input	CCR-output	BCC-input	BCC-output
Podaci	Inputi (x)	semi-pozitivni	semi-pozitivni	semi-pozitivni	bez ograničenja
	Outputi (y)	bez ograničenja	bez ograničenja	bez ograničenja	semi-pozitivni
Tumačenje nepromjenjivosti	Inputi (x)	NE	NE	NE	DA
	Outputi (y)	NE	NE	DA	NE
Neovisnost o mjernim jedinicama		DA	DA	DA	DA
Područje vrijednosti funkcije cilja		[0,1]	[0,1]	[0,1]	[0,1]
Tehnička ili mješovita neefikasnost		tehnička	tehnička	tehnička	tehnička
Stope povrata		CRS	CRS	VRS	VRS

Semi-pozitivni = vrijednosti nisu negativne i barem jedna vrijednost mora biti pozitivna za svaku DMU.
Bez ograničenja = vrijednosti podataka mogu biti bilo kojeg predznaka.
Izvor: Preuzeto iz Cooper i sur. (2007: 115).

Kod odabira je važno paziti na odnos između broja ulazno-izlaznih podataka i veličine uzorka. Kako bi se osigurala kvaliteta istraživanja i sposobnost razdvajanja modela predloženo je standardno pravilo o potrebnom broju DMU u uzorku obzirom na broj inputa i outputa. Minimalan broj DMU mora biti barem tri puta veći od zbroja inputa i outputa ($K > 3(m+n)$) ili veći od umnoška broja inputa i outputa u modelu ($K > m \times n$) (Jenkins i Anderson, 2003: 54; Sarkis, 2007: 306). Ako je veličina uzorka manja od ukupnog broja ulazno-izlaznih varijabli tada će zbog veće dimenzionalnosti rješenja i neadekvatnog broja stupnjeva slobode veliki udio uzorka bit identificiran kao učinkovit čime sposobnost razlučivosti modela postaje upitna.[116] Zbog toga se na početku svakog istraživanja preporuča odabir manjeg broja ulaznih i izlaznih podataka uz postepeno povećanje broja podataka za praćenje efikasnosti.

3.5.9. Oblik skupa proizvodnih mogućnosti i stope povrata

[116] U regulaciji troškova i potrošnje menadžment poduzeća najčešće je sklon odabiru modela s većim brojem inputa i outputa. Međutim treba biti oprezan jer veliki modeli mogu rezultirati iskrivljenim informacijama o (ne)efikasnosti poslovanja što posljedično dovodi do potpunog prekida ili smanjenja investicijskih ulaganja u održavanje proizvodnje, a u konačnom slučaju i do stečaja.

Kod odabira AOMP modela potrebno je razmotriti i oblik skupa proizvodnih mogućnosti koji ovisi o intenzitetu promjena stopa povrata. Odabir pretpostavke o promjenjivosti stopa povrata ovisi o kontekstu, dugoročnosti ili kratkoročnosti analize, prirodi podataka, veličini uzorka i povezanosti ulaznih podataka.[117] Zato je važno poznavati tržišna ograničenja s kojima se suočavaju poduzeća unutar sektora jer krivi odabir tehnoloških pretpostavki može dovesti do stvaranja većih modela koji daju optimističnije procjene, ili manjih modela čije procjene mogu zaustaviti nove investicije i dovesti vitalna poduzeća u stečaj. Zbog većih vrijednosti mjera efikasnosti i normi troškova, pretpostavka o promjenjivim stopama povrata ima prednost u financijskom poslovanju, a pretpostavka o nepromjenjivim stopama u reorganizaciji poslovanja i ispitivanjima mogućnosti spajanja ili razdvajanje poduzeća u cilju postizanja efikasnosti razmjera (Bogetoft i Otto, 2011: 90). Prema Smithu (1997) pretpostavka o promjenjivim stopama povrata rezultira precjenjivanjem efikasnosti u malim uzorcima i jednostavnim modelima gdje su ulazni podaci slabije povezani.

U procjenjivanju ukupne tehničke efikasnosti pod pretpostavkom nepromjenjivih stopa povrata razmjer poslovanja nije relevantan čimbenik CCR modela, dok DMU smještene na linearnoj granici efikasnosti u proizvodnji koriste iste omjere inputa i outputa bez obzira na volumen poslovanja. Njihova veličina poslovanja ne postiže ekonomiju ili disekonomiju razmjera zbog čega svaka promjena inputa dovodi do proporcionalne promjene outputa. Takav poželjan razmjer čimbenika rezultira najproduktivnijim stopama povrata gdje prihodi postiže maksimalne, a troškovi minimalne prosječne vrijednosti. Konačan rezultat CCR modela je *ukupna tehnička efikasnost* koja opisuje efikasnost korištenja inputa u maksimalnoj proizvodnji outputa (engl. *overall technical efficiency-OTE*).

Međutim, *pretpostavka o nepromjenjivim stopama povrata* se ne može koristiti u situacijama kada mjerimo efikasnost DMU koje ne posluju na optimalnoj razini ili koje odluče promijeniti razmjer poslovanja. Tada se koristi BCC model koji pod pretpostavkom promjenjivih stopa povrata omogućuje mjerenje promjena omjera outputa i inputa sukladno razini poslovanja. U slučaju ekonomije razmjera kada DMU posluju ispod optimalne razine model bilježi rastuće, a u slučaju disekonomije razmjera kada DMU posluju iznad optimalne razine padajuće stopa povrata.[118] To omogućuje razdvajanje *ukupne tehničke efikasnosti* na dvije

[117] Hollingsworth i Smith (2003) sugeriraju korištenje BCC modela u radu s relativnim podacima jer u takvim uvjetima CCR modeli proizvode tehnički netočne rezultate. Međutim, korištenje promjenjivih stopa povrata u BCC modelima je pogrešno jer podaci u obliku omjera pretpostavljaju nepromjenjive stope povrata.

[118] Kada DMU posluje ispod optimalne razine svaka promjena inputa rezultirati će iznad proporcionalnim povećanjem stopi povrata (engl. *increasing return to scale*). Vrijedi i obrnuto, kada je obujam poslovanja DMU iznad optimalne razine svaka promjena inputa rezultirati će ispod proporcionalnim smanjenjem stopi povrata (engl. *decreasing return to scale*).

komponente: *čistu tehničku efikasnost* (engl. *pure technical efficiency-PTE*) i *efikasnost razmjera* (engl. *scale efficiency-SE*). Stavljanjem u omjer ukupne tehničke CCR efikasnosti i čiste tehničke BCC efikasnosti računa se *efikasnost razmjera* koja pokazuje koliko su DMU udaljene od optimalne razine poslovanja.[119] Međutim, mjera ne pokazuje da li je razlog neefikasnosti razina poslovanja koja se nalazi ispod ili iznad svoje optimalne razine. Zato je potrebno izračunati tehničku efikasnost pod pretpostavkom padajućih stopi povrata i usporediti je s PTE_{BCC}.[120] Razdvajanje pruža uvid u izvore neefikasnosti i prednosti koje donosi optimalna razina proizvodnje (Kumar i Gulati, 2008: 35-36). Mjere i granice efikasnosti u uvjetima nepromjenjivih i promjenjivih stopa povrata su prikazane na slici 3.4.

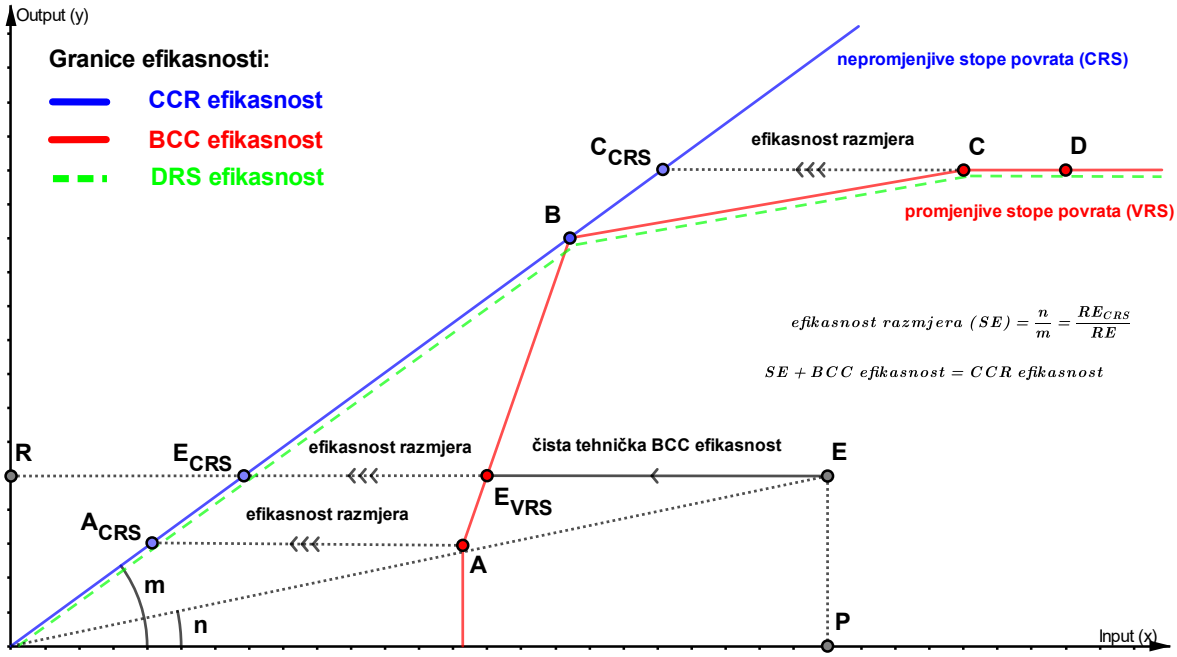

Slika 3.4. Mjere efikasnosti u uvjetima nepromjenjivih i promjenjivih stopa povrata.

Ovisno o pretpostavki u modelu, euklidska udaljenost između DMU i odgovarajućih granica učinkovitosti predstavlja mjeru *ukupne* i *čiste tehničke efikasnosti*. Rezultati efikasnosti pod

[119] Vrijednosti mjere *efikasnost razmjera* se kreću u rasponu od 0 do 1. Pri čemu 1 označava optimalnu razinu poslovanja gdje su mjere CCR i BCC efikasnosti jednake, a niže vrijednosti gubitke koje ostvaruju u odnosu na DMU s maksimalnom prosječnom proizvodnjom (Bogetoft i Otto, 2011: 99-101).

[120] Jedinica odlučivanja postiže ekonomiju razmjera i rastuće stope povrata ako vrijedi $E_{DRS} = E_{CRS}$. Kada je $E_{DRS} = E_{VRS}$, ali je $E_{DRS} \neq E_{CRS}$ kažemo da DMU postiže disekonomiju razmjera i padajuće stope povrata. U situacijama kada je $E_{DRS} = E_{VRS} = E_{CRS}$ jedinica odlučivanja posluje na optimalnoj razini s nepromjenjivim i najproduktivnijim stopama povrata (vidi sliku 3.4.).

pretpostavkom *promjenjivih stopa povrata* uvijek su veći ili jednaki rezultatima efikasnosti pod pretpostavkom *nepromjenjivih stopa povrata*. Na primjer, procjenjivanjem udaljenosti između neefikasne DMU_E i njene projekcije na granicu efikasnosti s promjenjivim stopama povrata mjerimo PTE (RE_{VRS}/RE), dok procjenjivanjem udaljenosti između dviju krivulja efikasnosti mjerimo drugu komponentu BCC efikasnosti koja je povezana s razmjerom poslovanja (RE_{CRS}/RE_{VRS}). Ukupnu tehničku efikasnost računamo iz omjera RE_{CRS}/RE. Isto vrijedi i za preostale DMU u promatranom skupu mogućnosti. Iako su tehnički efikasne, pod pretpostavkom promjenjivih stopa povrata, tri jedinice odlučivanja ne ostvaruju optimalnu razinu poslovanja (DMU_A, DMU_C i DMU_D). Pri čemu DMU_A postiže ekonomiju razmjera, a DMU_C i DMU_D disekonomiju razmjera. Nasuprot njima DMU_B je efikasna u organizaciji proizvodnje i istodobno ostvaruje optimalnu razinu poslovanja ($B_{CRS} = B_{VRS}$).[121]

3.6. Konfirmatorna faktorska analiza-CFA

3.6.1. Značaj i razlike između glavnih razreda faktorske analize (EFA vs. CFA)

Faktorska analiza je multivarijantna statistička metoda koja najveću primjenu ima u području psihologije, obrazovanja, sociologije i zdravstva. Ona predstavlja neizostavan alat koji pruža konstruktivne dokaze za razvoj, usavršavanje i ocjenjivanje validnosti postojećih ili novih teorija, testova, ljestvica i mjernih konstrukata. Njena primjena je široka i najčešće se koristi za smanjivanje broja varijabli u manji skup latentnih faktora, ispitivanje strukture ili odnosa između izmjerenih varijabli i faktora, procjenu jednodimenzionalnosti teorijskih konstrukata, postizanje parsimonije rezultata, utvrđivanje multikolinearnosti, razvoj već postojećih teorija ili za dokazivanje/opovrgavanje novo predloženih teorija (Williams i sur., 2010: 2).

Za utvrđivanje dimenzionalnosti i konstruktne validnosti uobičajeno se koristi *Eksplorativna faktorska analiza* (engl. *Exploratory factor analysis-EFA*) i *Konfirmatorna faktorska analiza* (engl. *Confirmatory factor analysis-CFA*). U EFA-i istraživač ne mora nužno imati očekivanja o broju ili prirodi temeljnih faktora i kao takva metoda dozvoljava istraživaču da ispita glavne dimenzije u cilju razvijanja teorije (modela) iz velikog i nepreglednog skupa podataka. Čak

[121] Jedinica odlučivanja u točki B istodobno postiže tehničku učinkovitost i učinkovitost razmjera u uvjetima nepromjenjivih i promjenjivih stopa povrata $OTE_{CRS} = PTE_{VRS} = SE_B = SB/SB = 1$.

i kada postoje određena očekivanja, kao npr. kod ocjenjivanja validnosti, EFA-a ne obvezuje istraživača da navede svoja očekivanja koja, isto tako, ne utječu na rezultate analize.

S druge strane, CFA-a se koristi isključivo za testiranje unaprijed postavljenih modela i od istraživača zahtjeva određena očekivanja u obliku broja faktora, koje varijable odražavaju faktore i jesu li faktori međusobno povezani. Za razliku od EFA-e koja je istraživačke naravi, u CFA-i se modeliranjem strukturnih jednadžbi ispituju prethodno postavljena očekivanja o broju faktora i koja teorijska pozadina faktora najbolje odgovara empirijskim podacima. Metoda CFA-e je korisnija u prisutnosti teorije jer se teorija može izravno testirati i stupanj uklapanja u model se može kvantificirati na razne načine. Ponekad istraživanja započinju s teorijskim očekivanjima, ali nakon što CFA-a pokaže da su ta očekivanja pogrešna potrebno je vratiti se korak naprijed i provesti EFA-u. Drugim riječima, ovladavanje CFA-om istodobno zahtijeva razumijevanje EFA-e koja je ipak njena prethodnica (Thompson, 2004: 5-7).

Inicijalni rezultati našeg empirijskog istraživanja i početni model koji je predložila EFA-e su prikazani i objašnjeni u potpoglavlju 4.2.1. (str. 110).

3.6.2. Postupak promjene i preinake EFA modela

Jedna od najčešće korištenih metoda u *post hoc* modeliranju strukturnih jednadžbi (engl. *model modification*) je upotreba indeksa za prilagodbu modela (MI).[122] Svrha je proizvesti model koji će istodobno osigurati kvalitetno slaganje i precizno predstavljati odnose između varijabli interesa unutar populacije. Strukturna prilagodba EFA modela mora biti opravdana dobro postavljenom hipotezom ili teorijom kako bi konačan model bio sadržajno značajan jer u protivnom to postaje putovanje koje rezultira povećanjem *vjerojatnosti pogreške tipa 1* (Schreiber i sur., 2006: 327). Svako nerazumno uvažavanje prijedloga indeksa prilagodbe smanjuje kompaktnost podataka i vjerojatnost procjenjivanja parametara u modelu. Iz tako prigodno dobivenih modela koji pokazuju poželjno pristajanje podataka lako se mogu izvući pogrešni zaključci koji prikrivaju slabiju prilagodbu strukturalnog modela kao relevantnog predmeta istraživanja (McCoach i sur., 2007: 465).

Ako se koristi samostalno, metoda ispitivanja veličine MI indeksa prilagodbe može dovesti do nepoželjnog oslobađanja parametara koji ne uzrokuju značajne promjene apsolutnih

[122] *Indeksi prilagodbe* (engl. *modification indices-MI*) predstavljaju modelska poboljšanja i predlažu izmjene u strukturi početnih modela koje dovode do smanjenja vrijednosti hi-kvadrat statistike i to najmanje za iznos apsolutne vrijednosti indeksa prilagodbe ako se relevantni parametri modela mijenjaju iz fiksnog u slobodne (Schumacker i Lomax, 2010: 65).

vrijednosti hi-kvadrat statistike. U kombinaciji s analizom osjetljivosti može se procijeniti veličina utjecaja uklanjanja parametara na veće promjene u pristajanju modela. Također, poput hi-kvadrat statistike i standardiziranih reziduala MI indeksi prilagodbe su osjetljivi na veličinu uzorka. U tu svrhu Saris, Sattora i Sörbom (1987) predlažu indeks očekivanih promjena vrijednosti parametra (EPC), a Kaplan (1990) standardiziranu verziju EPC indeksa za usporedno procjenjivanje veličine pogrešno procijenjenih parametara (SEPC). Whittaker (2012) pokazuje da upotreba SEPC statistike nadmašuje preporuke MI indeksa u postizanju ispravnog modela, dok se stupanj njihove učinkovitosti izjednačava usporedno s rastom veličine uzorka, zasićenja faktora i pogrešno određenih parametara.[123] Usporedno korištenje MI indeksa i EPC statistike rezultira s četiri različita ishoda. Istodobno visoke vrijednosti MI i EPC indeksa opravdavaju uklanjanje parametara iz modela posebice ako ima teorijske osnove. Uklanjanje nema smisla ako parametar ostvaruje visoke vrijednosti MI i niske vrijednosti EPC indeksa, a značajan pad vrijednosti hi-kvadrata može biti posljedica njegove povezanosti s veličinom uzorka. Nasuprot tome, varijabilnost uzorka ili neosjetljivost parametara na test statistiku može uzrokovati povezanost niskih MI indeksa s visokim EPC indeksima što dodatno otežava odluku o uklanjanju parametara. U takvim situacijama predlaže se provedba preciznijih analiza statističke snage. Istodobno niske vrijednosti MI i EPC indeksa pokazuju slabiji utjecaj parametara na promjene apsolutnih vrijednosti hi-kvadrata i pristajanje modela.

U korištenju empirijskih preporuka svaka izmjena koja dovodi do jednostavnih ili velikih promjena u strukturi modela mora biti opravdana i prikazana u konačnim rezultatima. U modeliranju strukturnih jednadžbi naglasak je prvenstveno stavljen na uklapanje modela što ne mora nužno značiti da se radi o ispravnom modelu. Steiger (1990) zamjera upotrebu SEPC statistike koja krši osnovna statistička načela jer se odabir parametara provodi bez statističke zaštite i ponavlja dok vrijednost hi-kvadrata ne postane bez značaja (Steiger, 1990: 173). Modeli s dobrim pristajanjem često objašnjavaju vrlo malu varijancu relevantnih pokazatelja. Zato istodobno s upotrebom MI indeksa prilagodbe treba promatrati rezidualne vrijednosti (SRMR) i veličinu učinaka u procjenjivanju prikladnosti. Empirijska istraživanja u modeliranju strukturnih jednadžbi potrebno je usmjeriti na mjerenje statističke snage uz istodobno provođenje testa značajnosti (MacCallum i sur., 1996). Schumaker i Lomax (2010) navode da se niti jedan postojeći postupak nije pokazao dovoljno opravdanim za

[123] *Indeksi prilagodbe* pronalaze nevjerodostojne parametre koji slabije opisuju latentne varijable i predlažu eventualna mjesta u modelu gdje bolje pristaju, dok očekivane promjene vrijednosti standardiziranih parametara (engl. *standardized expected parameter change*) mjere promjene u veličini i smjeru svakog nevjerodostojnog parametra koji se slobodno procjenjuje u specifikaciji promatranog modela (Whittaker, 2012). Pri čemu pozitivna vrijednost SEPC indeksa znači da promatrani i potencijalno nevjerodostojan parametar treba ostati fiksiran u određivanju modela.

ispravno pronalaženje modela. Iako su napravljeni pomaci kako bi se utvrdilo koja će kombinacija postupaka najvjerojatnije dovesti do ispravno određenog modela još uvijek nije pronađena optimalna strategija. Cjeloviti postupak promjene i sve preinake početnog EFA modela u našem istraživanju i mjerenju stupnja usvojenosti zadružnih načela je prikazan i interpretiran u potpoglavlju 4.2.2. (str. 113).

3.6.3. Ispitivanje razina robustnosti (invarijantnosti) CFA modela

Mjerenje razina robustnosti ili invarijantnosti (engl. *measurement invariance*) podrazumijeva ispitivanje jednakosti i razlika između mjernih konstrukta modela po nezavisnim skupinama. Statističke mjere kao što su kovarijanca, prosječne vrijednosti i regresijski koeficijenti mogu se uspoređivati po različitim interesnim skupinama unutar uzorka ovisno o razini postignute invarijantnosti. Invarijantnost strukture modela, faktorskih zasićenja, intercepta pokazatelja i varijance reziduala su najčešće korišteni oblici testiranja invarijantnosti faktorskih modela prvog reda.[124] Na ovaj način se stvaraju ugniježđeni faktorski modeli koji su organizirani po hijerarhijskom poretku. Na svakoj slijedećoj razini modeli imaju sve manji broj parametara, odnosno sve veći broj stupnjeva slobode, uz istodobno kumulativno nametanje sve većeg broja dodatnih zahtjeva. Ispitivanje razine nepromjenjivosti je snažan statistički postupak koji provodi niz usporedbi između složenijih modela više razine i jednostavnijih modela niže razine (Milfont i Fischer, 2010: 113).

Zahtjev prve razine je da isti pokazatelj mora biti dio istog faktora, dok se faktorska zasićenja mogu razlikovati među skupinama (engl. *configural invariance*). Kad se postigne prva razina invarijantnosti kažemo da su u skupinama prisutni slični, ali ne identični faktori. Identičnost faktora se provjerava na drugoj razini uvođenjem novog zahtjeva *invarijantnost faktorskog zasićenja* (engl. *factor loading invariance*). Kada su faktorska zasićenja svakog pokazatelja na faktoru jednaka po skupinama možemo kazati da je mjerenje faktora identično i moguća je usporedba odnosa između latentnih faktora i pokazatelja po skupinama. Međutim, značaj faktora se još uvijek ne može uspoređivati, jer se podrijetlo njihovih skala može razlikovati po skupinama. Kako bi se omogućila potpuna usporedba faktora po skupinama na trećoj razini se uvodi zahtjev *invarijantnost intercepta* (engl. *intercept invariance*) koji predstavlja podrijetlo skale. Ovaj zahtjev zajedno s prvim dodanim zahtjevom *invarijantnih zasićenja* na

[124] Prva razina mjerenja robustnosti strukture modela provjerava *invarijantnost konfiguracije modela* (engl. *configural invariance*). Na svakoj sljedećoj razini kumulativno se dodaje po jedan novi zahtjev. Tako se na drugoj razini robustnost modela provjerava nametanjem zahtjeva *invarijantnost faktorskih zasićenja* (engl. *weak invariance*). Na trećoj razini se zahtjevu invarijantnih zasićenja dodaje zahtjev *invarijantnost intercepta pokazatelja* (engl. *strong invariance*), a na četvrtoj razini prva dva zahtjeva se upotpunjuju s trećim zahtjevom *invarijantnost varijanci reziduala* (engl. strict variance).

drugoj razini je preduvjet za mjerenje srednjih vrijednosti faktora po skupinama. Kada se postigne treća razina nepromjenjivosti moguća je usporedba srednjih vrijednosti faktora po skupinama jer faktorska zasićenja imaju istu mjernu jedinicu, a faktori su mjereni skalom koja ima isto podrijetlo. U protivnom, se ne može sa sigurnošću tvrditi da li su razlike između faktora istinite ili su samo lažni signal koji je nastao prilikom obrade podataka. Četvrta razina ispitivanja invarijantnosti se utvrđuje dodavanjem zahtjeva *invarijantnost varijance reziduala* (engl. *residual invariance*) kao dodatak na prethodna dva zahtjeva s nižih razina. Time se provjerava da li pokazatelji opisuju faktore s istim stupnjem pogreške mjerenja. Kada se postigne ova razina invarijantnosti možemo kazati da sve razlike pokazatelja nastaju samo kao posljedica razlika faktora. U empirijskim istraživanjima je vrlo teško postići invarijantnost reziduala (Chen i sur., 2005: 474-475; Milfont i Fischer, 2010: 115).

Kod utvrđivanja razina nepromjenjivosti najčešće se koriste komparativni indeks slaganja (CFI), McDonaldov indeks necentraliteta (NCI) i Steigerov Gamma hat indeks (GH) jer su manje osjetljivi na veličinu uzorka, preciznije otkrivaju nejednakosti i pružaju više informacija nego hi-kvadrat statistika (Meade i sur., 2008: 588). Kada vrijednosti CFI, NCI i GH indeksa slaganja padnu ispod 0,01, 0,02 i 0,01 model s većim brojem zahtjeva se odbacuje (Milfont i Fischer, 2010: 118), dok u protivnom manji raspon kretanja indeksa slaganja potvrđuje postizanje invarijantnosti modela s više razine.[125] Cijeli postupak ispitivanja razina potpune invarijantnosti modela za mjerenje stupnja usvojenosti zadružnih načela i rezultati testiranja su objašnjeni u potpoglavlju 4.2.4 (str. 119).

3.6.4. Utvrđivanje robustnosti CFA modela nametanjem djelomičnih zahtjeva

U prethodnom koraku smo objasnili kako se kumulativnim postavljanjem dodatnih zahtjeva invarijantnosti na parametre u modelu mogu utvrditi razine robusnosti CFA modela i da li je moguća usporedba rezultata po skupinama. Ako na primjer usporedba nije bila moguća jer postoji jedan ili više pokazatelja koji nemaju jednak obrazac vrijednosti moguće je postaviti djelomične zahtjeve i na taj način dodatno ispitati invarijantnost CFA modela. Uklanjanjem zahtjeva za nejednake parametre i dopuštanjem da slobodno odstupaju po skupinama, dok su istodobno nad ostalim parametrima i dalje nametnuti zahtjevi invarijantnosti, postavljaju se uvjeti za uspoređivanje razlika po skupinama i razina invarijantnosti u situacijama kada

[125] Zbog relativne neosjetljivosti CFI indeksa na strukturu srednjih vrijednosti postoji vjerojatnost da važne promjene u vrijednostima intercepta faktora možda neće biti prikladno prepoznate (Chen i sur., 2005: 474-475) zbog čega navedenu graničnu vrijednost od 0,01 pojedini istraživači smatraju pretjerano velikom (Meade i sur., 2008).

odstupanja dovode do varijantnosti (engl. *partial measurement invariance*). Postavljanjem djelomičnih zahtjeva unutar modela moguće je utvrditi koja faktorska zasićenja, intercepti ili pogreške mjerenja značajno odstupaju po skupinama. Rezultati ispitivanja invarijantnosti CFA modela za mjerenje stupnja usvojenosti zadružnih načela nametanjem djelomičnih zahtjeva su objašnjeni u potpoglavlju 4.2.5. (str. 122).

3.6.5. Ispitivanje i procjena slaganja CFA modela s empirijskim podacima

U procjenjivanju konvergentne i diskriminativne validnosti mjernih konstrukata korištenje CFA analize osigurava mnogo korisnih dijagnostičkih podataka uz manje ograničavajuće pretpostavke. Do sada je u prethodnim potpoglavljima bila objašnjena teorija raščlanjivanja parametara modela koja se temelji isključivo na upotrebi hi-kvadrat statistike i koja u malim uzorcima može rezultirati prihvaćanjem modela koji sadrže mali udio varijance. Zato je potrebno primijeniti i druge kriterije, poput indeksa slaganja (engl. *fit indices*), koji će kao praktični dodatak hi-kvadrat statistici potvrditi značaj objašnjene varijance i provjeriti da li model sadrži više parametara nego što ih podaci mogu opravdati (engl. *overfitted model*).

Indeksi slaganja mjere sposobnost modela da reproducira rezultate matrice varijance-kovarijance istraživačkog uzorka u drugim uzorcima iste populacije. Prihvatljiv model je razumno dosljedan prikupljenim podacima i ne zahtijeva ponovno strukturalno određivanje parametara. Indeksi slaganja mogu se podijeliti u tri kategorije: *apsolutni indeksi slaganja* (hi-kvadrat, RMSEA, SRMR i GFI), *inkrementalni ili usporedni indeksi slaganja* (CFI, TLI i NFI) i *indeksi prilagodbe ili predviđanja za postizanje parsimonije modela* (AIC i ECVI).[126] Budući da svaki indeks pruža različite informacije, preporučljivo je prilikom ocjenjivanja sposobnosti modela koristiti i prikazivati rezultate barem jednog indeksa iz svake skupine. Hu i Bentler (1999) predlažu upotrebu indeksa koji dobro reagiraju s različitim veličinama uzorka, vrstama podataka i rasponom prihvatljivih rezultata kako bi se utvrdilo da li model dobro pristaje empirijskim podacima. Njihove smjernice za tumačenje graničnih vrijednosti indeksa slaganja tumače se poput „*svetog pisma*“ u modeliranju strukturalnih jednadžbi (Barrett, 2007: 817). Prema Worthingtonu i Whittakeru (2006) minimalnu zbirku prikaza indeksa slaganja čine: *hi-kvadrat test s odgovarajućim brojem stupnjeva slobode i razinom*

[126] Predložena tipologija nije idealna jer neki indeksi slaganja poput TLI i RMSEA mogu istodobno imati značajke više skupina. Odabir indeksa slaganja i kriterij graničnih vrijednosti za prihvatljivost modela strukturalnih jednadžbi još su uvijek aktualna pitanja o kojima raspravljaju istraživači. Na uobičajeno korištene indekse slaganja vrlo često utječu različiti aspekti analitičke situacije kao što su: veličina uzorka, složenost modela, metoda procjene, količina i vrsta pogrešne specifikacije modela, normalna raspodjela, kao i vrsta promatranih podataka (Brown, 2006: 81-88).

značaja, *prosječna standardizirana rezidualna pogreška mjerenja s intervalom pouzdanosti od 90%* (RMSEA), *komparativni indeks slaganja* (CFI) i *standardizirana prosječna kvadratna kovarijanca reziduala* (SRMR). Hu i Bentler (1999) sugeriraju kombinirani pristup korištenja *standardizirane prosječne kvadratne kovarijance reziduala* zajedno s jednim apsolutnim (Gamma Hat, MFI, RMSEA) ili inkrementalnim indeksom (NNFI, IFI, RNI, CFI) u izlaganju rezultata modela strukturalnih jednadžbi. Schreiber i sur. (2006) predlažu korištenje TLI, CFI i RMSEA indeksa slaganja u jednokratnim analizama. Preporučljivo je da se prilikom uspoređivanja modela koriste i indeksi za predviđanje slaganja podataka kako bi se dodatno provjerila vjerodostojnost modela u drugim uzorcima iste populacije. CFI, TLI i RMSEA su najčešće korišteni indeksi za pouzdano ocjenjivanje pogrešno definiranih modela. RMSEA indeks se pokazuje korisnim u izvršavanju proračuna statističke snage (MacCallum i sur., 1996), dok je Akaike informacijska mjera korisna za uspoređivanje ne ugniježdenih modela. Barrett (2007) navodi da korištenje indeksa koji opisuju slaganje podatka unutar modela, bez primjene hi-kvadrat testa, jednostavno predstavlja pogrešno načelo i predlaže njihovo potpuno izostavljanje iz istraživačke prakse. Hi-kvadrat statistika je trenutno jedini statistički instrument za testiranje modela strukturalnih jednadžbi čija je logika djelovanja kristalno čista i egzaktna. Istraživač je dužan istaknuti njegove rezultate na isti način kao što se prijavljuju rezultati drugih statističkih testiranja. Upotreba indeksa slaganja pridonosi širenju subjektivnih prosudbi i argumenta istraživača nad objektivnim hi-kvadrat testom za mjerenje slaganja modela (Barrett, 2007: 822). Cijeli postupak ispitivanja i procjenjivanje slaganja konačnog CFA modela za mjerenje stupnja usvojenosti zadružnih načela s empirijskim podacima je opisan u potpoglavlju 4.2.8. (str. 130).

3.7. Metoda potencijala

3.7.1. Subjektivno mjerenje

Subjektivne metode mjerenja temelje se na subjektivnim procjenama od strane pojedinca koji time izražava stupanj zastupljenosti određene kvalitete objekta kojeg procjenjuje. Postupak procjene moguće je provoditi ili direktno na nekoj skali ili uspoređivanjem u parovima. Kod uspoređivanja u parovima (engl. *pairwise comparison*) procjenjuje se intenzitet preferencije o čemu će biti više riječi u nastavku. Subjektivne procjene, bez obzira radi li se o uspoređivanju u parovima ili na skali, donose se u odnosu na atribut (kriterij) kojeg uočavamo na objektu procjene.

3.7.2. Graf preferencije

U Metodi potencijala (PM) graf preferencije čini osnovnu strukturu koja se koristi u daljnjoj obradi podataka. Graf preferencije se može promatrati kao vrsta strukture ulaznih podataka koja je sastavljena od skupa *vrhova* i skupa *bridova*.[127] Vrhovi grafa preferencije predstavljaju *alternative* koje se uspoređuju u parovima, dok usmjereni *bridovi* opisuju njihove usporedbe (vidi sliku 3.5.).

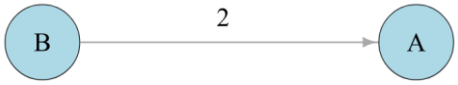

Slika 3.5. Prikaz intenziteta preferencije između dva vrha u grafu preferencije.

Preciznije, usmjereni brid izlazi iz manje preferiranog čvora B i ulazi u više preferirani čvor A. Pri tome, broj pridružen toj usporedbi (orijentiranom bridu) nazivamo *intenzitet preferencije*. Za tako ponderirane relacije kažemo da imaju *tok preferencije* koji se definira kao realna ne negativna funkcija na skupu bridova (engl. *preference flow*).[128] Graf

[127] Pojam *alternative* je termin koji se koristi kao sinonim za opcije ili mogućnosti. Termini *alternative*, *čvorovi* i *vrhovi* imaju isto značenje zbog čega se u nastavku mogu koristiti naizmjenično. Isto vrijedi za termine *bridovi* i *lukovi*, dok se *intenzitet preferencije* može poistovjetiti s ponderom ili težinom.

[128] Tok preferencije predstavio je De Condorcet (1785) kako bi pronašao najbolju metodu izbora između troje ili više kandidata za izbor u Francusku Akademiju. Koristeći graf preferencije uspoređuje

preferencije opisuje preferencije jednog donositelja odluke nad promatranim skupom alternativa, u odnosu na jedan kriterij ili atribut.

3.7.3. Metoda potencijala

Metodu potencijala (engl. *Potential Method*) je razvio Lavoslav Čaklović (2002). Preferencija predstavlja binarnu relaciju na skupu objekata (u ⪾ v) koja je dodatno opisana s intenzitetom preferencije. Cilj svakog vrednovanja je konstruirati realnu funkciju vrijednosti V definiranu na skupu opcija (alternativa) koja zadovoljava sljedeću formulu:

$$u \succcurlyeq v \iff \mathrm{V}(u) \geq \mathrm{V}(v) \tag{3.33.}$$

za svake dvije opcije *u*, *v* iz promatranog skupa opcija.[129] Takva funkcija ne postoji za svaku binarnu relaciju ⪾ na skupu alternativa. Razne teorije istražuju kakva svojstva relacija mora zadovoljavati da bi funkcija vrijednosti postojala. Jedna od njih je Metoda potencijala. Ova definicija funkcije vrijednosti postavlja pitanje uz koje uvjete na relaciju preferencije ona postoji. Metoda potencijala umjesto funkcije vrijednosti računa potencijal X koji može i ne mora biti funkcija preferencije. U tom smislu potencijal X je poopćenje funkcije vrijednosti o čemu će kasnije biti više rečeno.

Graf preferencije možemo definirati kao uređenu trojku $\mathcal{G} = (\mathcal{V}, \mathcal{A}, \mathcal{F})$ gdje je $\mathcal{V}$ skup čvorova nad kojima izražavamo preferencije, $\mathcal{A} \subseteq \mathcal{V} \times \mathcal{V}$ skup usmjerenih bridova u kojem svaki brid α povezuje dva čvora ($\alpha = (u, v)$), a $\mathcal{F}$ funkcija koja svakom bridu (u, v) pridružuje odgovarajući intenzitet preferencije $\mathcal{F}(u, v)$. Kada dva vrha *u* i *v* predstavljaju krajeve jednog brida α kažemo da su vrhovi incidentni s bridom i nazivamo ih *susjedni vrhovi*, dok dva brida incidentna s nekim zajedničkim vrhom nazivamo *susjedni bridovi*. Ukoliko graf preferencije $\mathcal{G}$ nema višestruke ili paralelne bridove kažemo da je graf preferencije *jednostavan*.

Općenito govoreći, svaki čvor $u \in \mathcal{V}$ biti će poželjniji od čvora $v \in \mathcal{V}$, ako postoji brid $m \in \mathcal{A}$ koji napušta početni (izlazni) čvor *v* i ulazi u terminalni (ulazni) čvor *u*. Takva relacija se u grafu preferencije prikazuje kao usmjereni brid, tj. uređeni par (u, v) pri čemu prvi simbol u zagradi označava *ulazni čvor*, a drugi simbol je *izlazni čvor*. To znači da je čvor *u* više

---

kandidate u parovima i definira tok *društvene preferencije* (engl. *social preference*) kao razliku između broja birača koji prednost daju prvom i broja birača koji prednost daju drugom kandidatu ($\mathcal{F}_C(u, v) := N(u, v) - N(v, u)$).

[129] Relaciju $u \succcurlyeq v$ čitaj kao: opcija *u* je „bolja ili jednako dobra“ kao opcija *v*.

preferiran u odnosu na čvor *v* (vidi formulu 3.33.). Ako je relaciju uparenih čvorova moguće numerički izraziti tada kažemo da usmjereni brid ima težinu tj. ponder koji zovemo *intenzitet toka preferencije* ($\mathcal{F}_{(u,\ v)}$).[130] Tok $\mathcal{F}$ možemo poistovjetiti s vektorom iz $\mathbb{R}^m$, što ćemo u nastavku i učiniti. Vektorski prostor $\mathbb{R}^m$ koji definira tok grafa preferencije nazivamo *prostor bridova* (engl. *arc space*), dok vektorski prostor $\mathbb{R}^n$ koji definira potencijal grafa preferencije nazivamo *prostor vrhova* (engl. *vertex space*). Na slici 3.6. je prikazan potpun i konzistentan graf koji uspoređujući alternative u parovima stvara poredak i vrednuje alternative.[131] Na primjer, smjer brida $B \overset{2}{\leftarrow} A$ ukazuje da je čvor B preferiranija alternativa od čvora A ($B \succcurlyeq A$), dok njegov intenzitet preferencije ima vrijednost 2 što znači da je subjektivna (nepoznata) vrijednost čvora B veća za 2 jedinice od vrijednosti čvora A.

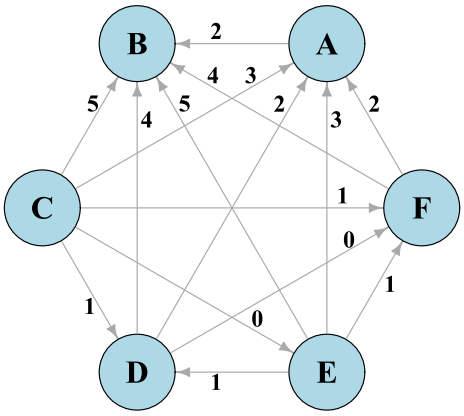

Slika 3.6. Primjer konzistentnog grafa preferencije sa šest čvorova (alternativa).

Iz prikazanog grafa preferencije lako je moguće konstruirati skalu važnosti čvorova koja izgleda:

$$B \succcurlyeq A \succcurlyeq F \sim D \succcurlyeq E \sim C \qquad (3.34.)$$

[130] *Intenzitet preferencije* je ne negativan broj ($F_\alpha \geq 0$) koji predstavlja tok preferencije grafa i u subjektivnim mjerenjima najčešće se izražava na brojčanoj skali od 0 do 4 što odgovara verbalnom intenzitetu: *jednaka*, *slaba*, *jaka*, *izrazita* i *potpuna preferencija*. Navedena skala vrijednosti je usporediva sa Saatyevom *metodom svojstvenog vektora* (engl. *eigenvector method*). S porastom broja alternativa korisno je povećati raspon skale intenziteta.

[131] Kažemo da je graf preferencije potpun kada je svaka komponenta maksimalno puta povezana odnosno ako je svaki par vrhova spojen bridom. Bilo koji skup uspoređenih parova dat će graf preferencije, pri čemu alternativa koja nije uspoređena naprosto će biti predstavljena vrhom bez incidentnih bridova u grafu.

Za računanje potencijala grafa potrebno je definirati *matricu incidencije* (engl. *incidence matrix*) i *Laplaceovu matricu* (engl. *Laplacian matrix*).

Neka je A = ($A_{\alpha,\ v}$) *m* × *n matrica incidencije* za graf preferencije ($\mathcal{G}$) definirana na sljedeći način:[132]

$$A_{\alpha,v} = \begin{cases} -1, & ako\ brid\ \alpha\ izlazi\ iz\ vrha\ v \\ 1, & ako\ brid\ \alpha\ ulazi\ \text{u}\ vrh\ v \\ 0, & inače \end{cases} \tag{3.35.}$$

pod pretpostavkom da su skup vrhova {1,… *n*} i skup bridova {1,… *m*}. To se može prikladnije napisati $A_{\alpha,v}$ gdje je *α* indeks brida, a *v* indeks vrha.

Laplaceova n × n matrica za graf preferencije ($\mathcal{G}$) je L = A^T A. Njeni matrični elementi su:[133]

$$L_{i,j} = \begin{cases} -1, & ako\ postoji\ brid\ koji\ ulazi\ ili\ izlazi\ iz\ vrha\ i \\ deg(i), & ukupan\ broj\ bridova\ koji\ ulaze\ ili\ izlaze\ iz\ vrha\ i \\ 0, & inače \end{cases} \tag{3.36.}$$

pri čemu *deg*(*i*) definiramo kao *stupanj vrha* koji predstavlja broj incidentnih bridova koji ulaze ili izlaze iz promatranog vrha.[134]

Za graf iz gornjeg primjera (Slika 3.6.) navedene matrice izgledaju ovako:

---

[132] Matrica incidencije često se koristi u teoriji grafova za prikazivanje povezanosti vrhova grafa. Indeks retka u matrici je indeks brida, a indeks stupca je indeks vrha na grafu preferencije. Maksimalno mogući broj usporedbi s *n* alternativa izračunava se po formuli $n(n-1)/2$ (Thurstone, 1927). Matrica incidencije pokazuje (ne)postojanje međuodnosa između bridova i vrhova, pri čemu vrijednost 1 označava incidentnost između retka *m* (brida) i stupca *n* (vrha) dok vrijednost 0 ukazuje da nema incidentnosti.

[133] Laplaceova matrica koristi se u području teorije grafova za matričnu prezentaciju i pronalaženje korisnih svojstava grafova. Često se definira kao *simetrična* i pozitivna *semidefinitna matrica* (engl. *semidefinite matrix*) u kojoj je zbroj svakog retka jednak nuli. Njene pripadajuće vrijednosti (eigenvalues) uvijek su ne negativne, pri čemu se vrijednost nula javlja najmanje jedanput.

[134] Stupanj svakog vrha grafa nalazi se na glavnoj dijagonali Laplaceove matrice. Ako je *deg*(*i*) = 0 tada vrh nazivamo *izoliranim*, ako je *deg*(*i*) = 1 onda ga nazivamo *krajnjim vrhom* te ako su svi vrhovi istog stupnja tada za graf kažemo da je *regularan*. Na slici 3.6. stupanj vrha ostvaruje maksimalnu vrijednost (*n* − 1) i jednak je za sve vrhove: *deg*(*a*) = *deg*(*b*) = *deg*(*c*) = *deg*(*d*) = *deg*(*e*) = *deg*(*f*) = 5.

$$\boldsymbol{A} = \begin{bmatrix} -1 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & -1 & 0 & 0 & 0 \\ 1 & 0 & 0 & -1 & 0 & 0 \\ 1 & 0 & 0 & 0 & -1 & 0 \\ 1 & 0 & 0 & 0 & 0 & -1 \\ 0 & 1 & -1 & 0 & 0 & 0 \\ 0 & 1 & 0 & -1 & 0 & 0 \\ 0 & 1 & 0 & 0 & -1 & 0 \\ 0 & 1 & 0 & 0 & 0 & -1 \\ 0 & 0 & -1 & 1 & 0 & 0 \\ 0 & 0 & -1 & 0 & 1 & 0 \\ 0 & 0 & -1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & -1 & 0 \\ 0 & 0 & 0 & -1 & 0 & 1 \\ 0 & 0 & 0 & 0 & -1 & 1 \end{bmatrix}, \qquad \boldsymbol{L} = \begin{bmatrix} 5 & -1 & -1 & -1 & -1 & -1 \\ -1 & 5 & -1 & -1 & -1 & -1 \\ -1 & -1 & 5 & 1 & -1 & -1 \\ -1 & -1 & -1 & 5 & -1 & -1 \\ -1 & -1 & -1 & -1 & 5 & -1 \\ -1 & -1 & -1 & -1 & -1 & 5 \end{bmatrix}$$

Matrica incidencije (lijevo) ima 15 redaka koji odgovaraju broju bridova u spomenutom grafu preferencije, dok 6 stupaca odgovara broju njegovih vrhova (alternativa). Možemo primijetiti da se u svakom stupcu matrice incidencije nalazi točno pet elemenata koji su različiti od nule. Iz toga zaključujemo da je svaki vrh grafa povezan s ostalim vrhovima tj. da je graf preferencije potpun i opisuje sve moguće međusobne usporedbe alternativa u parovima. Elementi na glavnoj dijagonali Laplaceove matrice (desno) potvrđuju da svaki vrh potpunog grafa preferencije ima maksimalan broj incidentnih bridova (5), a vrijednosti ispod i iznad glavne dijagonale ukazuju na međusobnu povezanost svih alternativa i potpunost grafa preferencije.[135]

3.7.4. Računanje potencijala u konzistentnom grafu preferencije

Cilj metode potencijala je korištenjem koncepta grafa preferencije odrediti vrijednosti alternativa $X = (X_u, X_v, \ldots X_n)$ tako da vrijedi:

$$X_u - X_v = \mathcal{F}_{(u,\, v)}, \qquad \forall\, (u, v) \in \mathcal{A} \tag{3.37.}$$

Rješenje gornje jednadžbe, ako postoji, zovemo potencijalom grafa preferencije. Formula (3.37.) se svodi na sustav jednadžbi koji sadrži toliko jednadžbi koliko ima bridova u grafu preferencije. Pri čemu je lijeva strana jednadžbe $X_u - X_v$ jednaka skalarnom produktu

[135] *Povezan graf* u teoriji grafova zovemo graf u kojem za svaka dva njegova vrha *u* i *v* postoji (*u*, *v*) put u tom grafu. Ako postoje vrh ili skupina vrhova koji se ne mogu povezati putem kažemo da je graf nepovezan. Pri čemu svaki ne povezani vrh ili skupina vrhova čini komponentu povezanosti u *nepovezanom grafu*.

vektora X i onog retka u matrici incidencije A koji odgovara bridu (u, v). Iz navedenog se dobiva:

$$AX = \mathcal{F} \tag{3.38.}$$

To nije uvijek moguće učiniti što znači da jednadžba (3.38.) nema uvijek rješenje. Ako sustav jednadžbi ima rješenje kažemo da je graf preferencije odnosno njegov tok $\mathcal{F}$ konzistentan. Primjer konzistentnog grafa preferencije prikazuje slika 3.6. U njemu podgraf određen lukovima α, β i γ je konzistentan jer je zbroj vrijednosti intenziteta preferencije dva uzastopna luka α i β (engl. *adjacent edges*) jednaka intenzitetu preferencije trećeg luka γ suprotnog smjera ($\mathcal{F}_\alpha + \mathcal{F}_\beta = \mathcal{F}_\gamma$). Kažemo da je tok ciklusa konzistentan ako je zbroj intenziteta preferencije svih bridova uzduž promatranog ciklusa jednak nuli (0) tj. graf je konzistentan ako je svaki njegov ciklus konzistentan.[136]

3.7.5. Računanje potencijala u nekonzistentnom grafu preferencije

Međutim, graf preferencije ne mora nužno biti konzistentan. Zahtijevati potpunu konzistentnost od strane ispitanika posebice u slučajevima s velikim brojem alternativa nije realno za očekivati. Zato formula (3.38.) ne postavlja nikakva ograničenja na konzistentnost preferencija ispitanika tako da u slučaju nekonzistentnosti ne zahtjeva točno, već najbolje aproksimativno (približno) rješenje u smislu najmanjih kvadrata, odnosno pomoću prostora stupaca matrice incidencije minimizirati kvadrat euklidske udaljenosti $\|AX - \mathcal{F}\|^2$.[137] Ako dvije gornje jednadžbe (3.37.) i (3.38.) nemaju rješenje tada sljedeća jednadžba ima rješenje koje također nazivamo potencijalom:

$$A^T AX = A^T \mathcal{F} \tag{3.39.}$$

Može se primijetiti da je $A^T A$ zapravo Laplaceova matrica grafa preferencije, dok produkt $A^T \mathcal{F}$ predstavlja *razliku toka* (engl. *flow difference*) tj. razliku između ukupnog toka koji ulazi

[136] *Ciklus* je zatvoren put koji počinje i završava u istom vrhu, a pri tome prolazi kroz različite čvorove.

[137] Odgovarajući AX je vektoru $\mathcal{F}$ najbliži vektor u slici linearnog operatora A, tj. u potprostoru R(A). Dakle, AX je ortogonalna projekcija od $\mathcal{F}$ na spomenuti potprostor.

u čvor *v* i ukupnog toka koji izlazi iz čvora *v*. Koristeći se definicijom matrice incidencije A, izračunava se razlika toka (∇):

$$\nabla_v = \sum_{\alpha=1}^{m} A_{v,\alpha}^T \mathcal{F}_\alpha = \sum_{\alpha\ ulazi\ u\ v} \mathcal{F}_\alpha - \sum_{\alpha\ izlazi\ iz\ v} \mathcal{F}_\alpha \tag{3.40.}$$

Iz navedene formule slijedi:

$$\sum_{v=1}^{n} \nabla_v = 0 \tag{3.41.}$$

Konačno sustav jednadžbi (3.40.) sada možemo raspisati kao:

$$LX = \nabla \tag{3.42.}$$

Matrica L je singularna matrica čiji je rang jednak *n* − *k*, gdje je *k* broj komponenata (slabo) povezanih alternativa u grafu $\mathcal{G}$. To znači da Laplaceov sustav jednadžbi nema jedinstveno rješenje. Jedinstveno rješenje za povezan graf postiže se dodavanjem jednadžbe:

$$\sum_{v=1}^{n} X_v = 0 \tag{3.43.}$$

Laplaceovoj matrici (L) i matrici razlike toka (∇). Uvjet (3.43.) smanjuje dimenziju prostora rješenja za 1 (jedan) pa u slučaju povezanog grafa (*k* = 1) uz njega dobivamo jedinstveno rješenje. Općenito je potrebno dimenziju prostora rješenja smanjiti za *k*, što činimo tako da dodamo uvjet (3.43.) na svaku povezanu komponentu grafa $\mathcal{G}$. Na takav način svaka povezana komponenta grafa ima svoj potencijal.

Primjer nekonzistentnosti vidljiv je unutar ciklusa kojeg zatvaraju čvorovi A, B i C na slici 3.7. Osim nekonzistentnosti, slika prikazuje nepotpun tok preferencije jer nisu sve alternative međusobno uspoređene.[138] Obzirom da su dvije alternative (čvor A i čvor C)

[138] U grafu preferencije izostaje prikaz relacija čvora *d* s čvorovima *a* i *c*. Unatoč tome, moguće je iz ostalih intenziteta preferencija ustanoviti da je alternativa *d* bolje rangirana u ukupnom poretku od alternativa *a* i *c*.

jednako preferirane u prikazanom grafikonu, za očekivati je da će biti jednako slabije rangirane u odnosu na čvor B. Međutim, vrijednosti intenziteta preferencija koje proizlaze iz njihovih relacija s čvorom B proturječe očekivanoj konzistentnosti grafa preferencije ($\mathcal{F}_{(B, A)}$ = 3 i $\mathcal{F}_{(B, C)}$ = 4). U slučaju jednake preferencije alternativa kao što je to slučaj s čvorovima A i C (A ~ C), smjer luka nema značaj u opisivanju ukupnog toka grafa, zapis (A, C) može se zamijeniti sa zapisom (C, A), a vrijednost intenziteta preferencije između relevantnih alternativa iznosi nula ($\mathcal{F}_{(A, C)}$ = 0).

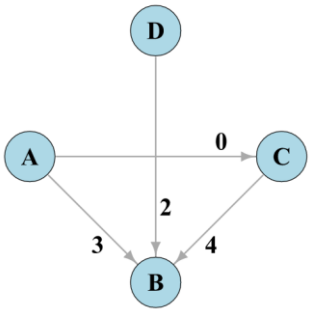

Slika 3.7. Primjer nekonzistentnog i nepotpunog grafa preferencije.

3.7.6. Agregiranje toka i konstruiranje multigrafa preferencije

Za razliku od jednostavnog grafa preferencije, multigraf dozvoljava prisutnost višestrukih ili paralelnih bridova. Potreba za multigrafom javlja se kada alternative uspoređujemo u parovima u odnosu na više atributa. Za svaki atribut, koji uspoređuje alternative *a* i *b*, u multigrafu dodajemo jedan novi brid koji incidentan s *a* i *b*. Time se povećava prostor bridova, a na kraju i dimenzija toka preferencije. Pri tome se matrica incidencije multigrafa zapisuje na identičan način kao kod jednostavnog grafa tj. svakom bridu pripada po jedan redak, a svakoj alternativi po jedan stupac u matrici incidencije. To se postiže okomitim nadovezivanjem matrica incidencija pojedinačnih grafova preferencije. Ispod su prikazane matrice incidencije za svaki graf preferencije na slici 4.4.:

	D	Z	P	R
α_1	1	−1	0	0
α_2	1	0	−1	0
α_3	1	0	0	−1
α_4	0	1	−1	0
α_5	0	1	0	−1
α_6	0	0	1	−1

	D	Z	P	R
α_7	1	−1	0	0
α_8	−1	0	1	0
α_9	1	0	0	−1
α_{10}	0	−1	1	0
α_{11}	0	1	0	−1
α_{12}	0	0	1	−1

	D	Z	P	R
α_{13}	1	−1	0	0
α_{14}	1	0	−1	0
α_{15}	1	0	0	−1
α_{16}	0	1	−1	0
α_{17}	0	1	0	−1
α_{18}	0	0	1	−1

	D	Z	P	R
α_{19}	1	−1	0	0
α_{20}	1	0	−1	0
α_{21}	1	0	0	−1
α_{22}	0	−1	1	0
α_{23}	0	−1	0	1
α_{24}	0	0	1	−1

	D	Z	P	R
α_{25}	1	−1	0	0
α_{26}	1	0	−1	0
α_{27}	1	0	0	−1
α_{28}	0	−1	1	0
α_{29}	0	1	0	−1
α_{30}	0	0	1	−1

	D	Z	P	R
α_{31}	1	−1	0	0
α_{32}	1	0	−1	0
α_{33}	1	0	0	−1
α_{34}	0	−1	1	0
α_{35}	0	−1	0	1
α_{36}	0	0	1	−1

Iz matrica incidencije moguće je konstruirati multigraf i Laplaceovu matricu na čijoj se dijagonali i dalje nalazi stupanj čvora. Ispod i iznad njene dijagonale, na mjestu *ij* stoji broj paralelnih bridova između čvora *i* i čvora *j* s negativnim predznakom. Potencijal multigrafa preferencije je rješenje Laplaceove jednadžbe (vidi formulu (3.39.)).

Multigraf preferencije se koristi i kod višekriterijskog ili grupnog odlučivanja gdje svaki sudionik mjerenja predstavlja atribut (kriterij) za koji se konstruira *zaseban graf* (engl. *individual ranking*). U tu svrhu se provodi agregiranje individualnih grafova za cijeli *skup atributa* (engl. *consensus*), dok se iz dobivenog multigrafa stvara *konačan poredak alternativa* (engl. *global ranking*).

3.7.7. Hijerarhijsko odlučivanje s jednim i više ciljeva

Prvi korak u postupku modeliranje odluke (engl. *decision modeling*) je izgradnja hijerarhije, odnosno grupiranje skupa promatranih elemenata odlučivanja u više razina. Raslojavanje elemenata odlučivanja se najčešće provodi u tri razine: *cilj*, *kriteriji*, *alternative*, dok složeniji problemi odlučivanja podrazumijevaju uključivanje novih razina tj. uvođenje *dodatnih kriterija* u izvorni skup početnih kriterija (Saaty i Vargas, 1982).[139] U praksi postoji mnogo argumenata koji govore u korist hijerarhijskog načina strukturiranja elemenata odluke.

[139] Složeniji problemi odlučivanja mogu uključiti kriterij *okoline* u izvorni skup kriterija (*cilj*, *okolina*, *atributi*, *kriteriji*, *alternative*), dok najsloženiji problemi odlučivanja mogu imati desetak razina. Grupiranje elemenata odlučivanja u razine se prepušta donositelju odluka. U našem istraživanju izvorni skup kriterija sadrži ekonomske pokazatelje, dok zadružna načela čine dodatne kriterije koji su smješteni u trećoj razini. Vrijednosti potencijala (X) kriterija u razinama tri i četiri služe kao pomoćni rezultati koje smo koristili u narednoj (drugoj) razini hijerarhije.

Mnogi problemi vrednovanja mogu se modelirati pomoću hijerarhije koju odlikuje *strukturalna* i *funkcionalna* stabilnost. Strukturalna stabilnost omogućava dodavanje ili oduzimanje elemenata bez narušavanja cijele organizacije, a funkcionalna stabilnost protok informacija odozgo prema dolje. U grafičkim prikazima hijerarhija se prikazuje u obliku piramide čiji se baza širi od gore prema dolje ili slijeva nadesno. Vrh piramide predstavlja *ciljeve vrednovanja*, njegova baza *alternative* koje međusobno uspoređujemo, dok se između nalaze *kriteriji* koje koristimo u vrednovanju alternativa. Hijerarhijsko raščlanjivanje omogućuje potpunije razumijevanje postupka odlučivanja, kriterija koje koristimo i alternativa koje ocjenjujemo. Također, može ukazati na nužnost ili mogućnost uvođenja dodatnih elemenata odlučivanja koji bi osigurali uvažavanje svih kriterija i mogućih alternativa. U našem empirijskom istraživanju naglasak je stavljen na rangiranje zadružnih načela. Na donjoj slici 3.8. je prikazana samodualna hijerarhija s četiri razine i dobivena je iz konkretnih podataka našeg empirijskog istraživanja.

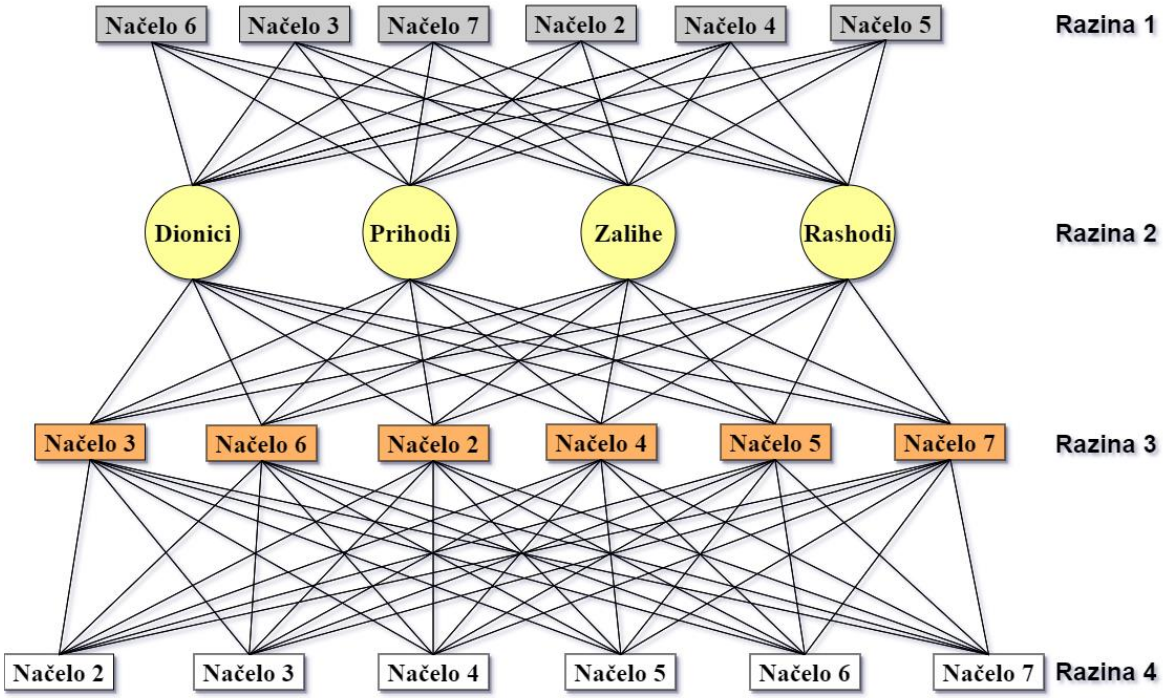

Slika 3.8. Samodualna hijerarhija s više ciljeva i četiri razine za sve elemente odlučivanja.

Na slici vrhove više razine koji imaju svoje sljedbenike zovemo *korijenom* ili *roditeljem*, dok njihove sljedbenike smještene na nižim razinama zovemo *listovima* ili *djecom*.[140] U našem

[140] Jedino ograničenje je da sljedbenici trebaju biti na istoj razini u hijerarhiji, dok njihovi roditelji mogu biti s različitih razina.

slučaju svaki vrh jedne razine dijeli iste sljedbenike na nižoj razini. Tako na primjer, vrhovi glavnog korijena (Razina 1) imaju djecu na drugoj razini hijerarhije (dionici, prihodi, zalihe i rashodi). Ovi ekonomski pokazatelji, smješteni na Razini 2, su roditelji djeci na trećoj razini (Načelo 3, Načelo 6, Načelo 2, Načelo 4, Načelo 5 i Načelo 7). Navedeno vrijedi duž cijele hijerarhije, sve do posljednje razine (Razina 4). Alternative zadnje razine su djeca roditelja smještenih na trećoj razini i one nemaju svoje sljedbenike (djecu).

3.7.8. Postupak vrednovanja hijerarhije metodom potencijala

U procesu vrednovanja hijerarhije pomoću metode potencijala može se dogoditi da kompozitni graf neke razine nije povezan. U tom slučaju za svaku komponentu povezanosti C i njen potencijal X_C računamo pripadni vektor težina (rangova) po sljedećoj formuli:

$$w_C = k_C \cdot \frac{a^{X_C}}{\|a^{X_C}\|_1} \tag{3.44.}$$

gdje $\| \cdot \|_1$ predstavlja l_1-normu, a k_C je jednak zbroju težina svih roditelja elemenata iz $\mathcal{C}$. Nakon rangiranja te razine može se nastaviti s rangiranjem sljedeće razine u hijerarhiji.

Postupak vrednovanja elemenata odlučivanja u hijerarhiji odvija se silazno po razinama i započinje rangiranjem elemenata na prvoj razini.[141] Vrednovani elementi odluke prve razine imaju određene težine koje se prenose na njihove sljedbenike. Postupak se ponavlja za svaku sljedeću razinu hijerarhije sve dok i posljednja razina ne bude rangirana. Pri tome vrijedi da je zbroj težina svih sljedbenika na pojedinoj razini jednaka težini svojih roditelja (*Zakon o očuvanju ukupnosti informacija*).[142] Iz toga slijedi da je zbroj težina svih alternativa na posljednjoj razini jednak težini glavnog korijena ($w_0 = w_3 = 1$). Hijerarhiju u kojoj je za svaku razinu napravljen poredak elemenata nazivamo *vrednovana hijerarhija*.

[141] U hijerarhiji s više ciljeva rangiranje elemenata određuje se na način da zbroj težina svih elemenata glavnog korijena iznosi jedan (1). U hijerarhiji s jednim ciljem elementu unutar glavnog korijena dodjeljuje se težina jedan (1).

[142] Vrednovanje u hijerarhiji može se promatrati kao proces prenošenja cjelovitih informacija, od prve do posljednje razine, bez gubitaka informacija prilikom prelaska hijerarhije (engl. *the law of conservation of information*).

3.7.9. Samodualna hijerarhija i revizija prioriteta

Samodualna hijerahija je organizirana tako da prva razina i posljednja razina sadrže iste elemente odlučivanja, a postupak vrednovanja se provodi na isti način kao kod obične hijerarhije s jednim ili više ciljeva. Težine elemenata prve razine (w_0) se najčešće određuju na način da su međusobno jednake ili normirane tako da zbroj njihovih vrijednosti iznosi jedan. Elementi odluke prve razine služe kao kriteriji za procjenu sljedbenika i po utvrđenim pravilima prenose svoje težine na djecu u drugoj razini. Izračunate težine posljednje razine (w_1) ovise o težinama prve razine (w_0), a funkciju Φ koja ih povezuje zovemo *operatorom samorangiranja* ($w_1 = \Phi(w_0)$).[143] Dobiveni vektor izračunatih težina (w_1) koristi se u revidiranju početnih težina prve razine (w_0). Postupak *revizije prioriteta* u Metodi potencijala je istovjetan postupku revizije vjerojatnosti upotrebom Bayesove formule za računanje vjerojatnosti (Čaklović, 2014: 439). Na kraju se ponovno provodi postupak rangiranja s novo revidiranim težinama pomoću formule (3.44.).

Samodualna hijerarhija je zapravo postupak revizije početnih težina elemenata na prvoj razini (w_0) koje donositelj odluka donosi na temelju znanja i iskustva. Postupak revidiranja težina vrlo brzo konvergira i konačan rezultat ne ovisi o početnim težinama elemenata odluke.

Cijeli postupak provedbe Metode potencijala za potrebe našeg empirijskog istraživanja i mjerenja stupnja usvojenosti zadružnih načela u modelu zadružnog poslovanja je detaljno opisan u odjeljku Rezultati istraživanja (vidi potpoglavlje 4.3.). Konačni rezultati Metode potencijala o usvojenosti zadružnih načela su obrazloženi u odjeljku Rasprava (vidi potpoglavlja 5.4., 5.5. i 5.6.).

[143] *Operator samorangiranja* uvažava strukturu sustava (hijerarhije) i vrijednosti početnih elemenata odluke na temelju kojih izračunava nove vrijednosti koje koristi u procjeni trenutnog stanja. Samorangirajuća hijerarhija omogućava reakciju modela na promijenjeno stanje okoline i objašnjava pojave u kojima je prisutna sinergija (Saaty, 2003).

4. REZULTATI ISTRAŽIVANJA

4.1. Analiza tehničke efikasnosti i efikasnosti razmjera zadruga

4.1.1. Opis izvornog skupa varijabli za definiranje konačnog AOMP modela

Prema Nacionalnoj klasifikaciji djelatnosti (NKD 2007.) uzorkovane poljoprivredne zadruge operativno djeluju u sektoru ratarstva i proizvode više vrsta jednogodišnjih usjeva (A-01.1). U Tablici 4.1. su prikazani svi raspoloživi poslovni podaci koje smo koristili u postupku definiranja konačnog AOMP modela, opis sadržaja AOP kategorija i mjerne jedinice. Izvorni skup podataka čini 9 varijabli čije su definicije i objašnjena odabira iznesene u nastavku. Iz izvornog skupa podataka na kraju su odabrane četiri varijable (*zalihe*, *dionici*, *ukupni prihodi* i *ukupni rashodi*), od čega prve dvije varijable čine ulazne podatke, a zadnje dvije varijable izlazne podatke u konačnom AOMP modelu. Cijeli postupak i razlozi odabira četiri varijable su objašnjeni u sljedećem potpoglavlju (4.1.2., str. 104).

Varijabla *dionici* okuplja sve fizičke osobe koje na različite načine sudjeluju u poslovanju zadruge, a njena vrijednost dobivena je sumom tri pokazatelja: *broj članova*, *zaposlenika* i *kooperanata*. Time je smanjena neujednačenost podataka u uzorku koja negativno utječe na sposobnost modela u određivanju i razdvajanju efikasnih jedinica odlučivanja (više o tome vidi u potpoglavlju 3.5.8., str. 78). Agregirani podatak izražava jednu od društvenih komponenti zadružnog poslovanja i ulazi u razmatranja kod definiranja AOMP modela. Posljednji Zakon o zadrugama (NN, br. 34/2011, 125/2013, 76/2014, 114/2018, 98/2019) propisuje da je član zadruge svaka fizička osoba koja sudjeluje u radu skupštine, posluje putem zadruge ili koristi njene usluge radi ostvarenja poslovnih ciljeva zbog kojih je zadruga osnovana (članak 10). Nasuprot njima, *zaposlenici* i *kooperanti* su definirani kao fizičke osobe koje ne ostvaruju pravo sudjelovanja u radu skupštine ako to nije drugačije uređeno unutrašnjim pravilnicima i mogu sudjelovati u obavljanju osnovnih djelatnosti ako time nisu ugroženi interesi i rad članova (članak 34). Sa zaposlenikom, uprava zadruge sklapa ugovor o radnom odnosu, dok s kooperantom sklapa ugovor o zajedničkoj proizvodnji. Agregiranu varijablu *dionici* uključujemo u daljnja razmatranja kod definiranja konačnog AOMP modela.

Preostale varijable u izvornom skupu podataka su isključivo ekonomske naravi i izražene su u novčanim jedinicama (kunama). Riječ je o varijablama: *dugotrajna materijalna imovina*, *zalihe*, *aktiva* i *zadržana dobit* koje čine sastavne elemente financijskog izvještaja bilance,

i varijablama *ukupni prihodi* i *ukupni rashodi* koji čine osnovne elemente Računa o dobiti i gubitku poslovanja. Varijable *materijalna imovina* i *zalihe* čine stavke aktive, dok varijabla *zadržana dobit* čini stavku pasive u bilanci. Sve ekonomske varijable sastoje se od nekoliko AOP kategorija čija je zadaća sistematizirano prikazati stanje imovine (aktive), te obveze i kapital (pasive) zadruga u financijskim izvještajima. Prikazivanjem stavki aktive i pasive u bilanci dobiva se uvid u strukturu financijskog poslovanja i mogućnost praćenja poslovnih promjena u promatranom vremenskom razdoblju. Pri čemu stavka aktive objašnjava s čime zadruga raspolaže, a stavka pasive da li su osnovna sredstva zadruge navedena u aktivi osigurana iz glavnice, odnosno dugoročnih i kratkoročnih obveza. Uravnoteženost stavki aktive i pasive u bilanci predstavlja značajku dobrog poslovanja. Na primjer, financiranje kratkoročne imovine iz kratkoročnih obveza odnosno dugoročne imovine iz kapitala i/ili dugoročnih obveza povećava sposobnost zadruge da svojim novčanim sredstvima redovito podmiruje sve svoje obveze (solventnost). U protivnom dolazi do nemogućnosti redovitog podmirivanja obveza zbog nedostatka novca ili novčanih ekvivalenata (insolventnost).

Varijabla *dugotrajna materijalna imovina* je izračunata zbrajanjem novčanih vrijednosti četiri AOP kategorije u financijskom izvješću: *zemljište* (AOP011), *građevinski objekti* (AOP012), *postrojenja i oprema* (AOP013) i *alati*, *pogonski inventar* i *transportna imovina* (AOP014).[144] Uvažavanjem svake navedene kategorije zasebno povećala se neujednačenost podataka u uzorku što rezultira stvaranjem AOMP modela čija sposobnost izdvajanja velikog broja tehnički efikasnih jedinica odlučivanja dovodi u pitanje robustnost takvih modela. Spajanjem četiri kategorije u jednu varijablu *dugotrajna imovina* smanjena je neujednačenost podataka i uklonjen je nered koji stvaraju alternativne pojedinosti i različiti rezultati neprikladno odabranih AOMP modela (više o tome vidi u potpoglavlju 3.5.8, str. 78). Varijabla *dugotrajna imovina* je uključena u daljnja razmatranja kod definiranja konačnog AOMP modela.

Varijablu *zalihe* definiramo kao kratkotrajnu materijalnu imovinu kojom zadruga raspolaže, a njena vrijednost računa se zbrajanjem vrijednosti sedam kategorija: *sirovine i materijali* (AOP039), *trenutna proizvodnja* (AOP040), *konačni proizvodi* (AOP041), *trgovačka roba* (AOP042), *predujmovi za zalihe* (AOP043), *dugotrajna imovina za prodaju* (AOP044) i *biološka imovina* (AOP045). Konačan rezultat sume sedam kategorija predstavlja varijablu *zalihe* koju uključujemo u daljnja razmatranja kod definiranja AOMP modela.

[144] Obrazac financijskog izvješća za zadruge ne vodi zasebnu evidenciju za sve kategorije dugotrajne materijalne imovine. Pet kategorija: *biološka imovina* (AOP 015), *predujmovi za materijalnu imovinu* (AOP 016), *materijalna imovina u pripremi* (AOP 017), *ostala materijalna imovina* (AOP 018) i *ulaganja u nekretnine* (AOP 019) nisu sastavni dio financijskog obrasca za zadruge.

Tablica 4.1. Opis sadržaja varijabli izvornog skupa za definiranje konačnog AOMP modela

	Početni podaci	AOP oznaka	Opis kategorije	Mjerna jedinica	Konačni podaci
			Ulazni podaci AOMP modela (INPUT varijable)		
1	Članovi		Fizička osoba koja sudjeluje u radu skupštine zadruge, posluje ili koristi usluge zadruge	Nº	Dionici
2	Zaposlenici		Fizička osoba koja sklapa ugovor o radu sa zadrugom	Nº	
3	Kooperanti		Fizička osoba koja sklapa ugovor o zajedničkoj proizvodnji sa zadrugom	Nº	
4	Materijalna imovina AOP010	AOP011	Zemljište	HRK	Dugotrajna imovina
		AOP012	Građevinski objekti	HRK	
		AOP013	Postrojenja i oprema	HRK	
		AOP014	Alati, pogonski inventar i transportna imovina	HRK	
5	Zalihe AOP038	AOP039	Sirovine i materijal	HRK	Zalihe
		AOP040	Proizvodnja u tijeku	HRK	
		AOP041	Gotovi proizvodi	HRK	
		AOP042	Trgovačka roba	HRK	
		AOP043	Predujmovi za zalihe	HRK	
		AOP044	Dugotrajna imovina namijenjena prodaji	HRK	
		AOP045	Biološka imovina	HRK	
6	Aktiva AOP065	AOP001	Potraživanja za upisani a neuplaćeni kapital	HRK	Aktiva
		AOP002	Dugotrajna imovina	HRK	
		AOP037	Kratkotrajna imovina	HRK	
		AOP064	Plaćeni troškovi budućeg razdoblja i obračunati prihodi	HRK	
			Izlazni podaci AOMP modela (OUTPUT varijable)		
7	Zadržana dobit	AOP082	Zadruga izdvaja i posebno evidentira najmanje 20% dobiti za razvoj i 5% u obvezne pričuve	HRK	Zadržana dobit
8	Ukupni prihodi AOP177	AOP125	Poslovni prihodi	HRK	Ukupni prihodi
		AOP154	Financijski prihodi	HRK	
		AOP173	Udio u dobiti od društava povezanih sudjelujućim interesom	HRK	
		AOP174	Udio u dobiti od zajedničkih pothvata	HRK	
9	Ukupni rashodi AOP178	AOP131	Poslovni rashodi	HRK	Ukupni rashodi
		AOP165	Financijski rashodi	HRK	
		AOP175	Udio u gubitku od društava povezanih sudjelujućim interesom	HRK	
		AOP176	Udio u gubitku od zajedničkih pothvata	HRK	

Izvor: Obrada autora godišnjeg obrasca financijskih izvješća FINA-e i Zakona o zadrugama (NN, br. 34/2011, 125/2013, 76/2014, 114/2018, 98/2019).

Varijabla *aktiva* pruža uvid u resurse od kojih zadružno poslovanje ostvaruje ekonomske koristi i uključuje četiri kategorije: *potraživanja za upisani a neuplaćeni kapital* (AOP001), *dugotrajna imovina* (AOP002), *kratkotrajna imovina* (AOP037), *obračunati prihod i plaćeni troškovi budućeg razdoblja* (AOP064). U financijskom izvještaju koji smo dobili od FINA-e navedene četiri kategorije su već bile zbrojene tako da je bilo nemoguće pratiti vrijednosti za svaku sastavnicu zaliha zasebno. Zbroj četiri AOP kategorije čini varijablu *aktiva* koju uključujemo u daljnja razmatranja kod definiranja konačnog AOMP modela.

Varijabla *zadržana dobit* je jedina stavka pasive koja se evidentira u godišnjim financijskim izvještajima za zadruge.[145] Ova varijabla predstavlja instrument provjere zakonskih obveza zadruga da izdvajaju najmanje 20% svoje dobiti za razvoj poslovanja i najmanje 5% dobiti u obvezne pričuve dok se ne dosegne ukupan iznos uloga svih članova (NN, br. 34/2011, 125/2013, 76/2014, 114/2018, 98/2019, članak 37). Varijabla *zadržana dobit* je uključena u daljnja razmatranja kod definiranja konačnog AOMP modela.

Posljednje dvije ekonomske varijable *ukupni prihodi* (AOP177) i *ukupni rashodi* (AOP178) čine osnovni dio Računa o dobiti i gubitku koji se uz bilancu redovito koristi u financijskim analizama radi dobivanja informacija o poslovnim aktivnostima poduzeća. Varijablu *ukupni prihodi* opisuju tri kategorije *poslovni prihodi* (AOP125), *financijski prihodi* (AOP154), *udio u dobiti od društava povezanih sudjelujućim interesom* (AOP173) i *udio u dobiti od zajedničkih pothvata* (AOP174). Slično time, varijablu *ukupni rashodi* opisuju tri kategorije *poslovni rashodi* (AOP131), *financijski rashodi* (AOP165), *udio u gubitku od društava povezanih sudjelujućim interesom* (AOP175) i *udio u gubitku od zajedničkih pothvata* (AOP176). U financijskom izvještaju koji smo dobili od FINA-e navedene kategorije su već bile zbrojene tako da je bilo nemoguće pratiti izvore prihoda i rashoda zasebno. Zbrajanjem relevantnih AOP kategorija dobivene su dvije ekonomske varijable *ukupni prihodi* i *ukupni rashodi* koje su uključene u razmatranja kod definiranja konačnog AOMP modela.

4.1.2. Određivanje broja ulaznih i izlaznih podataka u AOMP modelu

U definiranju konačnog AOMP modela koristili smo R-paket *Benchmarking* (Bogetoft i Otto, 2011) koji olakšava primjenu ove metode bez ograničavanja broja promjena u modelima i

[145] Zbog nepotpune evidencije o stavkama pasive nemoguće je utvrditi na koje načine se zadruge financiraju i koliko ukupnih ulaganja dolazi od strane zadruge i njenih članova (vlasnički kapital), a koliko od kooperanata i drugih vanjskih ulagača (obveze). Nepotpuna evidencija izaziva sumnje, pogoduje spekulacijama i nastavku nelegalnih aktivnosti koje u sektoru zadrugarstva sustavno započinju s procesom osamostaljenja RH (vidi potpoglavlje 2.5.2, str. 43).

proračunima. U Tablici 4.2. je prikazana opisna statistika za sve potencijalne varijable iz izvornog skupa ekonomskih pokazatelja. Sve varijable smo razmatrali kod konstruiranja konačnog AOMP modela za analizu efikasnosti poljoprivrednih zadruga. U nastavku je opisan postupak odabira ulaznih i izlaznih podataka za konačan AOMP model.

Tablica 4.2. Opisna statistika svih potencijalnih ekonomskih varijabli izvornog skupa (N = 23)

	Varijable	mean	med	min	max	S.D.
INPUTI	dionici	156,3	31	7	1.078	264,3507
	dugotrajna imovina	5.943.054	977.254	35.805	81.185.998	16.880.390
	zalihe	1.970.737	158.227	0	18.740.850	4.528.136
	aktiva	15.809.481	2.459.784	124.688	166.359.415	37.247.813
OUTPUTI	Zadržana dobit	1.222.631	120.523	1.713	4.980.049	1.744.637
	Ukupni prihodi	13.286.178	2.701.533	33.217	118.981.792	26.282.689
	Ukupni rashodi	13.180.758	2.631.165	12.121	118.518.659	26.194.882

mean = srednja vrijednost; **med** = medijana; **min** = minimalna i **max** = maksimalna vrijednost.
Izvor: Izračun autora na temelju službenih poslovnih podataka FINA-e (2009. - 2013.).

Razlike između srednjih vrijednosti i medijane jasno ukazuju na postojanje značajnih razlika između zadruga. U skupini ulaznih podataka razlike između zadruga su najviše izražene u kontekstu vrijednosti *dugotrajna imovina* (S.D. = 16.880.390) i *aktiva* (S.D. = 37.247.813) s kojom zadruge raspolažu. U skupini izlaznih podatka najveće razlike su vidljive u kontekstu *ukupni prihodi* (S.D. = 26.282.689) i *ukupni rashodi* (S.D. = 26.194.882) koje zadruge postižu u promatranom razdoblju. S druge strane, najveća ujednačenost podataka uočena je u kontekstu broja *dionici* (S.D. = 264,35) i vrijednosti ***zadržana dobiti*** (S.D. = 1.744.637).

U tablici 4.3. je prikaza matrica korelacije između potencijalnih varijabli izvornog skupa poslovnih pokazatelja. Između nekih pokazatelja je vidljiva jaka pozitivna korelacija koja ukazuje na mogućnost manjeg broja relevantnih varijabli. U skupini ulaznih podataka vidljiva je jaka korelacija između poslovnih varijabli *dugotrajna imovina*, *zalihe* i *aktiva*. To je logično za očekivati obzirom da tri navedene varijable čine sastavni dio aktive u bilanci poslovanja. Nadalje, u skupini izlaznih podataka jake korelacije su uočene između svih varijabli, a posebno između varijabli *ukupni prihodi* i *ukupni rashodi* (r = 0,999). Veza između dva izlazna podatka je vidljiva u tome što razlika između ukupnih prihoda i ukupnih rashoda definira visinu bruto dobiti, tj. određuje da li zadruge posluju s dobitkom ili gubitkom.

Tablica 4.3. Matrica korelacije između ulaznih i izlaznih varijabli poslovnih podataka

	INPUTI				OUTPUTI		
	Imovina	**Aktiva**	**Zalihe**	**Dionici**	**Zadržana dobit**	**Prihodi**	**Rashodi**
Imovina	**1,000**						
Aktiva	0,983 [c]	**1,000**					
Zalihe	0,887 [c]	0,922 [c]	**1,000**				
Dionici	-0,101	-0,074	-0,017	**1,000**			
Zadržana dobit	0,270	0,325	0,237	-0,169	**1,000**		
Prihodi	0,383 [a]	0,425 [b]	0,241	-0,106	0,867 [c]	**1,000**	
Rashodi	0,378 [a]	0,420 [b]	0,237	-0,104	0,867 [c]	0,999 [c]	**1,000**

[a] Potvrđena je statistička značajnost veze na razini od 10%, [b] na razini od 5% i [c] na razini od 1%.
Izvor: Izračun autora na temelju službenih poslovnih podataka FINA-e.

Ovako visoke korelacije ukazuju da različite poslovne varijable možda opisuju isti kriterij. U situacijama kada se istraživač susreće s visokim korelacijama između varijabli, Jenkins i Anderson (2003) sugeriraju statistički postupak koji može pomoći u odlučivanju koje izvorno korelirane varijable ostaviti odnosno ukloniti iz promatranog skupa podataka, a da se pritom ostvari najmanji gubitak informacija.[146] Njihov postupak daje dobru empirijsku osnovu za uklanjanje varijabli koje se ne mogu utvrditi subjektivnim promatranjem matrice korelacije i nasumičnim uklanjanjem jedne ili više jako koreliranih varijabli. Ovu metodu smo koristili za testiranje kako odabir ulaznih i izlaznih podataka utječe na robustnost modela da izdvaja i rangira efikasne poljoprivredne zadruge. Naše istraživanje je potvrdilo da uklanjanje jako koreliranih ekonomskih varijabli koje sadrže malo dodatnih informacija ne rezultira nužno preciznijim mjerenjem efikasnih zadruga. Upravo suprotno, različite kombinacije i uklanjanje varijabli koje sadrže više informacija i uzrokuju veći gubitak zadržane varijance značajno mijenjaju rezultate relativne efikasnosti.

U tablici 4.4. je prikazano kretanje vrijednosti mjera efikasnosti i zadržane varijance nakon uklanjanja pojedinih poslovnih pokazatelja iz izvornog skupa poslovnih podataka. Tako na primjer, uklanjanje pokazatelja *ukupni prihodi* ili *ukupni rashodi* koji donose beznačajnu količinu dodatnih informacija nema značajnog utjecaja na rezultate efikasnosti. U slučaju njihovog uklanjanja zadržava se čak 99,99% informacija, vrijednosti neefikasnih zadruga se

[146] Nakon što se izračuna matrica kovarijance provodi se postupak normalizacije podataka na način da srednja vrijednost svakog pokazatelja bude jednaka nula (0), a njegova varijanca jednaka jedan (1). Normaliziranjem varijance daje se jednaka važnost svakom pokazatelju i olakšava se nadziranje kretanja preostale varijance tijekom uklanjanja varijabli (eng. *residual variance*). Uklanjanje varijabli se temelji na proučavanju parcijalne korelacije (engl. *partial correlation*) koja se koristi kao mjera za količinu informacija sadržanih u zadržanim varijablama. Varijanca koja ostaje nakon izostavljanja varijabli mjeri da li zadržane varijable sadrže dovoljno informacija da bi predstavljale izvorne podatke. Njihovo istraživanje pokazuje da izostavljanje jako povezanih varijabli koje sadrže malo dodatnih informacija također mogu imati značajan utjecaj na izračunavanje mjera efikasnosti.

neznatno smanjuju, a iste poljoprivredne zadruge zadržavaju čistu tehničku (14 zadruga) i ukupnu tehničku efikasnost (7 zadruga) kao i prije odluke o njihovom uklanjanju.[147] S druge strane, uklanjanje varijable *zadržana dobit* dovodi do najvećeg gubitka varijance (-8,26%), ali se istodobno postiže najbolja robustnost modela koja je izražena u najmanjem broju zadruga koje postižu čistu tehničku (11 zadruga) i ukupnu tehničku efikasnost (3 zadruge). Ukupno je šest poljoprivrednih zadruga smanjilo BCC-učinkovitost (z1, z3, z4, z23, 24, z25) i trinaest zadruga je smanjilo CCR-učinkovitost (z1, z2, z3, z4, z5, z7, z11, z12, z20, z21, z23, z24, z25). Izostavljanjem varijable *zadržana dobit* objašnjeno je 91,74% varijance koju sadrže tri izlazne varijable i gubi se svega 0,248% ukupne varijance koju sadrži svih sedam varijabli (engl. *partial correlation*, *trace*). Nakon uklanjanja varijable *zadržana dobit* bilo je moguće provesti robustnije rangiranje uzorkovanih zadruga.

Isti postupak smo koristili i unutar skupine ulaznih varijabli. Vrijednost koeficijenta korelacije (r = 0,983) ukazuje da varijable *dugotrajna imovina* i *aktiva* možebitno opisuju isti kriterij. U slučaju izostavljanja varijable *dugotrajna imovina* zadržava se 99,25% informacija, dok se izostavljanjem varijable *aktiva* također objašnjava visoki postotak varijance koju opisuju četiri ulazne varijable (99,46%). Njihovo pojedinačno izostavljanje iz AOMP modela dovelo je do neznatnog smanjenja broja poljoprivrednih zadruga koje zadržavaju čistu tehničku (13 zadruga) i ukupnu tehničku efikasnost (6 zadruga).[148] Međutim, istodobno uklanjanje obje navedene varijable rezultiralo je značajnim padom čiste i ukupne tehničke efikasnosti kod velikog broja zadruga.[149] Također, analiza parcijalne korelacije (Jenkins i Anderson, 2003) je potvrdila da ako se želi zadržati više informacija (varijance) onda dvije navedene varijable predstavljaju najbolji izbor za uklanjanje. Isto tako, iz tablice 4.4. može se jasno vidjeti da uklanjanje varijable *zalihe* koja također jako korelira s ove dvije varijable dovodi do značajno većeg gubitka varijance koju opisuju četiri ulazne varijable (-3,45%), ali i ukupne varijance koju opisuju svih sedam varijabli izvornog skupa (-0,138%).

---

[147] Kada se uklonila varijabla *ukupni prihodi* samo tri zadruge su neznatno smanjile vrijednosti BCC neefikasnosti (z6, z9 i z25), dok je sedam zadruga neznatno smanjilo vrijednosti CCR neefikasnosti (z9, z11, z12, z21, z22, z25 i z26). Kada se uklonila varijabla *ukupni rashodi* samo dvije zadruge su neznatno smanjile vrijednosti BCC neefikasnosti (z1 i z17), dok je devet zadruga neznatno smanjilo vrijednosti CCR neefikasnosti (z1, z5, z6, z14, z16, z17, z20, z21 i z23).

[148] Kada se uklonila varijabla *dugotrajna imovina* samo četiri zadruge su smanjile vrijednosti BCC efikasnosti (z1, z20, z23 i z25), a deset zadruga je smanjilo vrijednosti CCR efikasnosti (z1, z5, z7, z11, z12, z17, z20, z21, z23 i z25). Kada se uklonila varijabla *aktiva* samo četiri zadruge su neznatno smanjile vrijednosti BCC efikasnosti (z3, z6, z9 i z17), a deset zadruga je smanjilo vrijednosti CCR efikasnosti (z3, z4, z5, z6, z9, z11, z12, z16, z17 i z21).

[149] Istodobno uklanjanje varijabli *dugotrajna imovina* i *aktiva* rezultiralo je znatnim padom vrijednosti rezultata efikasnosti, kao i ukupnog broja BCC i CCR-efikasnih zadruga. U odnosu na izvorni model sa sedam varijabli samo devet zadruga je ostvarilo čistu tehničku efikasnost (z2, z4, z5, z7, z10, z19, z21, z22 i z24) i samo dvije zadruge je ostvarilo ukupnu tehničku efikasnost (z10 i z19).

Na kraju je konstruiran AOMP model koji sadrži dvije ulazne varijable (*dionici* i *zalihe*) i dvije izlazne varijable (*ukupni prihodi* i *ukupni rashodi*). Konačan AOMP model omogućio nam je cjelovito rangiranje jedinica odlučivanja i pokazao da dvije zadruge postižu ukupnu tehničku (CCR) efikasnost, a pet zadruga postiže čistu tehničku (BCC) efikasnost. Dobiveni rezultati AOMP su detaljno obrazloženi u Raspravi za svaku godinu zasebno (vidi potpoglavlje 5.1., str. 140) i ukupno za cijelo promatrano razdoblje (vidi potpoglavlje 5.2. str. 142).

Tablica 4.4. Zadržana varijanca i mjere efikasnosti nakon uklanjanja varijabli

Broj inputa i outputa	7		6		6		6		6		6		6		6	
Uklonjena varijabla			Dionici		Dug imovina		Zalihe		Aktiva		Zadržana dobit		Ukupni prihodi		Ukupni rashodi	
Zadržana varijanca	100%		75,96%		99,25%		96,55%		99,46%		91,74%		99,99%		99,99%	
Parcijalna korelacija			0,9615033		0,0301824		0,1379588		0,0215804		0,2477226		0,0002385		0,0002385	
DMU	BCC	CCR	BCC	CCR	BCC	CCR	BCC	CCR	BCC	CCR	BCC	CCR	BCC	CCR	BCC	CCR
z1	0,811	0,669	0,811	0,669	0,710	0,607	0,754	0,661	0,811	0,669	0,768	0.638	0,811	0,669	0,781	0,636
z2	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	0,619	0,198	**1,000**	**1,000**	**1,000**	0.482	**1,000**	**1,000**	**1,000**	**1,000**
z3	**1,000**	0,990	**1,000**	0,990	**1,000**	0,990	**1,000**	0,990	0,870	0,539	0,463	0.090	**1,000**	0,990	**1,000**	0,990
z4	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	0,893	**1,000**	0,632	0,644	0.383	**1,000**	**1,000**	**1,000**	**1,000**
z5	**1,000**	0,381	**1,000**	0,381	**1,000**	0,376	**1,000**	0,381	**1,000**	0,343	**1,000**	0.360	**1,000**	0,381	**1,000**	0,374
z6	0,976	0,523	0,976	0,523	0,976	0,523	0,917	0,466	0,954	0,332	0,976	0.523	0,974	0,523	0,976	0,518
z7	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	0,954	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	0.725	**1,000**	**1,000**	**1,000**	**1,000**
z9	0,603	0,517	0,603	0,517	0,603	0,517	0,484	0,451	0,449	0,381	0,603	0.517	0,590	0,500	0,603	0,517
z10	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	0,112	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**
z11	0,542	0,147	0,243	0,147	0,542	0,146	0,542	0,135	0,542	0,105	0,542	0,108	0,542	0,146	0,542	0,147
z12	**1,000**	0,095	**1,000**	0,095	**1,000**	0,092	**1,000**	0,095	**1,000**	0,087	**1,000**	0,087	**1,000**	0,064	**1,000**	0,095
z13	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**
z14	0,776	0,590	0,617	0,590	0,776	0,590	0,776	0,204	0,776	0,590	0,776	0,590	0,776	0,590	0,776	0,539
z16	**1,000**	0,482	**1,000**	0,482	**1,000**	0,482	**1,000**	0,450	**1,000**	0,412	**1,000**	0,482	**1,000**	0,482	**1,000**	0,476
z17	0,281	0,268	0,281	0,268	0,281	0,269	0,281	0,223	0,226	0,216	0,281	0,268	0,281	0,268	0,278	0,265
z19	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**
z20	**1,000**	0,667	0,661	0,602	0,752	0,558	**1,000**	0,667	**1,000**	0,667	**1,000**	0,608	**1,000**	0,667	**1,000**	0,662
z21	**1,000**	0,599	**1,000**	0,598	**1,000**	0,418	**1,000**	0,517	**1,000**	0,598	**1,000**	0,598	**1,000**	0,598	**1,000**	0,591
z22	**1,000**	0,263	0,215	0,076	**1,000**	0,263	**1,000**	0,263	**1,000**	0,263	**1,000**	0,263	**1,000**	0,259	**1,000**	0,263
z23	0,740	0,470	0,710	0,420	0,721	0,254	0,714	0,437	0,740	0,470	0.600	0,385	0,740	0,470	0,740	0,468
z24	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	0.330	0,327	**1,000**	**1,000**	**1,000**	**1,000**
z25	0,629	0,593	0,626	0,592	0,484	0,460	0,522	0,505	0,629	0,593	0.593	0,568	0,621	0,572	0,629	0,593
z26	0,703	0,142	0,187	0,142	0,703	0,142	0,703	0,137	0,703	0,142	0.703	0,142	0,703	0,130	0,703	0,142
Efikasne DMU	**14**	**7**	**12**	**7**	**13**	**6**	**13**	**4**	**13**	**6**	**11**	**3**	**14**	**7**	**14**	**7**

Izvor: Izračun autora na temelju službenih poslovnih podataka FINA-e.

4.2. Konfirmatorna faktorska analiza stupnja usvojenosti zadružnih načela

4.2.1. Eksplorativna faktorska analiza usvojenosti zadružnih načela

Vrijednosti deskriptivne statistike za izvorni skup podataka od 29 pokazatelja se nalaze u prilogu (vidi Prilog 2. Deskriptivna analiza pokazatelja reduciranog skupa). Nad skupom podataka je provedena EFA analiza kako bi se pokazatelji saželi u manji broj komponenti i omogućila kvalitetnija analiza njihove međusobne linearne povezanosti. Kod izlučivanja latentnih faktora je korištena *metoda maksimalne vjerodostojnosti* i *pravokutna varimax rotacija faktora*.[150] U sažimanju izvornih pokazatelja na manji broj komponenti uvažili smo rezultate PCA analize i Kaiser-Gutmanovog kriterija koji predlažu sedam latentnih faktora sukladno teoriji zadružnih načela. Nasuprot njima, Hornova paralelna analiza (1965) je potvrdila značaj šest faktora.[151] Predloženi EFA model sa sedam latentnih faktora je prihvaćen kao prihvatljivo rješenje za mjerenje usvojenosti zadružnih načela i kao takav podliježe daljnjem ispitivanju konstruktne stabilnosti korištenjem CFA analize. Već i prije korištenja CFA analize vidljiva su mjesta u predloženom EFA modelu koja zahtijevaju preinake. U modelu sa sedam faktora Cronbach alfa koeficijenti su potvrdili prihvatljivu unutarnju konzistenciju skala za sve latentne faktore osim za načelo O*tvorenosti i dragovoljnosti* (Cronbach α_{F1} = 0,467). Neprihvatljivost ljestvice za mjerenje otvorenosti članstva potvrđuje povezanost njegova dva pokazatelja s faktorom koji nema sadržajnu poveznicu s njima.[152] Također, pokazatelj otvorenosti zadruga prema novim članovima bez obzira na spolnu, nacionalnu, političku ili vjersku pripadnost pojedinca (otvorenost3) nema značajno zasićenje na niti jednom od sedam faktora. U tablici 4.5. se nalaze faktorska

[150] *Maksimalna vjerodostojnost* (engl. *maximum likelihood method*) je metoda koja maksimizira vjerodostojnost. Metoda se može primijeniti na većini teorijskih distribucija i pod određenim uvjetima ima dobre statističke značajke kao što su *invarijantnost*, *konzistentnost* i *asimptotska nepristranost*. *Pravokutna varimax rotacija* pretpostavlja da faktori nisu međusobno povezani i kao takva predstavlja najučinkovitiju proceduru (Kline, 1994: 68). Prema Nunnallyu i Bernsteinu (1994) pametna značajka procedure je da se postupak rotacije primjenjuje na kvadriranim, a ne na stvarnim vrijednostima faktorskih opterećenja.

[151] Hornova paralelna analiza (1965) uspoređuje svojstvene vrijednosti faktora iz matrica korelacije stvarnih podataka i prosječne svojstvene vrijednosti faktora iz nasumično stvorenih matrica. Zadržavaju se faktori s većim vrijednostima, a pojava faktora s vrijednostima koje su jednake ili manje od prosječnih svojstvenih vrijednosti nasumično stvorenih matrica ukazuje na pogrešku uzorkovanja (Hayton i sur., 2004: 194). Iako se smatra jednom od najpreciznijih metoda ona je gotovo u potpunosti zanemarena od strane istraživača i rijetko se koristi u redukciji podataka i zadržavanju faktora.

[152] Pokazatelji održavanja trenutnog broja članova (otvorenost1) i poticanja ulaska novih članova od strane uprave (otvorenost2) sudjeluju u opisivanju faktora *Gospodarsko sudjelovanje* (Načelo 3).

zasićenja i komunaliteti pokazatelja u predloženom EFA modelu sa sedam (lijevo) i u EFA modelu sa šest faktora nakon uklanjanja pokazatelja *otvorenost3* (desno).[153]

U EFA modelu sa šest faktora pokazatelji su raspoređeni u skladu s teorijom zadružnih načela i objašnjavaju 52% ukupne varijance. Prvi faktor (**F1**) se sastoji od pet pokazatelja i opisuje zadružno načelo *Međuzadružna suradnja* (12%). Na drugom faktoru (**F2**) se nalazi pet pokazatelja koji opisuju načelo *Gospodarsko sudjelovanje* (10%). Treći faktor (**F3**) ima četiri pokazatelja koji opisuju načelo *Poslovna autonomija* (9%). Četvrti faktor (**F4**) opisuje načelo *Briga za lokalnu zajednicu* i sastoji se od četiri pokazatelja (9%). Slijedi faktor (**F5**) s četiri pokazatelja koji opisuju načelo *Zadružna edukacija* (6%) i na zadnjem mjestu je faktor (**F6**) s tri pokazatelja koji opisuju načelo *Demokratičnost poslovanja* (6%).

Slijedeći korak redukcije podataka i postupak preinaka predloženog EFA modela sa sedam faktora je objašnjen u sljedećem potpoglavlju (4.2.2.). Korištenjem CFA analize detaljnije su objašnjeni razlozi uklanjanja pokazatelja koji opisuje načelo *Otvorenosti i dragovoljnosti*. U nastavku je opisan cijeli postupak redukcije i uklanjanja 8 pokazatelja do konačnog CFA modela koji ima 6 latentnih faktora i sadrži 21 pokazatelj.

[153] *Komunaliteti* (h^2) pokazuju proporciju varijance svakog pokazatelja koji će biti objašnjena putem latentnih faktora. Više vrijednosti komunaliteta znače veći udio objašnjene varijance, bolje pristajanje pokazatelja i veću pouzdanost modela.

Tablica 4.5. Rezultati eksplorativne faktorske analize (model sa 7 i 6 faktora)

	Načelo 6 F1	Načelo 3 F2	Načelo 4 F3	Načelo 7 F4	Načelo 2 F5	Načelo 5 F6	F7	h^2 [a]	Cronbach alfa (α)
otvorenost1	-0,128	**0,657**	0,156	-0,113	-0,125	0,075	-0,058	0,51	
otvorenost2	0,183	**0,565**	0,148	0,130	0,059	0,082	-0,046	0,40	0,467
otvorenost3	0,019	0,244	0,013	0,165	-0,083	0,069	-0,068	0,10	
demokratičnost2	-0,003	-0,057	-0,209	-0,132	**0,590**	0,031	0,106	0,42	
demokratičnost3	0,041	-0,185	-0,017	0,012	**0,793**	0,015	0,029	0,67	0,656
demokratičnost5	-0,239	-0,238	0,135	-0,112	**0,564**	0,047	-0,117	0,48	
demokratičnost6	-0,070	-0,007	0,147	-0,216	0,318	0,012	**0,347**	0,29	
gospSurad1	0,125	**0,502**	0,085	-0,022	0,006	0,092	0,010	0,28	
gospSurad2	0,226	**0,544**	-0,038	0,227	0,039	-0,017	0,233	0,46	
gospSurad5	-0,016	**0,533**	0,095	0,089	-0,101	0,035	-0,262	0,38	0,707
gospSurad7	0,048	**0,640**	-0,117	0,071	-0,143	0,089	0,122	0,47	
gospSurad8	0,113	**0,653**	-0,032	0,168	-0,283	-0,014	0,049	0,55	
autonomija1	-0,115	0,079	**0,761**	-0,023	0,035	0,120	-0,144	0,64	
autonomija2	0,054	0,000	**0,692**	0,079	-0,092	-0,052	0,044	0,50	0,834
autonomija4	-0,043	0,088	**0,802**	-0,045	-0,001	-0,018	0,103	0,67	
autonomija5	0,110	0,077	**0,745**	0,061	0,001	-0,010	0,022	0,58	
edukacija1	**0,459**	0,097	-0,266	0,218	0,079	**0,555**	-0,144	0,67	
edukacija2	**0,438**	0,248	-0,112	0,149	0,088	**0,568**	0,016	0,62	0,794
edukacija3	**0,440**	0,144	-0,002	0,222	0,130	**0,684**	0,234	0,80	
edukacija4	0,144	0,169	0,344	-0,130	-0,057	**0,563**	-0,096	0,51	
zadSurad2	**0,729**	0,115	0,068	0,201	-0,073	0,122	0,027	0,61	
zadSurad3	**0,687**	0,247	-0,063	0,156	0,129	0,024	**-0,307**	0,67	
zadSurad4	**0,769**	0,032	0,015	0,065	-0,088	0,258	0,218	0,72	0,856
zadSurad6	**0,777**	-0,024	0,128	0,105	-0,118	0,117	-0,117	0,67	
zadSurad8	**0,567**	0,150	-0,090	0,316	-0,085	0,205	0,091	0,51	
brigaZajed1	0,288	0,167	0,131	**0,572**	0,029	-0,060	-0,176	0,49	
brigaZajed4	0,130	0,017	0,065	**0,712**	-0,089	0,107	-0,042	0,55	0,789
brigaZajed5	0,297	0,100	-0,091	**0,681**	-0,002	0,088	0,037	0,58	
brigaZajed6	0,047	0,164	0,009	**0,708**	-0,196	0,011	0,026	0,57	
SS zasićenja:	**3,555**	**2,877**	**2,684**	**2,354**	**1,676**	**1,633**	**0,614**		
Varijanca (%):	**12,26**	**9,92**	**9,25**	**8,12**	**5,78**	**5,63**	**2,12**		
Ukupna var. (%):	**12,26**	**22,18**	**31,43**	**39,55**	**45,33**	**50,96**	**53,08**		

	Načelo 6 F1	Načelo 3 F2	Načelo 4 F3	Načelo 7 F4	Načelo 5 F5	Načelo 2 F6	h^2 [a]	Cronbach alfa (α)
otvorenost1	-0,123	**0,661**	0,159	-0,114	0,044	-0,122	0,51	
otvorenost2	0,193	**0,577**	0,145	0,137	0,072	0,058	0,42	
demokratičnost2	-0,002	-0,054	-0,219	-0,123	0,053	**0,583**	0,41	
demokratičnost3	0,057	-0,175	-0,029	0,027	0,016	**0,795**	0,67	0,656
demokratičnost5	-0,202	-0,214	0,126	-0,100	-0,039	**0,583**	0,45	
demokratičnost6	-0,099	-0,024	0,139	-0,216	0,097	0,303	0,18	
gospSurad1	0,119	**0,509**	0,082	-0,020	0,104	0,000	0,29	
gospSurad2	0,189	**0,511**	-0,039	0,221	0,101	-0,001	0,36	
gospSurad5	0,016	**0,534**	0,096	0,095	-0,040	-0,100	0,32	0,780
gospSurad7	0,021	**0,623**	-0,115	0,066	0,148	-0,158	0,45	
gospSurad8	0,098	**0,650**	-0,033	0,169	0,027	-0,300	0,55	
autonomija1	-0,087	0,087	**0,754**	-0,028	0,043	0,053	0,59	
autonomija2	0,044	-0,002	**0,691**	0,081	-0,040	-0,089	0,50	0,834
autonomija4	-0,055	0,084	**0,800**	-0,046	-0,006	0,008	0,65	
autonomija5	0,105	0,077	**0,748**	0,063	-0,006	0,006	0,58	
edukacija1	**0,461**	0,099	-0,246	0,204	**0,506**	0,073	0,59	
edukacija2	**0,424**	0,239	-0,102	0,132	**0,578**	0,078	0,60	0,794
edukacija3	0,386	0,129	0,011	0,202	**0,770**	0,120	0,81	
edukacija4	0,146	0,185	0,351	-0,129	**0,479**	-0,027	0,43	
zadSurad2	**0,713**	0,105	0,068	0,200	0,182	-0,099	0,61	
zadSurad3	**0,699**	0,248	-0,065	0,171	0,000	0,101	0,59	
zadSurad4	**0,707**	0,020	0,020	0,065	0,364	-0,107	0,65	0,856
zadSurad6	**0,790**	-0,019	0,131	0,105	0,114	-0,132	0,68	
zadSurad8	**0,548**	0,135	-0,089	0,304	0,273	-0,111	0,51	
brigaZajed1	0,307	0,172	0,126	**0,576**	-0,071	0,013	0,48	
brigaZajed4	0,129	0,019	0,069	**0,708**	0,111	-0,098	0,55	0,789
brigaZajed5	0,279	0,086	-0,091	**0,674**	0,145	-0,029	0,57	
brigaZajed6	0,027	0,160	0,011	**0,713**	0,047	-0,209	0,58	
SS zasićenja:	**3,365**	**2,759**	**2,664**	**2,299**	**1,777**	**1,700**		
Varijanca (%):	**12,02**	**9,85**	**9,51**	**8,21**	**6,35**	**6,07**		
Ukupna var. (%):	**12,02**	**21,87**	**31,38**	**39,59**	**45,94**	**52,01**		

F1 = Međuzadružna suradnja, **F2** = Gospodarsko sudjelovanje, **F3** = Poslovna autonomija, **F4** = Briga za lokalnu zajednicu, **F5** = Zadružna edukacija i **F6** = Demokratičnost.
Metoda izlučivanja faktora: metoda maksimalne vjerodostojnosti (engl. *maximum likelihood method*).
[a] h^2 = objašnjenje varijance od strane latentnog faktora, u^2 = jedinstven (neobjašnjiv) dio varijance ($u^2 = 1 - h^2$).
Izvor: Izračun autora na temelju anketnih podataka.

4.2.2. Preinake EFA modela za mjerenje stupnja usvojenosti zadružnih načela

U potpoglavlju 3.6.2. je objašnjeno kako se provodi postupak preinake modela korištenjem MI indeksa i SEPC statistike. U skladu s teorijom zadružnih načela i uvažavanjem kriterija CFA analize, iz predloženog EFA modela sa 7 latentnih faktora i 29 pokazatelja je uklonjeno 8 pokazatelja. Zadržani pokazatelji su raspoređeni na 6 latentnih faktora koji se poklapaju sa zadružnim načelima. Kriteriji za skraćivanje modela su utvrđeni promatranjem vrijednosti MI i SEPC indeksa, standardiziranih reziduala i veličine njihovih učinaka.[154] Kao granica za uklanjanje pokazatelja bez statističkog značaja u početku smo koristili vrijednosti MI indeksa veće od 10, a u narednim pregledima razina granice je dodatno smanjena. Konačna odluka o uklanjanju pokazatelja s velikim vrijednostima MI indeksa je donesena korištenjem SEPC statistike i standardiziranih reziduala.[155] Tijekom reduciranja modela (engl. *model trimming*) uvažavala se teorijska osnova zadružnih načela. Utjecaj uklanjanja pokazatelja u modelu i kretanje razlika u vrijednostima MI indeksa prilagodbe su prikazane u Tablici 4.6.

Prvi korak redukcije modela. Tri pokazatelja *otvorenosti i dragovoljnosti članstva* nisu se pokazala prikladnim u opisivanju prvog zadružnog načela (N1). U prvom koraku je iz modela uklonjen pokazatelj *otvorenost3* zbog utjecaja na vrijednosti ostalih parametara, strukturne koeficijente i na odluke o uklanjanju drugih pokazatelja koji odgovaraju stvarnim podacima. Preostala dva pokazatelja otvorenosti (*otvorenost1* i *otvorenost2*) EFA je jako povezala s faktorom *Gospodarsko sudjelovanje* (F2-Načelo 3) zbog čega su dva pokazatelja zadržana. Također, ova povezanost ima smisla i ukazuje na otvorenost zadruga prema gospodarskoj suradnji koju ostvaruje s postojećim ili potencijalnim dionicima. Naše empirijsko istraživanje je preliminarnog karaktera i povezanost između otvorenosti i gospodarskog sudjelovanja može biti putokaz za kasnija istraživanja i kreiranje konačnih skala (ankete). Konačni CFA model ima šest, a ne sedam faktora koliko predlaže teorija zadružnih načela.[156] Tako je u

---

[154] Standardizirane rezidualne vrijednosti mogu se tumačiti kao z-vrijednosti zbog čega uobičajene razine statističke značajnosti koristimo kao praktične granične vrijednosti u interpretaciji. Apsolutne vrijednosti reziduala veće od 1,96 predstavljaju statistički značajne rezultate na razini značajnosti od 5%, a vrijednosti veće od 2,58 na razini od 1%.

[155] Standardizirane rezidualne vrijednosti predstavljaju udaljenost izraženu u broju standardnih devijacija između reziduala promatranog i zasićenog modela. Pozitivne vrijednosti standardiziranih reziduala ukazuju na potrebu uvođenja dodatnih parametra da bi se kvalitetnije objasnila kovarijanca između dva pokazatelja, dok negativne vrijednosti ukazuju da model precjenjuje promatranu kovarijancu. Ispitivanje indeksa prilagodbe i standardiziranih reziduala najčešće su korištene metode u vrednovanju i utvrđivanju izvora pogrešne specifikacije CFA modela (Brown, 2006: 115-124).

[156] Treći pokazatelj otvorenosti za sve zainteresirane bez obzira na inherentna obilježja i pripadnost pojedinaca obilježava slabije zasićenje (otvorenost3 = 0,244) i niski komunalitet (h^2 = 0,10). Preostala dva pokazatelja (otvorenost1 = 0,657 i otvorenost2 = 0,565) imaju značajna zasićenja i komunalitete na drugom faktoru (F2). Također, u opisivanju sedmog potencijalnog faktora mali značaj imaju i dva

prvom koraku skraćivanja modela zbog male veličine učinka u objašnjenju varijance početnog EFA modela 1.0. uklonjen pokazatelj *otvorenost3* (R^2 = 0,076).

Drugi korak. Uklonjen je šesti pokazatelj demokratičnosti tj. preuzimanja veće odgovornosti rukovodstva zadruge u cilju osiguravanja zajedničkih interesa (R^2 = 0,134).[157] Osim slabije veličine učinka, ovaj pokazatelj demokratičnosti zadružnog poslovanja obilježava i najveća vrijednost varijance reziduala (1,127) sa standardnom pogreškom procjene (0,119). Iz navedenih empirijskih razloga pokazatelj *demokratičnost6* je uklonjen iz modela 1.1.

Treći korak. Uklonjen je pokazatelj dobivanja informacija i usluga od strane jedinica lokalne samouprave (edukacija4) zbog sadržajno nepovezane, ali statistički značajne kovarijance koju ovaj pokazatelj ostvaruje s faktorom *Poslovna autonomija*. Indeksi prilagodbe i SEPC statistika su potvrdili da strukturu ove povezanosti EFA model ne može razumno i sadržajno objasniti (MI = 31,455; SEPC = 0,399). Pozitivne vrijednosti standardiziranih reziduala, na razini značajnosti od 1%, ukazuju na potrebu uvođenja dodatnih parametara (pokazatelja) ako se želi kvalitetnije objasniti njegova povezanost s preostalim pokazateljima autonomije. Njegova povezanost s faktorom *Briga za lokalnu zajednicu* (MI = 6,933) također ukazuje na problematično mjesto koje smanjuje pristajanje podataka (SEPC = -0,220). To je izraženo u kovarijanci koju *edukacija4* ostvaruje s pokazateljem ulaganja u edukacijske programe (brigaZajed5). Pretjerano naglašavanje ove povezanosti u CFA modelu potvrđuje vrijednost standardiziranog reziduala na razini značajnosti od 1% (MI = 10,649; SEPC = -0,161). Povezanost pokazatelja *edukacija4* s pokazateljem redovitog plaćanja obveza od strane članova (gospSurad2) predstavlja još jedno mjesto slabijeg pristajanja u EFA modelu (MI = 20,375; SEPC = -0,254). Međutim, iako je struktura ove povezanosti precijenjena vrijednost standardiziranog reziduala nije potvrdila njen značaj (-1,917). Potrebno je reći da pokazatelj *edukacija4* ima najveći broj značajnih standardiziranih reziduala na razini od 1%, najveću vrijednost varijance reziduala (1,064) sa standardnom pogreškom procjene (0,109) i najmanji učinak u modelu (R^2 = 0,173). Sve navedeno ukazuje na manji doprinos i slabiju preciznost relevantnog pokazatelja koji je povezan s tematski neusporedivim konstruktima. Zbog toga je pokazatelj *edukacija4* uklonjen iz modela 1.2.

---

pokazatelja (demokratičnost6 = 0,347 i zadSurad3 = -0,307) koji nisu sadržajno povezani s načelom otvorenosti i istodobno imaju višestruka zasićenja na nekoliko faktora.

[157] U EFA modelu sa sedam faktora šesti pokazatelj demokratičnosti ima niski komunalitet (h^2 = 0,29) i slabija višestruka zasićenja na faktoru *Otvorenost i dragovoljnost članstva* (0,347), *Briga za lokalnu zajednicu* (-0,216) i *Demokratičnost poslovanja* (0,318). Slični rezultati su dobiveni u modelu sa šest faktora i istim brojem pokazatelja gdje šesti pokazatelj demokratičnosti poslovanja ostvaruje još niža zasićenja (< 0,300) i niže vrijednosti komunaliteta (h^2 = 0,18).

Tablica 4.6. Rezultati pristajanja i ispitivanje razlika između potencijalnih CFA modela

	MODEL	χ^2 (df)	RMSEA (90% I.P.)	CFI	ECVI	AIC	Usporedba modela	$\Delta\chi^2$ (Δdf)	ΔRMSEA (90% I.P.)	ΔCFI	ΔECVI	ΔAIC
1.0	Početni EFA model	753,568 (362)	0,073 (0,066; 0,081)	0,825	4,453	15.151,307						
1.1	otvorenost3	727,592 (335)	0,076 (0,069; 0,084)	0,823	4,305	14.602,975	1.1 vs. 1.0	25,976 (27)	0,003 (0,003; 0,003)	0,002	0,148	548,332
1.2	demokratičnost6	691,915 (309)	0,078 (0,071; 0,086)	0,826	4,108	13.993,011	1.2 vs. 1.1	35,677 (26)	0,002 (0,002; 0,002)	0,003	0,197	609,964
1.3	literatura4	592,185 (284)	0,073 (0,065; 0,082)	0,853	3,595	13.396,722	1.3 vs. 1.2	99,73 (25)	0,005 (0,006; 0,004)	0,027	0,513	596,289
1.4	zadSurad6	459,309 (237)	0,068 (0,059; 0,077)	0,876	2,898	12.464,887	1.4 vs. 1.3	65,796 (23)	0,003 (0,003; 0,003)	0,010	0,345	500,214
1.5	zadSurad3	394,974 (215)	0,064 (0,054; 0,074)	0,892	2,559	11.872,695	1.5 vs. 1.4	64,335 (22)	0,004 (0,005; 0,003)	0,016	0,339	592,192
1.6	brigaZajed5	352,380 (194)	0,064 (0,053; 0,074)	0,897	2,329	11.342,108	1.6 vs. 1.5	42,594 (21)	0 (0,001; 0,000)	0,005	0,230	530,587
1.7	autonomija1	303,918 (174)	0,061 (0,049; 0,072)	0,907	2,069	10.875,177	1.7 vs. 1.6	48,462 (20)	0,003 (0,004; 0,002)	0,01	0,260	466,931
1.8	gospSurad2	274,414 (155)	0,062 (0,050; 0,074)	0,910	1,903	10.355,499	1.8 vs. 1.7	29,504 (19)	0,001 (0,001; 0,002)	0,003	0,166	519,678
2.0	brigaZajed4 ~~ brigaZajed6	231,667 (136)	0,059 (0,046; 0,072)	0,924	1,682	9.826,500	2.0 vs. 1.8	4,537 [a] (1)	0,001 (0,001; 0,001)	0,004	0,019	3,965
3.0	demokratičnost2 ~~ demokratičnost3	228,602 (135)	0,059 (0,045; 0,071)	0,926	1,676	9.825,435	3.0 vs. 2.0	7,630 [a] (1)	0 (0,001; 0,001)	0,002	0,006	1,065

[a] Postojanje i značajnost razlika između ugniježdenih modela ispitana je Satorra-Bentlerovim testom (2010): $p < 0,001$.
Izvor: Izračun autora na temelju anketnih podataka.

Četvrti korak. Uklonjen je pokazatelj suradnje s relevantnim institucijama za zaštitu okoliša (*zadSurad6*). Razlog tome je što EFA model ne može prikladno objasniti strukturu statistički značajne kovarijance koju pokazatelj *zadSurad6* dijeli s faktorima *Zadružna edukacija* (MI = 10,175; SEPC = -0,322) i *Gospodarsko sudjelovanje* (MI = 5,099; SEPC = -0,143). Vrijednosti standardiziranih reziduala ukazuju na pretjerano naglašavanje povezanosti s varijablama odlaska na edukacijske radionice koje organiziraju HZCP (zadSurad2 = -3,317) i nadležna ministarstava (zadSurad4 = -3,037), kao i povezanosti s pokazateljem iznošenja poslovnih ideja i uvažavanje mišljenja Skupštine (gospSurad7 = -3,378). S druge strane, vrijednosti MI i SEPC statistike predlažu dodavanje parametara ako se želi bolje objasniti struktura povezanosti pokazatelja *zadSurad6* s faktorom *Poslovna autonomija* (MI = 4,058; SEPC = 0,112). Isto vrijedi za objašnjenje njegove povezanosti s pokazateljima zadržavanja neovisnosti tijekom suradnje s financijskim institucijama (autonomija2 = 2,335) i nadležnim Ministarstvima (autonomija5 = 2,852). Kovarijance nemaju praktičnu podlogu koja bi slijedila teoriju zadružnih načela zbog čega je varijabla *zadSurad6* uklonjena iz modela 1.3. Tome u prilog ide i veliki broj standardiziranih reziduala na razini značajnosti od 1%.

Peti korak. Pokazatelj zadružne suradnje s kreditnim unijama (*zadSurad3*) je uklonjen iz modela zbog višestruke povezanosti s većim brojem pokazatelja čija je struktura sadržajno neprihvatljiva.[158] Indeksi prilagodbe ukazuju da EFA model precjenjuje njegovu povezanost s pokazateljem sudjelovanja na radionicama pod pokroviteljstvom Ministarstva (edukacija3, MI = 13,456; SEPC = -0,142). Nasuprot tome, predloženi model slabije procjenjuje strukturu njegove povezanosti s pokazateljem održavanja poslovne stabilnosti upotrebom unutrašnjih pravilnika (demokratičnost3, MI = 9,451; SEPC = 0,144) i pokazateljem novčanih izdvajanja za zdravstveno osiguranje (brigaZajed1, MI = 9,965; SEPC = 0,149). Navedene empirijske prijedloge potvrđuju i vrijednosti standardiziranih reziduala na razini značajnosti od 1%. Iako instrumentarij sadrži općenita pitanja za mjerenje konstrukata (faktora), kovarijance nemaju dobru teorijsku podlogu za donošenje ispravnih zaključaka. Treba napomenuti da najveća varijanca reziduala (0,958) s najvećom standardnom pogreškom procjene (0,108) ukazuje na slabiju preciznost pokazatelja u opisivanju varijance modela putem prediktivnih odnosa s latentnim faktorom. Iz navedenih razloga treći pokazatelj suradnje zadruga s financijskim institucijama (*zadSurad3*) je uklonjen iz modela 1.4.

Šesti korak. Vodeći se načelom parsimonije iz modela je uklonjen pokazatelj brige zadruge za blagostanje članova (*brigaZajed5*). Ovaj pokazatelj ima višestruke korelacije s faktorima

[158] Deskriptivna analiza je pokazala da uzorkovane zadruge rijetko surađuju s kreditnim unijama, dok odgovori ispitanika imaju najveća odstupanja od srednje vrijednosti (x = 2,08; SD = 1,29). Prema podacima HNB (2020) u Hrvatskoj je trenutno aktivno 18 kreditnih unija od kojih 4 djeluje na području uzorkovanih županija (stanje na datum 17. studenog 2020.).

s kojima nije sadržajno povezan. Strukturu povezanosti s faktorima *Zadružna edukacija* (MI = 11,688; SEPC = 0,251) i *Međuzadružna suradnja* (MI = 10,927; SEPC = 0,271) je moguće kvalitetnije objasniti ako se u model doda još novih parametara. Rezultati su pokazali da je povezanost pokazatelja *brigaZajed5* s faktorom *Poslovna autonomija* značajno precijenjena (MI = 5,779; SEPC = -0,148). Empirijske vrijednosti indeksa prilagodbe (MI = 10,329; SEPC = 0,132) i standardiziranih reziduala potvrđuju da model slabije objašnjava povezanost s pokazateljem sudjelovanja predstavništva zadruge na zadružnim skupovima (zadSurad8 = 3,966). Isto tako, predloženi model pretjerano naglašava korelaciju pokazatelja *brigaZajed5* s pokazateljima održavanje autonomije u suradnji sa zadrugama (autonomija1 = -2,657) i resornim ministarstvima (autonomija5 = -2,296). Navedeni empirijski prijedlozi nisu u skladu s teorijom zadružnih načela zbog čega je pokazatelj *brigaZajed5* uklonjen iz modela 1.5.

Sedmi korak. Zbog nedostatka praktične primjene iz predloženog EFA modela je uklonjen pokazatelj zadržavanja neovisnosti tijekom suradnje s lokalnim zadrugama (*autonomija1*). Struktura povezanosti pokazatelja *autonomija1* s pokazateljem suradnje s Ministarstvima nadležnim za razvoj zadružnog poduzetništva (zadSurad4, MI = 14,020; SEPC = -0,142) i pokazateljem osiguranja zajedničkog vlasništva je pretjerano naglašena (demokraticnost5, MI = 6,884; SEPC = -0,116). Na ova problematična mjesta u modelu ukazuju i vrijednosti standardiziranih reziduala na razini značajnosti od 1%. Model nejasno objašnjava i strukturu povezanosti pokazatelja *autonomija1* s pokazateljem korištenja informacija i usluga HZCP (*edukacija2*), a vrijednosti indeksa prilagodbe predlažu dodavanje novih parametara u cilju boljeg pristajanja i objašnjenja korelacije (MI = 5,774; SEPC = 0,087). Ova mjesta u strukturi modela opisuju kovarijance koje su sadržajno nepovezane i neopravdane. Zbog navedenih razloga pokazatelj *autonomija1* je uklonjen iz modela 1.6.

Osmi korak. Iz modela je uklonjen pokazatelj plaćanja obveza radi održivosti zadružnog poslovanja (*gospSurad2*). Analiza je potvrdila značajnu količinu kovarijance koja povezuje pokazatelj *gospSurad2* s faktorima *Međuzadružna suradnja* (MI = 8,433; SEPC = 0,222) i *Zadružna edukacija* (MI = 7,816; SEPC = 0,206), Međutim, struktura njihove povezanosti je nejasno i nepotpuno objašnjena. Mjesta slabijeg pristajanja u modelu potvrđena su na razini značajnosti od 1% kod povezanosti pokazatelja *gospSurad2* s pokazateljem sudjelovanja predstavništva u razmjeni znanja na zadružnim skupovima (zadSurad8 = 3,344), tj. na razini od 5% kada govorimo o povezanosti pokazatelja *gospSurad2* s pokazateljima održavanja edukacijskih radionica u organizaciji HZCP (edukacija2 = 2,408) i nadležnih Ministarstava (edukacija3 = 2,027). Vrijednosti standardiziranih reziduala ukazuju na slabije objašnjenje povezanosti pokazatelja *gospSurad2* s pokazateljima upotrebe unutrašnjih pravilnika u cilju osiguranja poslovne stabilnosti zadruge (demokratičnost3 = 2,390) i provođenja zajedničkih interesa (demokratičnost5 = 2,829). Iako ovi empirijski prijedlozi sugeriraju da će uvođenje

dodatnih pokazatelja (parametara) jasnije objasniti strukturu navedenih korelacija i ukupnu varijancu modela, radi se o sadržajno nepovezanim strukturama. Zbog toga je pokazatelj *gospSurad2* uklonjen iz modela 1.7.

Nakon što smo u osam koraka napravili preinake modela korištenjem MI indeksa prilagodbe i SEPC statistike konstruiran je konačan CFA model (Model 1.8) koji je u skladu s teorijom zadružnih načela. Na temelju ovog modela je napravljena konačna interpretacija podataka o stupnju usvojenosti zadružnih načela (vidi potpoglavlje 5.3.).

4.2.3. Mogućnosti poboljšanja CFA modela uvažavanjem kovarijance varijabli

Daljnjim ispitivanjem mogućnosti prilagodbe i strukturnih razlika CFA modela uočeno je da između pokazatelja brige za zaštitu okoliša (*brigaZajed4*) i uvođenja inovativnih tehnologija proizvodnje (*brigaZajed6*) postoji značajna količina varijance koja nije najbolje objašnjena u CFA modelu (Model 1.8). Isto vrijedi i za odnos između pokazatelja načina poslovanja koji osigurava provođenje interesa članova (*demokratičnost2*) i upotrebe unutrašnjih pravilnika u cilju osiguranja poslovne stabilnosti (*demokratičnost3*). U dva dodatna koraka ispitali smo kako dva potencijalna modela (Model 2.0 i Model 3.0) pristaju empirijskim podacima. Zbog sadržajne sličnosti između pokazatelja demokratičnosti i sličnosti između pokazatelja brige za lokalnu zajednicu dopustili smo povezanost između njihovih varijanci reziduala. Dobiveni modeli 2.0 i 3.0 postižu kvalitetnije pristajanje podataka (vidi Tablicu 4.6., str. 115).[159]

Međutim, prihvatljivo pristajanje dva potencijalna modela i sposobnost ponavljanja rezultata u drugim uzorcima je potvrđena i prije povezivanja varijanci reziduala ovih pokazatelja zbog čega je u narednim analizama korišten jednostavniji model koji postiže bolju parsimoniju podatka (Model 1.8). Ako između pokazatelja demokratičnosti i brige za lokalnu zajednicu uistinu postoji značajna povezanost potrebno je provesti dodatne provjere i analize putem longitudinalnih istraživanja. U protivnom dopuštanje povezivanja pogreški mjerenja u cilju poboljšanja kvalitete pristajanja modela rezultirati će gubitkom svrhovitosti CFA metode u potvrđivanju rezultata i dovesti do njenog metodološkog povratka u otkrivačku (EFA) fazu istraživanja. Prema Andersonu i Gerbingu (1988) povezivanje pogreški mjerenja dovodi do prikrivanja stvarne strukture, gubitka logike interpretabilnosti i teorijske smislenosti modela.

[159] Korištenjem Satorra-Bentlerovog testa (2010) za uspoređivanje ugniježdenih modela i robusnih procjenitelja je potvrđeno da kompleksniji modeli (Model 2.0 i Model 3.0) koji omogućuju kovarijancu između pokazatelja brige za zajednicu (MI = 5,019; SEPC = 0,268) i pokazatelja demokratičnosti poslovanja (MI = 1,929; SEPC = 0,119) uklapaju podatke značajno bolje od jednostavnijeg modela u kojem su relevantni pokazatelji međusobno neovisni (Model 1.8).

4.2.4. Ispitivanje razina robustnosti (invarijantnosti) CFA modela

U potpoglavlju 3.6.3. (str. 85) je objašnjena pozadina i razlozi ispitivanja razina robustnosti (invarijantnosti) konačnog modela za mjerenje stupnja usvojenosti zadružnih načela. Nakon što smo u prethodnom koraku napravili preinake modela, uzorak je podijeljen u više skupina obzirom na sociodemografske karakteristike ispitanika. Provedena je CFA analiza na svakoj od podskupini ispitanika (engl. *multi-group CFA*). To je napravljeno kako bi se provjerila robustnost konačnog modela 1.8 na različitim razinama i potvrdilo da li se novo formirane mjerne skale za ispitivanje stupnja usvojenosti zadružnih načela mogu koristiti na različitim skupinama ispitanika. U tablici 4.7. (str. 120) su prikazani indeksi slaganja i robustnost svih hijerarhijskih modela obzirom na socioekonomska obilježja ispitanika. Rezultati slaganja hijerarhijskih modela ukazuju da skale ostvaruju različite razine invarijantnosti. Glavni cilj mjerenja nije ispitivanje razlika po skupinama nego utvrđivanje stabilnosti strukture modela prije ulaska u završnu fazu našeg empirijskog istraživanja i provođenja Metode potencijala. Zbog male veličine uzorka i neujednačenog broja ispitanika unutar skupina svi hijerarhijski modeli imaju neprihvatljive indekse slaganja i ne zadovoljavaju preduvjet dobrog pristajanja.

Prva i druga razina invarijantnosti. Mjerenje je potvrdilo da konačan CFA model postiže *invarijantnost konfiguracije* (Razina 1) i *invarijantnost faktorskih zasićenja* (Razina 2) bez obzira na socioekonomske karakteristike ispitanika. Time je potvrđeno da isti pokazatelji sudjeluju u opisivanju istih faktora u svim skupinama (Razina 1), odnosno da je mjerenje faktora identično zbog čega je moguće uspoređivati odnose između faktora i pokazatelja po skupinama (Razina 2). Raspon kretanja vrijednosti indeksa slaganja je unutar preporučenih granica (ΔCFI ≤ 0,01; ΔNCI ≤ 0,02 i ΔGH ≤ 0,01). Hi-kvadrat test nije potvrdio pad u slaganju sa stvarnim podacima obzirom na zahtjeve *invarijantnosti konfiguracije modela* i *faktorskih zasićenja* po svim kategorijama socioekonomskih obilježja. Iznimka je pokazatelj uzimanja zemljišta u zakup gdje zasićenja jednog ili više pokazatelja odstupaju.[160] Iz toga možemo zaključiti da između skupina ispitanika koji uzimaju i ne uzimaju zemlju u zakup nije moguća usporedba odnosa između faktora i pokazatelja, odnosno između skupina postoji drugačija percepcija faktora. Usporedba je moguća obzirom na ostala socioekonomska obilježja.

[160] Hi-kvadrat statistika nije potvrdila invarijantnost faktorskih zasićenja između poljoprivrednika koji imaju odnosno nemaju zakupljeno zemljište ($\Delta\chi^2(13) = 23{,}197$; $p = 0{,}04$). S druge strane, raspon kretanja indeksa slaganja ukazuje na invarijantnost metrike modela i opravdava njihovu usporedbu (ΔCFI = 0,007; ΔNCI = 0,018 i ΔGH = 0,005). Obzirom na osjetljivost hi-kvadrat testa na veličinu uzorka možemo kazati da je ograničenje jednakih faktorskih zasićenja ipak održivo, a postavljanjem uvjeta djelomičnih zahtjeva (engl. *partial invariance*) biti će moguće utvrditi izvore varijantnosti.

Tablica 4.7. Mjerenje robustnosti modela obzirom na socioekonomska obilježja ispitanika

Pokazatelj	Kategorije odgovora	N	Razina modela	χ^2	df	$\Delta\chi^2$	Δdf	CFI	ΔCFI	NCI	ΔNCI	GH	ΔGH
	Ukupan uzorak	202	Konačan model 1.8	237,632	137			0,920		0,780		0,950	
dob	mladi poljoprivrednici (manje od 45 godina)	70	Invarijantnost strukture	503,087	274			0,837		0,567		0,893	
			Invarijantnost zasićenja	511,133	287	8,046	13	0,840	0,003	0,574	0,007	0,895	0,002
	stariji poljoprivrednici (više od 45 godina)	132	Invarijantnost intercepta	515,542	300	4,409	13	0,847	0,007	0,587	0,013	0,899	0,004
			Invarijantnost reziduala	541,772	319	26,230	19	0,841	0,006	0,576	0,011	0,896	0,001
vrsta članstva	članovi zadruge	162	Invarijantnost strukture	474,332	274			0,856		0,609		0,905	
			Invarijantnost zasićenja	493,839	287	19,507	13	0,851	0,005	0,599	0,010	0,902	0,003
	nečlanovi zadruge (zaposleni i kooperanti)	40	Invarijantnost intercepta	520,979	300	27,140 [a]	13	0,841	0,010	0,579	0,020	0,896	0,006
			Invarijantnost reziduala	586,272	319	65,293 [b]	19	0,807	0,034	0,516	0,063	0,885	0,011
veličina zemljišta	manje od 5 hektara	76	Invarijantnost strukture	437,417	274			0,879		0,667		0,921	
			Invarijantnost zasićenja	455,616	287	18,199	13	0,875	0,004	0,659	0,008	0,919	0,002
	više od 5 hektara	126	Invarijantnost intercepta	482,324	300	26,708 [a]	13	0,865	0,010	0,637	0,022	0,913	0,006
			Invarijantnost reziduala	521,809	319	39,485 [b]	19	0,850	0,015	0,605	0,032	0,906	0,007
aktivnost	manje od 10 godina	80	Invarijantnost strukture	448,885	274			0,870		0,649		0,916	
			Invarijantnost zasićenja	464,428	287	15,543	13	0,868	0,002	0,645	0,004	0,915	0,001
	više od 10 godina	122	Invarijantnost intercepta	481,336	300	16,908	13	0,866	0,002	0,638	0,007	0,913	0,002
			Invarijantnost reziduala	513,478	319	32,142 [a]	19	0,856	0,010	0,618	0,020	0,912	0,001
prihodi u poljoprivredi	manje od 100.000 kn	128	Invarijantnost strukture	435,076	274			0,880		0,671		0,922	
			Invarijantnost zasićenja	452,797	287	17,721	13	0,877	0,003	0,663	0,008	0,920	0,002
	više od 100.000 kn	74	Invarijantnost intercepta	488,094	300	35,297 [b]	13	0,860	0,017	0,628	0,035	0,910	0,010
			Invarijantnost reziduala	514,528	319	26,434	19	0,855	0,005	0,616	0,012	0,908	0,002
zakupljeno zemljište	nemam zemlju u zakupu	112	Invarijantnost strukture	409,020	274			0,899		0,716		0,934	
			Invarijantnost zasićenja	432,217	287	23,197 [a]	13	0,892	0,007	0,698	0,018	0,929	0,005
	imam zemlju u zakupu	90	Invarijantnost intercepta	456,473	300	24,256 [a]	13	0,883	0,009	0,679	0,019	0,924	0,005
			Invarijantnost reziduala	504,615	319	48,142 [b]	19	0,861	0,022	0,632	0,047	0,924	0

[a] $p < 0,05$; b $p < 0,01$

Izvor: Izračun autora na temelju anketnih podataka.

Treća razina invarijantnosti. Mjerenje je potvrdilo da se podrijetlo korištene mjerne skale ne razlikuje po skupinama, odnosno da one imaju istu operativnu svrhu i interval u mjerenju usvojenosti zadružnih načela po skupinama. Time je opravdan značaj, mjerenje i usporedba srednjih vrijednosti latentnih faktora po skupinama. Uspoređivanje faktorskih vrijednosti nije moguće jedino obzirom na pokazatelje veličine zemljišta i visinu prihoda od poljoprivredne proizvodnje. Promjene vrijednosti indeksa slaganja i hi-kvadrat test pokazuje na značajne razlike u vrijednostima *intercepta pokazatelja* između skupina poljoprivrednika koji ostvaruju manje ili više od 100.000 kuna prihoda (ΔCFI = 0,017; ΔNCI = 0,035; ΔGH = 0,010 i $\Delta\chi^2(13) = 35,297$; $p < 0,001$), tj. između skupina ispitanika koji posjeduju manje ili više od 5 hektara vlastitog zemljišta (ΔCFI = 0,010; ΔNCI = 0,022; ΔGH = 0,006 i $\Delta\chi^2(13) = 26,708$; $p = 0,014$). Usporedba faktorskih vrijednosti nije moguća niti obzirom na pokazatelj vrsta članstva. Iako se promjene indeksa slaganja nalaze na granici prihvatljivosti (ΔCFI = 0,010; ΔNCI = 0,020 i ΔGH = 0,006), hi-kvadrat test potvrđuje da zahtjev *invarijantnost intercepta pokazatelja* ipak dovodi do značajnog pada pristajanja podataka obzirom na članstvo ($\Delta\chi^2(13) = 27,140$; $p = 0,012$). To potvrđuje da barem jedan intercept u CFA modelu slobodno odstupa između članova, kooperanata i zaposlenika zadruge. Uspoređivanje srednjih faktorskih vrijednosti između skupina članova i nečlanova moguće je postići postavljanjem djelomičnih zahtjeva invarijantnosti (vidi potpoglavlje 4.2.5.). Nasuprot tome, usporedba srednjih vrijednosti po skupinama je moguća obzirom na dob ispitanika, dužinu aktivnog bavljenja poljoprivrednom proizvodnjom i uzimanje zemljišta u zakup.

Četvrta razina invarijantnosti. Mjerenje je potvrdilo da CFA model postiže *invarijantnost varijance reziduala* obzirom na dob ispitanika i dužinu aktivnog bavljenja poljoprivrednom proizvodnjom. Ovaj zahtjev invarijantnosti ukazuje da navedene skupine ispitanika opisuju faktore sa sličnim stupnjem pogreške bez obzira radi li se o mlađim ili starijim ispitanicima, tj. bave li se oni poljoprivrednom proizvodnjom manje ili više od 10 godina. Raspon kretanja vrijednosti indeksa slaganja (ΔCFI = 0,006; ΔNCI = 0,011; ΔGH = 0,003) i hi-kvadrat test su potvrdili da su varijance reziduala u dvije dobne skupine ispitanika podjednake ($\Delta\chi^2(19) = 26,230$; $p = 0,124$). Nešto drugačija situacija je kada uspoređujemo *invarijantnost varijance reziduala* obzirom na dužinu aktivnog bavljenja poljoprivrednom proizvodnjom. Raspon kretanja vrijednosti indeksa slaganja ukazuje da su varijance reziduala približno jednake (ΔCFI = 0,010; ΔNCI = 0,020 i ΔGH = 0,005), međutim hi-kvadrat statistika ipak ukazuje na postojanje značajnih razlika u mjerenju pogrešaka između ispitanika koji se poljoprivredom bave manje tj. više od 10 godina ($\Delta\chi^2(19) = 32,142$; $p = 0,03$). Postavljanjem djelomičnih

zahtjeva invarijantnosti biti će moguće preciznije utvrditi reziduale pokazatelja koji odstupaju po skupinama obzirom na profesionalno iskustvo poljoprivrednika (potpoglavlje 4.2.5.).[161]

Iznesene rezultate treba uzeti s oprezom budući da niti jedan ugniježdeni hijerarhijski model ne zadovoljava osnovni preduvjet prihvatljivog pristajanja i ispitivanje se provodi na malom uzorku i skupinama s neujednačenim brojem jedinki.[162] To može uvelike utjecati na kretanje vrijednosti indeksa slaganja i odbacivanje pretpostavki hi-kvadrat statistike da hijerarhijski modeli postižu određenu invarijantnost. Mjerenjem smo htjeli dodatno utvrditi potencijalnu stabilnost CFA modela čiju strukturu konstrukata i vjerodostojnost dobivenih rezultata treba provjeriti povećanjem veličine uzorka, te novim prostornim i longitudinalnim istraživanjima.

4.2.5. Ispitivanje robustnosti CFA modela nametanjem djelomičnih zahtjeva

U prethodnom koraku smo postavljanjem više zahtjeva invarijantnosti utvrdili da usporedba faktorskih vrijednosti nije moguća između skupina ispitanika s određenim socioekonomskim obilježjima. Ovdje nastavljamo s ispitivanjem robustnosti modela nametanjem djelomičnih zahtjeva koji omogućuju usporedbu rezultata između različitih skupina ispitanika. Faktorske vrijednosti i rezultate modela je moguće uspoređivati ako se uklone zahtjevi invarijantnosti nad onim parametrima koji stvaraju razlike između faktora i zbog kojih je nemoguće provesti usporedbu. Istodobno se nad ostalim parametrima koje možemo uspoređivati zadržavaju zahtjevi invarijantnosti. Na taj način se parametrima koji uzrokuju varijantnost dopušta odstupanje po skupinama. Postavljanjem ovakvih djelomičnih zahtjeva moguće je precizno utvrditi koja faktorska zasićenja, intercepti pokazatelja i vrijednosti reziduala odstupaju po skupinama (engl. *partial invariance measurement*). Analiza je vezana uz gornju Tablicu 4.7.

Hi-kvadrat test i indeksi slaganja su potvrdili da na razini *invarijantnost faktorskih zasićenja* (**Razina 2**) postoje značajna odstupanja i razlike u opisivanju odnosa faktora i pokazatelja kod skupine ispitanika koji imaju i skupine ispitanika koji nemaju zakupljeno zemljište. Zbog toga nije moguće uspoređivati njihove odgovore u opisivanju faktora (usvojenosti zadružnih načela). Međutim, ako dopustimo da vrijednosti faktorskih zasićenja slobodno odstupaju

[161] Osnovna pretpostavka o savršenom pristajanju modela, osjetljivost na veličinu uzorka, odstupanja od normalne razdiobe i nedostatak kompatibilnosti često dovode do odbacivanja modela zbog čega bi hi-kvadrat statistiku trebalo više koristiti kao mjeru, a ne kao test za utvrđivanje pristajanja (Milfont i Fischer, 2010: 117). U situacijama kada se rezultati dva pristupa ne podudaraju potrebno je prikazati sve argumente koji govore za i protiv mjerenja invarijantnosti budući da hi-kvadrat test i indeksi mogu biti korisni, ali ne i zamjena za prosudbu i stručnost istraživača (Chen i sur., 2005: 488).

[162] Indeksi slaganja (CFI, NCI i GHI) ugniježdenih modela s dodatnim zahtjevima su ispod minimalnih standardnih vrijednosti (vidi potpoglavlje 3.6.5., str. 86).

unutar dvije navedene skupine ispitanika moguće je provesti analizu rezultata. Utvrđeno je da se skupina poljoprivrednika koja ima zakupljeno zemljište ($\bar{x}$ = 3,92; SD = 0,84; 0,813; z = 5,315; p = 0) u većoj mjeri slaže da korištenje usluga Ministarstava (autonomija5) nema veliki utjecaj na ograničenje mogućnosti poslovanja u odnosu na skupinu poljoprivrednika koji nemaju zakupljeno zemljište. Poljoprivrednici bez zakupljenog zemljišta u većoj mjeri smatraju da suradnja s nadležnim Ministarstvima ograničava poslovne mogućnosti zadruga ($\bar{x}$ = 4,07; SD = 0,90; 1,249; z = 7,007; p = 0).

Hi-kvadrat test i indeksi slaganja potvrđuju da na razini *invarijantnost intercepta pokazatelja* (**Razina 3**) postoje velika odstupanja i razlike kada govorimo o podrijetlu mjerne skale kod skupina ispitanika koji se razlikuju obzirom na veličinu vlastitog zemljišta i visinu novčanih prihoda koje ostvaruju u poljoprivrednoj proizvodnji. Vrijednosti njihovih faktora je moguće uspoređivati ako dopustimo da vrijednosti intercepta pokazatelja odstupaju između navedenih skupina. Tako je utvrđeno da skupina poljoprivrednika koji posjeduju manje od 5 hektara zemljišta ($\bar{x}$ = 2,54; SD = 0,97; 2,539; z = 21,819; p = 0) u većoj mjeri smatraju da unutrašnji pravilnici osiguravaju poslovnu stabilnost zadruga (demokratičnost3) u odnosu na skupinu poljoprivrednika koji raspolažu s više od 5 hektara vlastitog zemljišta ($\bar{x}$ = 2,29; SD = 0,90; 2,166; z = 17,189; p = 0). Isto tako, utvrđeno je da se skupina poljoprivrednika koja ostvaruje manje prihode ($\bar{x}$ = 3,23; SD = 0,97; 3,227; z = 37,428; p = 0) u većoj mjeri slaže da predstavništvo njihovih zadruga sudjeluje na skupovima iz područja zadružnog poduzetništva (zadSurad8) u odnosu na skupinu poljoprivrednika koja ima veće novčane prihode ($\bar{x}$ = 2,62; SD = 1,11; 2,661; z = 20,317; p = 0). Nešto drugačija situacija je kada uspoređujemo ispitanike obzirom na vrstu članstva. Ovdje indeksi slaganja imaju prihvatljive vrijednosti, međutim hi-kvadrat test je potvrdio postojanje značajnih odstupanja u mjernim skalama članova i ne članova zadruga po pitanju da li njihova zadruga izdvaja dio prihoda za plaćanje zdravstvenog osiguranja (brigaZajed1). Kada se dopustilo da razlike u mjerenju slobodno odstupaju između navedenih skupina uočeno je da se nečlanovi zadruge u većoj mjeri slažu da im zadruge plaća zdravstveno osiguranje ($\bar{x}$ = 3,77; SD = 1,07; 3,425; z = 17,865; p = 0), u odnosu na skupinu članova koji se s time u manjoj mjeri slaže ($\bar{x}$ = 2,54; SD = 1,19; 2,543; z = 27,575; p = 0).

Invarijantnost modela može se ispitati i na razini *invarijantnost varijance reziduala* (**Razina 4**) čime bi se analiza nadopunila utvrđivanjem da li su razlike u vrijednostima pokazatelja samo posljedica razlika faktorskih vrijednosti. Međutim, zbog malog uzorka i neujednačenih podskupina ispitanika pojavljuju se negativne vrijednosti varijance unutar matrice.[163] Time

[163] Raspon kretanja vrijednosti indeksa slaganja (ΔCFI = 0,034; ΔNCI = 0,063 i ΔGH = 0,019) ukazuje na značajne razlike, a ispitivanje veličine varijanci reziduala na potrebu uklanjanja više pokazatelja ako se želi postići *invarijantnost pogreške mjerenja* između skupine članova i nečlanova zadruge.

je potvrđeno da konačan model (Model 1.8) ne postiže invarijantnost na četvrtoj razini koju je u empirijskim istraživanjima ionako teško ili gotovo nemoguće postići.

Oblik anketnog upitnika ima veliki utjecaj na razumijevanje i mentalni konstrukt ispitanika, kao i na invarijantnost CFA modela. Mjerenje razina invarijantnosti uključuje prilagođavanje formulacije, semantike i strukture pokazatelja u anketnom upitniku kako bi se u budućim istraživanjima postigla što veća razina konstruktne validnosti i invarijantnosti istraživačkog modela. Ispitivanjem razina invarijantnosti faktorskih zasićenja, podrijetla mjerne ljestvice i pogreški mjerenja po skupinama ispitanika moguće je preciznije ispitati stabilnost i kvalitetu strukture mjernog instrumentarija, kao i stupanj slaganja modela s empirijskim podacima.

4.2.6. Ispitivanje konstruktne validnosti CFA modela

Prije ispitivanja značajnosti odnosa u CFA modelu potrebno je ispitati njegovu pouzdanost i validnost. To je važan preduvjet za ispravno testiranje istraživačkih teorija. Ispitivanjem konvergentne validnosti je provjereno u kojem opsegu konstrukti mjere stupanj usvojenosti zadružnih načela, dok su razlike i sličnosti između konstrukata provjerene procjenjivanjem diskriminativne validnosti. Rezultati najčešće korištenih tehnika za ispitivanje konstruktne validnosti i utvrđivanje psihometrijskih svojstva modela su prikazani u Tablici 4.8.[164]

Količina varijance koju varijable dijele u opisivanju latentnih faktora izračunata je pomoću *koeficijenta kompozitne pouzdanosti* (CR).[165] Vrijednosti koeficijenata iznad 0,7 ukazuju na dobru unutarnju konzistentnost faktora, dok se vrijednosti između 0,6 i 0,7 mogu se smatrati pouzdanim pod uvjetom da su ostale varijable konstruktne validnosti prihvatljive (Hair i sur., 2010: 680). Vrijednosti koeficijenata ukazuju da varijable dosljedno opisuju varijance svih latentnih faktora, uz slabiju pouzdanost varijabli gospodarskog sudjelovanja koje se nalaze na granici prihvatljive i dobre pouzdanosti. Preciznost ljestvica je provjerena izračunom intervala pouzdanosti i točke optimalne vrijednosti CR koeficijenata na razini populacije. S

Slična situacija, ali s manjim razlikama indeksa slaganja je uočena između skupina ispitanika koji se razlikuju obzirom na veličinu zemljišta i novčane prihode.

[164] *Koeficijent kompozitne pouzdanosti* (CR) se procjenjuje u kontekstu mjerenja modela i predstavlja omjer između vrijednosti prave i ukupne varijance. U računanju CR koeficijenata koriste se procjene faktorskih zasićenja, varijance i kovarijance pogreški prave i ukupne varijance. Metoda se pokazuje korisnom u izračunavanju optimalnih vrijednosti populacije, procjenjivanju intervala pouzdanosti i u ispitivanjima promjena kompozitne pouzdanosti prilikom pročišćivanja novih mjernih ljestvica ili kod usporedbi po skupinama (Brown, 2006: 337-351).

[165] Pojam *varijabla* je stručni termin koji se koristi kao sinonim za *pokazatelj* i odnosi se na anketne podatke koje je EFA i CFA analiza pokazala značajnim za mjerenje stupnja usvojenosti zadružnih načela. Termini pokazatelji i varijable imaju isto značenje i mogu se koristiti naizmjenično.

95% sigurnosti možemo tvrditi da se vrijednosti pouzdanosti populacije za sve faktore nalaze između 0,693 i 0,795. Pri čemu latentni faktori *Poslovna autonomija* (F1), *Zadružna edukacija* (F5) i *Međuzadružna suradnja* (F3) postižu dobru razinu pouzdanosti, a faktori *Gospodarsko sudjelovanje* (F2), *Briga za zajednicu* (F4) i *Demokratičnost poslovanja* (F6) prihvatljivu razinu pouzdanosti u opisivanju faktorske varijance.[166]

Tablica 4.8. Pouzdanost i validnost faktora u CFA modelu usvojenosti zadružnih načela [a]

		CR	CR (95% I.P.)	AVE	MSV	F1	F2	F3	F4	F5	F6
F1	Načelo 2	0,704	0,635 – 0,774	0,443	0,267	0,750					
F2	Načelo 3	0,699	0,636 – 0,768	0,382	0,267	-0,517	0,655				
F3	Načelo 4	0,792	0,743 – 0,841	0,562	0,014	-0,091	0,055	0,749			
F4	Načelo 5	0,841	0,803 – 0,879	0,639	0,641	0,034	0,281	-0,117	0,699		
F5	Načelo 6	0,793	0,744 – 0,843	0,563	0,641	-0,223	0,294	0,063	0,800	0,799	
F6	Načelo 7	0,724	0,654 – 0,786	0,467	0,184	-0,263	0,367	0,107	0,361	0,429	0,665
TOTAL		**0,848**	**0,693 – 0,795**	**0,516**							

[a] Na dijagonali matrice korelacije nalaze se prosječna faktorska zasićenja (drugi korijen iz AVE).
Izvor: Izračun autora na temelju anketnih podataka.

Vrijednosti *prosječno izdvojene varijance* (AVE) potvrđuju da varijable demokratičnosti, gospodarskog sudjelovanja i brige za lokalnu zajednicu imaju nešto slabiju pouzdanost i objašnjavaju manje od 50% ukupne varijance faktora za razliku od varijabli autonomije, međuzadružne suradnje i zadružne edukacije.[167] Vrijednosti koeficijenata iznad 0,50 ukazuju na dobru konvergentnu validnost faktora koji objašnjavaju više od 50% varijance. Međutim, upotreba AVE statistike nije prikladna u slučaju kada je varijanca pogreške mjerenja veća od operativne varijance (AVE < 0,5), a CR koeficijenti potvrđuju preciznost mjerenja (Fornell i Larcker, 1981: 47).

Diskriminativna validnost faktora je utvrđena usporedbom AVE koeficijenata s vrijednostima *maksimalne varijance koju međusobno dijele faktori* (MSV). Ako su faktori uistinu različiti maksimalna varijanca koju dijele ne smije biti veća od prosječno izdvojene varijance faktora (MSV < AVE). Usporedba MSV i AVE koeficijenata ukazuje na sadržajnu sličnost faktora

[166] Kelley i Pornprasertmanit (2016) sugeriraju korištenje intervala pouzdanosti u procjenjivanju populacijskih vrijednosti koeficijenta pouzdanosti jer prikazuju stupanj pogreške mjerenja.

[167] Prema Fornellu i Larckeru (1981) *prosječno izdvojena varijanca* predstavlja prosječnu količinu varijance koju faktor objašnjava pomoću izvornih varijabli u odnosu na ukupnu varijancu istih varijabli. Računa se kao omjer zbroja kvadriranih standardiziranih faktorskih zasićenja i broja varijabli na jednom faktoru. Kada vrijednost AVE koeficijenta iznosi 0,50 prosječno zasićenje svih varijabli na jednom faktoru iznosi 0,50.

Zadružna edukacija (F5) i *Međuzadružna suradnja* (F6) koji dijele veći udio varijance nego što je objašnjavaju njihove pripadajuće varijable. To potvrđuje veliki koeficijent faktorske povezanosti (r_{F5-F6} = 0,800) čija je vrijednost veća od prosječnih faktorskih zasićenja varijabli zadružne edukacije (AVE_{F5} = 0,699) i međuzadružne suradnje (AVE_{F6} = 0,799) smještenih na dijagonali matrice.

Pristup Fornella i Larckera (1981) se temelji na procjenjivanju diskriminativne validnosti u kontekstu metode modeliranja strukturnih jednadžbi (SEM) koja ima namjeru precjenjivanja faktorskih zasićenja posebno kada mali broj varijabli opisuje varijancu faktora. Njihov pristup se pokazuje manje učinkovitim u otkrivanje slabije validnosti varijabli u uvjetima umjereno jakih faktorskih korelacija, preklapanja varijabli ili umjerenih faktorskih zasićenja. Henseler i suradnici (2015) ukazuju na slabiju preciznost AVE kriterija u usporedbi varijanci i predlažu učinkovitiji pristup u procjenjivanju diskriminativne validnosti.[168] Procjenjivanje vrijednosti HTMT koeficijenata pod strožim kriterijem potvrđuje diskriminativnu validnost dva faktora koji se empirijski ipak razlikuju ($HTMT_{F5-F6}$ = 0,803). Na taj način je potvrđeno da su svi teorijski konstrukti jedinstveni i da njihovi izvorne varijable odražavaju jedino svoje žarišne (izvorne) konstrukte. Visoki koeficijenti korelacije, ponekad viši od 0,9, još uvijek mogu proizvesti statistički značajne razlike u pristajanju modela (Hair i sur., 2010: 680) zbog čega se koeficijenti od 0,85 koriste kao gornja granica iznad koje je narušena diskriminativna validnost konstrukata (Brown, 2006: 131). Procjenjivanje diskriminativne validnosti nema isključivo empirijsko značenje u ocjenjivanju validnosti faktora. Teorijske osnove također trebaju predstavljati argumente u utvrđivanju korelacija između faktora. Osim procjenjivanja konstruktne validnosti postupak konstruiranja modela trebao bi uvažavati teoriju. U budućim istraživanjima veću pažnju treba posvetiti nekim od utvrđenih varijabli za dva relevantna faktora. Također, biti će potrebno dodavati nove varijable čija će se validnost ispitivati. Osim toga, biti će potrebno mijenjati i prilagođavati formulaciju, semantiku i strukturu postojećih pokazatelja (varijabli) u anketnom upitniku kako bi se osigurala uniformnost instrumentarija za prikupljanje podataka. To će na kraju rezultirati da svih sedam zadružnih načela budu prepoznata kao jedinstven mjerni konstrukt (faktor). Nadalje, povećanje uzorka će potvrditi da li empirijski podaci uistinu podržavaju statistički značajne faktore ili su oni jednostavno

[168] *Heterotrait-monotrait koeficijent korelacije* (HTMT) predstavlja odnos između prosječnih korelacija varijabli koje mjere različite konstrukte (engl. *heterotrait-heteromethod correlation*) i geometrijske sredine prosječnih korelacija varijabli koje mjere zasebne konstrukte (engl. *monotrait-heteromethod correlation*). Vrijednosti HTMT koeficijenata bliže 1 označavaju jaču povezanost faktora i nedostatak diskriminativne validnosti, dok vrijednosti 0,85 i 0,90 predstavljaju konzervativniji odnosno liberalniji kriterij za utvrđivanje diskriminativne validnosti (Henseler i sur., 2015: 121). Metoda se pokazuje učinkovitom u malim uzorcima i slučajevima preklapanja većeg broja varijabli, dok stroži kriterij (HTMT.85) ima najbolju ravnotežu između visoke sposobnosti otkrivanja i niske stope ne utemeljenih pogrešaka (Voorhees i sur., 2016: 131).

predmet modeliranja istog faktora kojeg mjerimo dvaput unutar predloženog modela. To posebice vrijedi za prvo načelo otvorenosti zadružnog poslovanja koje nije niti prepoznato od strane ispitanika. Prije nego se krene u ispitivanje hipoteza biti će potrebno primijeniti stroge kriterije u ispitivanjima konstruktne validnosti kako bi se osigurala robustna mjera za buduća istraživanja. To je dugotrajan (iterativan) postupak koji se treba ponavljati sve dok se ne potvrdi unidimenzionalnost i invarijantnost mjernog instrumentarija unutar različitih skupina ispitanika iste populacije.

Na kraju je potrebno naglasiti da se prilagođeni anketni upitnik za ispitivanje sastavnica socijalnog kapitala (WVS, 2021) po prvi puta koristi u području zadrugarstva i za ispitivanje stupnja usvojenosti zadružnih načela zbog čega dobivene rezultate konstruktne validnosti smatramo prikladnim za potrebe našeg istraživanja.[169]

4.2.7. Ispitivanje karakteristika metrike CFA modela

U prethodnom potpoglavlju je potvrđena konstruktna validnost našeg modela unatoč jakoj korelaciji između latentnih faktora *Međuzadružna suradnja* (F3) i *Zadružna edukacija* (F5). Diskriminativna validnost dva navedena faktora dodatno je provjerena metodom testiranja ugniježdenih modela.[170] U tu svrhu koristili smo Sattora-Bentlerov test (2010), hi kvadrat statistiku i indekse slaganja. U Tablici 4.9. su prikazane vrijednosti hi-kvadrat statistike i indeksa slaganja između tri ugniježdena modela koje smo međusobno uspoređivali.

U potpoglavlju 3.6.5. je opisana uloga indeksa slaganja u postupku procjenjivanja teorijskih modela sa stvarnim empirijskim podacima iz različitih aspekata. Oni daju objektivniju ocjenu o uspješnosti modela da reproducira dobivene podatke na drugim uzorcima iste populacije. Za potrebe našeg istraživanja izračunato je jedanaest indeksa slaganja: *apsolutni* (χ^2) i *relativni hi-kvadrat test* (χ^2/df), *prosječna standardizirana rezidualna pogreška mjerenja* (RMSEA) s intervalom pouzdanosti od 90% (engl. *confidence interval*), *standardizirana*

[169] Nunnally (1994) kaže da zadovoljavajuća razina pouzdanosti ovisi o svrsi mjernog instrumentarija. U početnoj fazi istraživačkog rada, skroman, ali dovoljno pouzdan instrumentarij uštedjet će vrijeme i energiju istraživača. On smatra da u kasnijim fazama istraživanja granice pouzdanosti veće od 0,80 nisu niti približno dovoljne. U preciznijim istraživanjima gdje se donose važne odluke, obzirom na specifične rezultate mjerenja, pouzdanost od 0,90 treba predstavljati minimum, a pouzdanost veća od 0,95 poželjan standard (Nunnally i Bernstein, 1994: 264-265).

[170] Kada su modeli ugniježdeni, kao u slučaju modela M1 i M2, tako da se jedan model može dobiti iz drugog modela nametanjem dodatnih zahtjeva CFA analiza može pomoći u istraživanju validnosti modela upotrebom hi-kvadrat testa. Procjenjivanje validnosti na ovaj način omogućuje usporedbe parametara kao što su faktorska zasićenja, procjene koeficijenata faktorskih korelacija i varijance pogreški mjerenja između ugniježđenih modela (Bagozzi i sur., 1991: 431).

prosječna kvadratna kovarijanca reziduala (SRMR), *komparativni indeks slaganja* (CFI), *Tucker-Lewisov indeks slaganja* (TLI), *normirani indeks slaganja* (NFI), *indeks najboljeg slaganja* (GFI), *Akaike kriterij o gubitku informacija* (AIC), *indeks očekivane validnosti* (ECVI) i *Bayes-Schwartzov informacijski kriterij* (BIC).

Tablica 4.9. Rezultati testiranja i indeksi slaganja ugniježđenih strukturalnih modela

Indeksi slaganja	**Model 3** M_3	**Model 2** M_2	**Model 1** M_1
Hi-kvadrat test (χ^2)	291,190	451,490	237,632
broj stupnjeva sloboda (df)	142	152	137
p-vrijednost	0	0	0
Prosječna standardna rezidualna pogreška (RMSEA)	0,072	0,099	0,060
donja granica 90% intervala pouzdanosti RMSEA	0,060	0,088	0,047
gornja granica 90% intervala pouzdanosti RMSEA	0,084	0,109	0,073
RMSEA p-vrijednost dobrog slaganja	0,001	0	0,094
standardizirana prosječna kvadratna kovarijanca reziduala (SRMR)	0,076	0,170	0,068
Komparativni indeks slaganja (CFI)	0,882	0,763	0,920
Tucker-Lewisov indeks slaganja (TLI)	0,858	0,733	0,900
Normirani indeks slaganja (NFI)	0,797	0,685	0,834
Indeks najboljeg slaganja (GFI)	0,868	0,814	0,895
Akaike kriterij o gubitku informacija (AIC)	9.874,023	10.014,323	9.830,465
Očekivana validnost modela (ECVI)	1,917	2,611	1,701
Bayes-Schwartzov informacijski kriterij (BIC)	10.032,820	10.140,037	10.005,803

Izvor: Izračun autora na temelju anketnih podataka.

Prvi ugniježdeni model je mjerni model koji ima dvadeset i jedan pokazatelj raspoređenih unutar šest faktora koji međusobno kovariraju (M_1). To je izvorni model kojeg smo dobili korištenjem EFA i CFA i čiji je postupak kreiranja objašnjen u prethodnim potpoglavljima (Model 1.8). Drugi model je identičan prvom modelu uz jednu razliku da faktori nisu međusobno povezani (M_2), dok je treći model (M_3) nastao spajanjem varijabli zadružne edukacije i međuzadružne suradnje u jedan faktor sukladno rezultatima metode usporedbe prosječno izdvojene i zajedničke varijance faktora u procjenjivanju validnosti modela (AVE-MSV). Ovaj model (M_3) je nastao na temelju rezultata analize konstruktne validnosti koja je detaljno objašnjena u prethodnom potpoglavlju. Smanjenje modela na pet faktora (M_3) odgovara rezultatima EFA analize. U procjeni parametara ugniježdenih modela koristili smo metodu maksimalne vjerodostojnosti (engl. *maximum likelihood method*), pri čemu je varijanca ograničena na jedan (1) tj. faktori su standardizirani u cilju slobodne procjene faktorskih zasićenja.[171] Manja vrijednost hi-kvadrat statistike označava kvalitetnije

[171] Metoda najveće vjerodostojnosti jedna je od najpoznatijih statističkih metoda koja maksimizira vjerodostojnost. Može se primijeniti na većini teorijskih distribucija i pod određenim uvjetima ima vrlo

pristajanje, a obzirom na vrijednosti indeksa slaganja jedino prvi ugniježdeni model postiže prihvatljivo slaganje sa stvarnim empirijskim podacima (M_1). Značajno povećanje hi-kvadrat vrijednosti kod ostalih modela rezultat je uvođenja pretpostavki da između faktora nema korelacije (M_2) i spajanju dva potencijalno slična faktora unutar mjernog modela (M_3).

Uspoređivanje ugniježdenih modela (M_1-M_2). Pomoću Sattora-Bentlerovog testa (2010) i indeksa slaganja je potvrđeno da pretpostavka o ortogonalnim projekcijama faktorskih centroida značajno pogoršava kvalitetu slaganja drugog modela u odnosu na prvi model koji dopušta povezanost faktora ($\Delta\chi^2(15)_{M1\text{-}M2} = 213{,}86$; $p < 0{,}001$).[172] Velike promjene u apsolutnim vrijednostima hi-kvadrat testa obzirom na male promjene u stupnjevima slobode ukazuju na značajne razlike između dva modela. Na slabiju kvalitetu parsimoničnog modela (M2) ukazuje i veliko smanjenje vrijednosti komparativnog indeksa (ΔCFI = 0,157), Tucker-Lewisovog indeksa (ΔTLI = 0,167) i normiranog indeksa slaganja (ΔNFI = 0,149).

Uspoređivanje ugniježdenih modela (M_1-M_3). Pomoću Sattora-Bentlerovog testa (2010) i indeksa slaganja ispitali smo učinak pretpostavke o preklapanju potencijalno sličnih faktora u reduciranom modela s pet faktora (M_3). Usporedba modela je potvrdila da model sa šest faktora (M_1) ima značajno kvalitetnije pristajanje podataka ($\Delta\chi^2(5)_{M1\text{-}M3} = 34{,}743$; $p < 0{,}001$). Promjene u apsolutnim vrijednostima hi-kvadrat testa obzirom na promjene u stupnjevima slobode ukazuju na manje, ali još uvijek statistički značajne razlike između dva modela (u odnosu na usporedbu M_1-M_2). Pad vrijednosti indeksa slaganja ispod minimalnih granica prihvatljivosti potvrđuje značajnu degradaciju reduciranog modela (M_3) s pet faktora (ΔCFI = 0,038; ΔTLI = 0,042 i ΔNFI = 0,037).

Rezultati usporedbe modela su potvrdili da je prvi mjerni model (M_1) sa šest faktora najbolje rješenje od tri ugniježdena modela jer objašnjava najveći udio varijance u mjerenju stupnja usvojenosti zadružnih načela i ostvaruje najbolje slaganje s empirijskim podacima. Osim toga potvrđena je diskriminativna validnost faktora *Međuzadružna suradnja* (F3) i *Zadružna edukacija* (F5). Time smo još jednom potvrdili validnost CFA modela (Model 1.8) kojeg smo dobili nakon postupka skraćivanja početnog EFA modela (vidi potpoglavlje 4.2.2., str. 113).

---

dobre statističke značajke kao što su invarijantnost, konzistentnost i asimptotska nepristranost. Pokazuje se prikladnom za ocjenjivanje kvalitete slaganja modela s empirijskim podacima pomoću različitih indeksa u CFA analizi (Tabachnick i Fidell, 2007). Najjači argument za korištenje ML metode leži u činjenici da omogućuje testiranje značaja svakog latentnog faktora koji se izlučuje i u odnosu na druge metode ima jake statističke testove (Kline, 1994: 49-50).

[172] U odnosu na druge statističke testove, Satorra-Bentlerov test (2010) koristi robustne procjenitelje koji ne podliježu utjecaju veličine uzorka. Upotrebom srednjih vrijednosti, ili srednjih vrijednosti i varijance test ima veću preciznost u podešavanju funkcije prilagodbe modela kada uzorak ne slijedi normalnu distribuciju podataka (Beaujean, 2014: 156).

Na temelju svih rezultata možemo kazati da CFA model usvojenosti zadružnih načela sadrži dvadeset i jednu varijablu (pokazatelj) koji su podjednako raspoređeni na šest latentnih faktora. Struktura konačnog CFA modela je prikazana na Slici 4.1. (str. 133).

4.2.8. Ispitivanje i procjena slaganja CFA modela s empirijskim podacima

U potpoglavlju 3.6.5. je opisana uloga indeksa slaganja u postupku procjenjivanja teorijskih modela sa stvarnim empirijskim podacima iz različitih aspekata. Iz gornje tablice 4.9. vidimo da konačan model za mjerenje stupnja usvojenosti zadružnih načela gotovo u potpunosti zadovoljava postavljene kriterije slaganja. Početna hipoteza o dobrom pristajanju podataka je potvrđena hi-kvadrat testom ($\chi^2(137) = 237{,}632$, $p = 0{,}000$). Vrijednost hi-kvadrat testa obzirom na broj stupnjeva slobode također potvrđuju dobro slaganje podataka ($\chi^2/df_{M1} = 1{,}73$).[173] Vrijednosti prosječne standardizirane rezidualne pogreške mjerenja ($RMSEA_{M1} = 0{,}060$) i standardizirane prosječne kvadratne kovarijance reziduala ($SRMR_{M1} = 0{,}068$) ukazuju na dobro slaganje podataka.[174] Raspon kretanja vrijednosti RMSEA indeksa kreće se od 0,047 do 0,073 s intervalom pouzdanosti od 90%. To ukazuje na zadovoljavajuću sposobnost modela da reproducira kovarijancu modela i u drugim uzorcima iste populacije.

Slične rezultate dobivamo kada promatramo skupinu inkrementalnih ili usporednih indeksa slaganja. Na dobro slaganje podataka u CFA modelu ukazuju komparativni indeks slaganja ($CFI_{M1} = 0{,}920$), Tucker-Lewisov indeks slaganja ($TLI_{M1} = 0{,}900$) i indeks najboljeg slaganja ($GFI_{M1} = 0{,}900$).[175] Nasuprot njima, vrijednosti normiranog indeksa slaganja ($NFI_{M1} = 0{,}897$) se nalaze ispod, ali u blizini donje granice prihvatljivosti.[176] Uvažavajući vrijednosti indeksa

---

[173] Niže vrijednosti hi-kvadrat statistike u odnosu na broj stupnjeva slobode (*relativni hi-kvadrat test*, χ^2/df) ukazuje na dobru reprodukciju matrice varijance uzorka. Iako ne postoje standardne granične vrijednosti, literatura preporuča da se one kreću barem u rasponu od 2 do 5 (Marsh i Hocevar, 1985: 567), dok drugi istraživači smatraju da se jedino vrijednosti manje od 2 mogu tumačiti adekvatnim za dobro pristajanje podataka (Brookings i Bolton, 1988: 143). Međutim, apsolutne i relativne vrijednosti hi-kvadrat statistike su ovisne o veličini uzorka i zato ih je dobro koristiti s drugim indeksima slaganja.

[174] U malim uzorcima ($N \leq 250$) preporuča se istodobno korištenje SRMR, RMSEA i CFI indeksa slaganja. Ovisno o kretanju vrijednosti RMSEA i SRMR indeksa možemo govoriti o: *tijesnom* (≤ 0,05), *dobrom* (0,05 - 0,08), *slabom* (0,08 - 0,1) i *neprihvatljivom* (≥ 0,1) slaganju podataka između matrice predviđenih i stvarnih empirijskih podataka. Za relativno dobro slaganje podataka između hipoteze modela i stvarnih podataka gornja granična vrijednost kod RMSEA indeksa trebala bi se kretati oko 0,060 odnosno oko 0,080 kod SRMR indeksa (Hu i Bentler, 1998: 449).

[175] Komparativni indeks slaganja (CFI) je najmanje osjetljiv na veličinu uzorka i najčešće se koristi u SEM analizama (Fan i sur., 1999). Vrijednosti veće od 0,90 ukazuju na dobru pouzdanost modela.

[176] Vrijednosti NFI indeksa iznad 0,95 smatraju se dobrim, a vrijednosti ispod 0,90 lošim pokazateljem slaganja modela (Hu i Bentler, 1998). Glavni nedostatak NFI indeksa je korelacija s veličinom uzorka. Tucker-Lewisov indeks (TLI) ispravlja nedostatak NFI indeksa i pokazuje se pouzdanim u uzorcima

slaganja iz ove skupine možemo zaključiti da je potvrđena razumna prikladnost podataka unutar konačnog CFA modela (M_1).

Posljednja skupina indeksa slaganja u tablici ukazuje na gubitak informacija i koristi se radi postizanja parsimonije modela.[177] Obzirom da nema graničnih vrijednosti za ovu skupinu indekse najbolje ih je koristiti u usporedbama s drugim modelima. Iz tablice 4.9. vidimo da vrijednosti Akaike kriterija o gubitku informacija (AIC_{M1} = 9.874,023), očekivane validnosti ($ECVI_{M1}$ = 1,917) i Bayes-Schwartzov informacijski kriterij (BIC_{M1} = 10.032,820) predviđaju manji gubitak informacija i veću sličnost podataka između matrice kovarijanci očekivanih i stvarnih (empirijskih) vrijednosti u konačnom CFA modelu (M_1).

4.2.9. Ispitivanje pouzdanosti CFA modela

U Tablici 4.12. se nalaze svi podaci o homogenosti i pouzdanosti *Skale za mjerenje stupnja usvojenosti zadružnih načela*. Konačan model je prikazan na Slici 4.1. (str. 133). Podaci u tablici pokazuju da je skala unutarnje homogeni konstrukt. Značajnost matrice korelacije je potvrđena Bartlettovim testom ($\chi^2(20) = 138{,}48$, $p < 0{,}001$), dok je Kaiser-Meyer-Olkinov test matricu ocijenio pogodnom za provođenje faktorske analize (KMO = 0,793).[178]

Tablica 4.10. Podaci o pouzdanosti skale za mjerenje usvojenosti zadružnih načela

	aritmetička sredina	medijan	koeficijent asimetričnosti	koeficijent spljoštenosti	S.E.	Cronbach Alfa	KMO	Gutman λ-2
F1-Načelo 4	4,02	4,00	-0,55	0,27	0,05	0,787	0,690	0,741
F2-Načelo 3	3,73	3,83	-0,28	0,24	0,04	0,772	0,841	0,765
F3-Načelo 6	2,92	2,67	0,26	-0,63	0,07	0,787	0,697	0,741
F4-Načelo 7	3,14	3,33	-0,17	-0,21	0,06	0,718	0,659	0,688
F5-Načelo 5	2,26	2,00	0,83	0,10	0,07	0,837	0,724	0,788
F6-Načelo 2	2,58	2,67	0,41	0,79	0,05	0,702	0,664	0,661
Ukupno:						**0,818**	**0,793**	**0,791**

S.E. = standardna pogreška koeficijenata asimetričnosti/spljoštenosti.
Izvor: Izračun autora na temelju anketnih podataka.

koji imaju manje od 200 ispitanika (Tabachnick i Fidell, 2007). Vrijednost od 0,95 osigurava dobro slaganje podataka, ali vrijednosti iznad 1 je teško interpretirati zbog nepostojanja gornje granice.

[177] Ne postoje jasno definirane granice kretanja za ovu skupinu indeksa slaganja jer apsolutne vrijednosti nisu normirane na ljestvici od 0 do 1. Međutim, manje vrijednosti indeksa upućuju na dobro pristajanje podataka i parsimoniju modela.

[178] *Kaiser-Mayer-Olkinov test* (KMO) pokazuje proporciju varijance koja je zajednička, odnosno koju zajednički objašnjavaju latentni faktori. Vrijednosti KMO indeksa veće od 0,6 predstavljaju osrednju razinu faktorske jednostavnosti i prihvatljive su za provođenje faktorske analize (Kaiser, 1974: 35).

Unutarnju konzistentnost je potvrdio Cronbach Alfa koeficijent koji za ukupnu skalu od 21 čestice iznosi 0,818. To ukazuje na prihvatljivu pouzdanost ukupne skale.[179] Isti koeficijent je potvrdio prihvatljivu pouzdanost za svaku subskalu (zadružno načelo) zasebno. Raspon kretanja Alfa koeficijenata za svako zadružno načelo kreće se u rasponu od 0,702 do 0,837. Guttmanova Lambda 2 je također potvrdila prihvatljivu pouzdanost ukupne skale (Gutman λ-2 = 0,791). Vrijednost indeksa za svaku subskalu kreće se u rasponu od 0,661 do 0,788.[180]

Vrijednosti koeficijenta asimetričnosti (engl. *skewness*) ukazuju da je distribucija rezultata nagnuta na lijevu stranu kod subskali koje mjere usvojenost načela *poslovna autonomija* (-0,55), *gospodarsko sudjelovanje* (-0,28) i *briga za lokalnu zajednicu* (-0,17). Ispitanici pokazuju veći stupanj slaganja s pokazateljima koji mjere ova tri načela. S druge strane, vrijednosti koeficijenta asimetričnosti pokazuju da se ispitanici manje slažu s pokazateljima koji mjere usvojenost načela *međuzadružna suradnja* (0,26), *demokratičnost poslovanja* (0,41) i *zadružna edukacija* (0,83). Vrijednosti koeficijenta spljoštenosti (engl. *kurtosis*) upućuju na postojanje određene tendencije prema spljoštenosti distribucije kada mjerimo usvojenost načela *međuzadružna suradnja* (-0,63) i *briga za lokalnu zajednicu* (-0,21). Stupanj slaganja ispitanika s pokazateljima koji mjere usvojenost ova dva načela imaju odstupanja veća od aritmetičke sredine. S druge strane, pozitivne vrijednosti koeficijenta spljoštenosti ukazuju da rezultati slijede normalnu distribuciju podataka kada mjerimo stupanj usvojenosti načela *zadružna edukacija* (0,10), *gospodarsko sudjelovanje* (0,24), *poslovna autonomija* (0,27) i *demokratičnost poslovanja* (0,79). Odgovori ispitanika koji mjere usvojenost četiri zadružna načela nalaze se oko svoje aritmetičke sredine. Kolmogorov-Smirnovljev test je potvrdio da distribucija rezultata dobivena primjenom ukupne skale odstupa od normalne distribucije (K-S D= 0,877; $p < 0,05$).

[179] Prema Nunnallyu i Bernsteinu (1994) zadovoljavajuća razina pouzdanosti ovisi o načinu na koji se mjera koristi. U ranim fazama istraživanja korištenje instrumenata koji imaju skromnu pouzdanost, npr. 0,700, mogu značajno uštedjeti vrijeme i energiju istraživača (Nunnally i Bernstein, 1994: 265).

[180] Guttmanova Lambda (λ) procjenjuje korelacije između rezultata paralelnih testova, dok Cronbach Alfa procjenjuje korelacije između rezultata slučajno ekvivalentnih testova. U složenijim situacijama, Lambda-2 se smatra robusnijim pokazateljem i uvijek je veća ili jednaka vrijednosti Alfa.

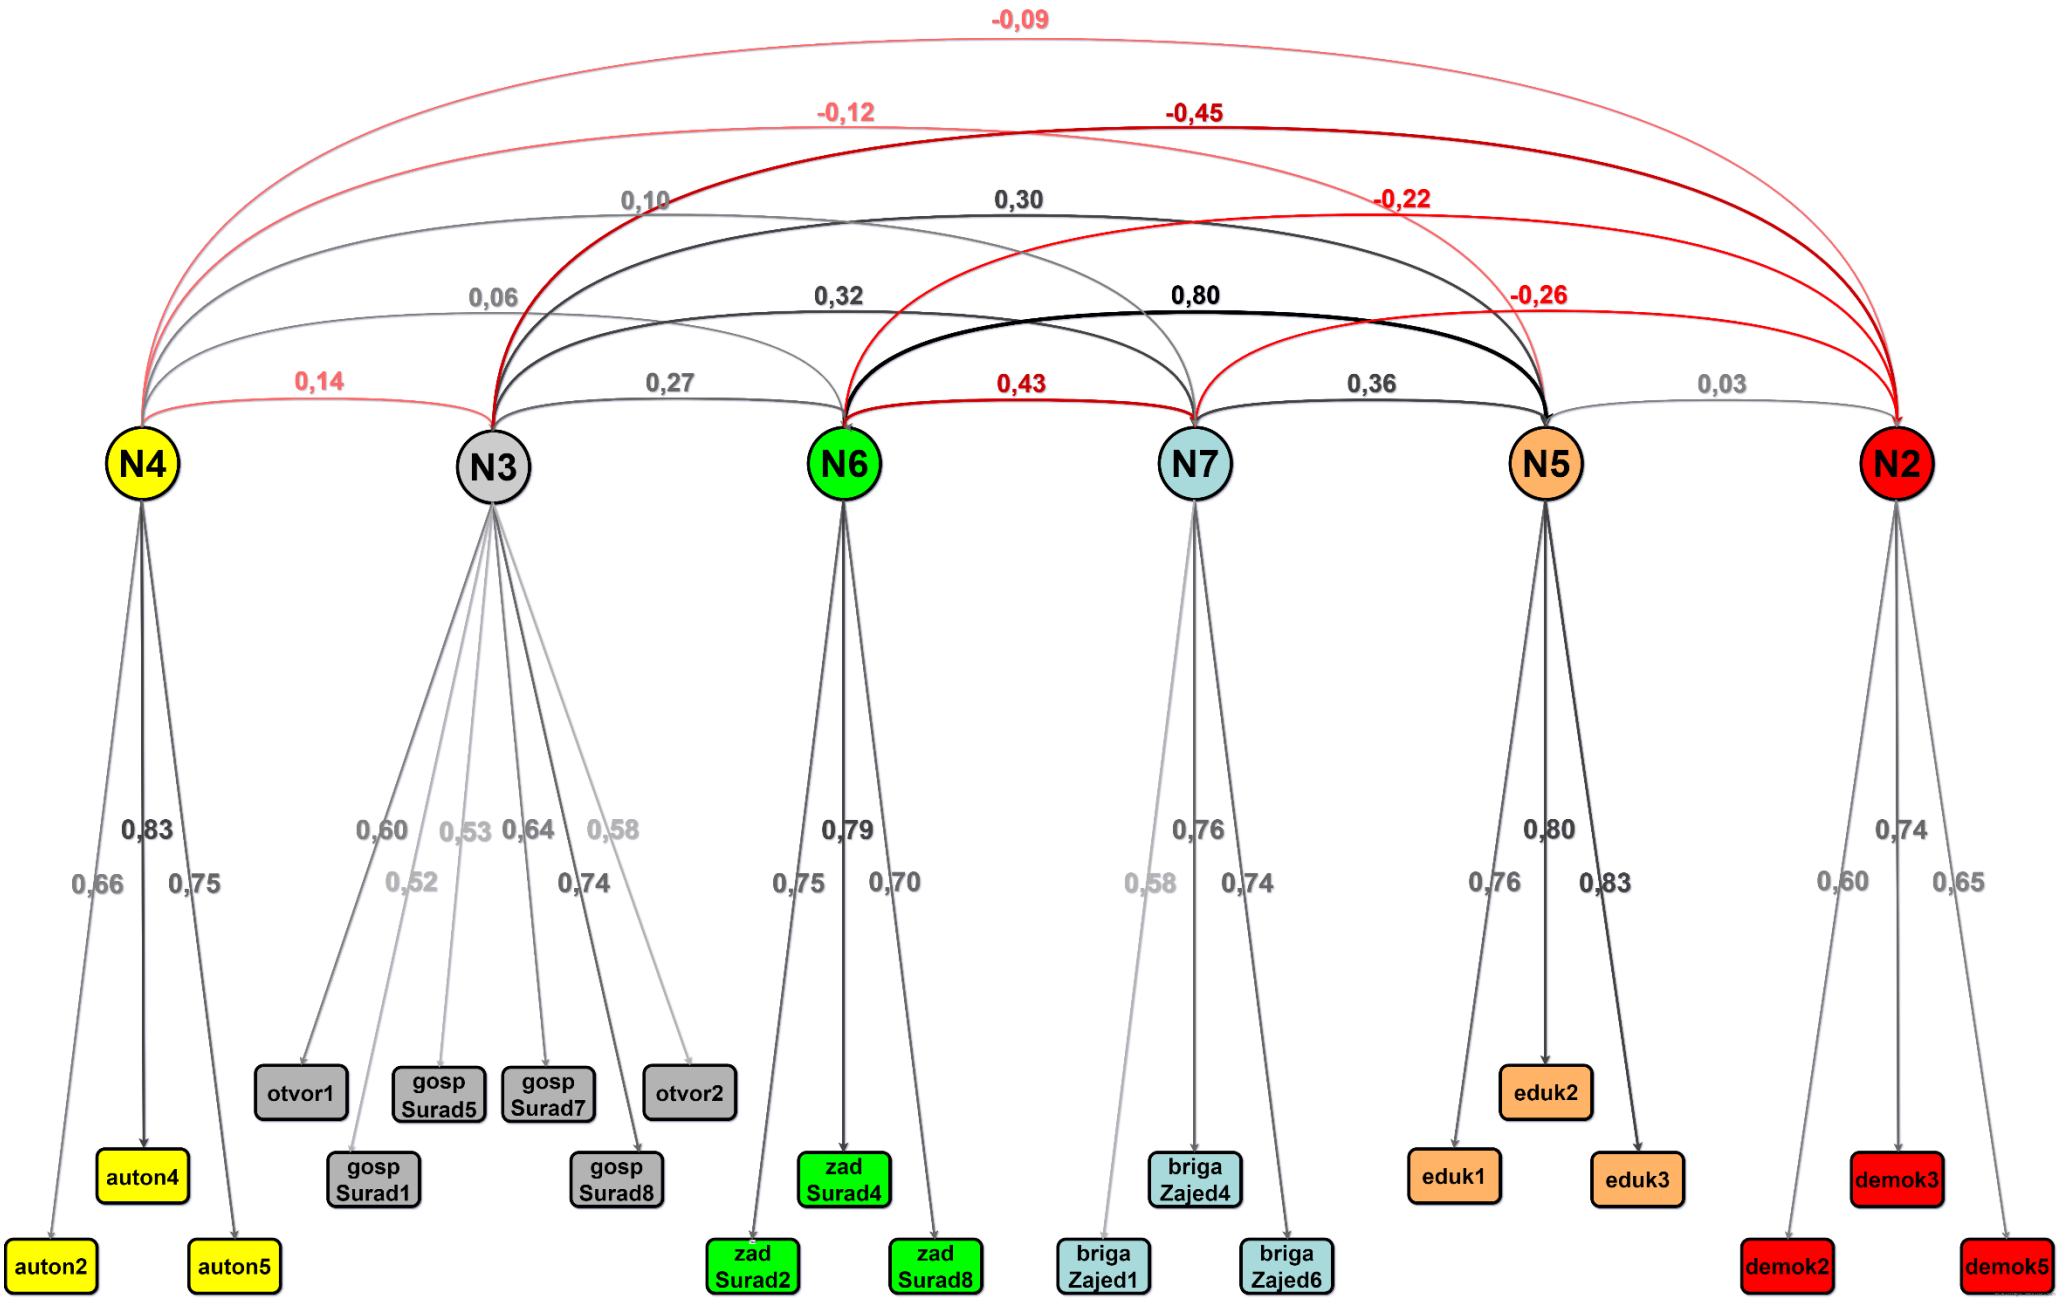

Slika 4.1. Konačan CFA model za mjerenje usvojenosti zadružnih načela (Model 1.8 - M1).

4.3. Procjena stupnja usvojenosti zadružnih načela Metodom potencijala

4.3.1. Agregiranje preferencija

Metode potencijala i objašnjenje ključnih pojmova neophodnih za razumijevanje procjene stupnja usvojenosti zadružnih načela su objašnjeni u potpoglavlju 3.7. Osnovu cijele analize čini multigraf preferencije koji nastaje kao rezultat uspoređivanja alternativa u parovima. Ako se ekonomski pokazatelji uspoređuju u parovima, u odnosu na zadružna načela kao atribute, dobiva se multigraf na lijevoj strani slike 4.2. Ako zadružna načela uspoređujemo u parovima, u odnosu na ekonomske pokazatelje kao atribute, dobiva se multigraf na desnoj strani slike 4.2.

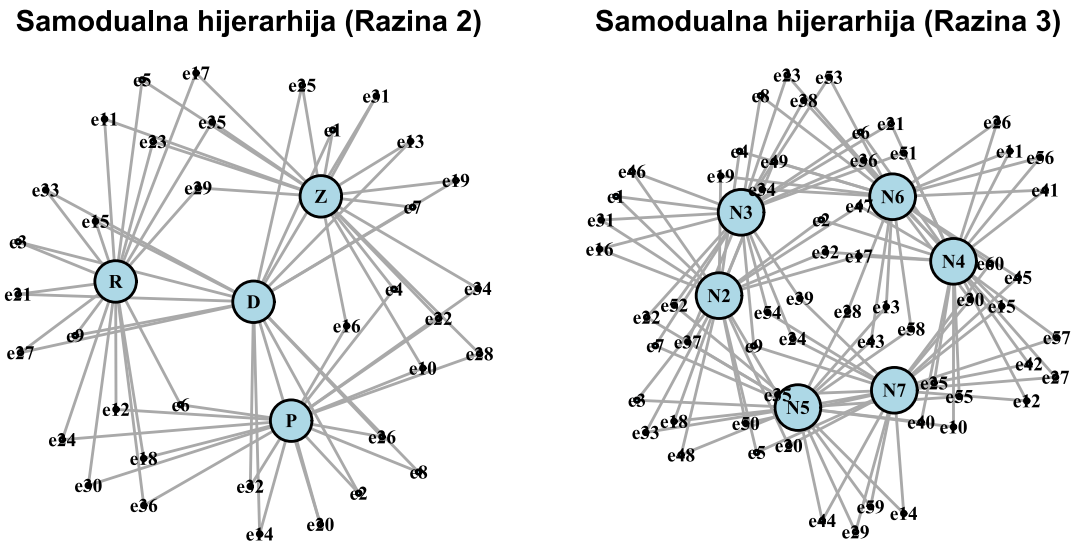

Slika 4.2. Multigrafovi preferencije samodualne hijerarhije na razini 2 i razini 3.

Postoji nekoliko načina računanja potencijala za multigraf preferencije. Prvi način je već opisan u potpoglavlju 3.7.5. i (1) provodi se na multigrafu koji sadrži paralelne lukove dok se Lapaceova matrica računa na isti način kao i u slučaju kod jednostavnog grafa (vidi formulu 3.39.). Drugi način je pretvoriti multigraf preferencije u jednostavan graf preferencije i njegove paralelne lukove zamijeniti s jednim lukom čiji se intenzitet računa kao (2) zbroj intenziteta odgovarajućih paralelnih lukova u multigrafu, ili kao (3) aritmetička sredina odgovarajućih paralelnih lukova koja uvažava i težine atributa ako su one različite.

Konstrukcija agregiranog grafa preferencije se računa na sljedeći način (Čaklović, 2012):

$$\mathrm{F}_{\alpha} := \sum_{\substack{i=1 \\ \pm\alpha\in\mathcal{A}_i}}^{k} w_i \mathcal{F}_i(\alpha) \tag{4.1.}$$

pri čemu se $w_i\mathcal{F}_i$ (α) uzima u obzir, ako i samo ako, je $\alpha \in \mathcal{A}_i$ ili $-\alpha \in \mathcal{A}_i$. Kada je F_α ne negativan tada je luk α luk $\mathcal{A}$ u agregiranom grafu preferencije ($\mathcal{F}$ (α) := F_α), a vrijednost luka α je jednaka dobivenom intenzitetu preferencije (F_α). Kada je F_α negativan tada je luk $-\alpha$ luk $\mathcal{A}$ agregiranog grafa preferencije, a vrijednost luka α na tom toku $\mathcal{F}$ je apsolutna vrijednost intenziteta preferencije $|-\mathrm{F}_\alpha|$.[181] U slučaju kada F_α nije definiran, čvorovi *u* i *v*, nisu susjedni vrhovi u agregiranom grafu preferencije. Ako dva vrha multigrafa preferencije nisu susjedni vrhovi onda oni nisu susjedni niti u agregiranom grafu preferencije i nema luka među njima. U tablici 4.11. (str. 136) se prikazane Laplaceove matrice i vektori razlike toka za svaki od tri konstruirana multigrafa preferencije. U tablici 4.12. (str. 137) su prikazane matrice incidencije za svaki pojedinačni graf preferencije na slikama 4.3. i 4.4.

Prednost svođenja multigrafa u jednostavan graf je smanjenje inkonzistentnosti multigrafa koja je velika jer je njegova dimenzija prostora bridova velika. Odabir odgovarajuće metode prvenstveno ovisi o kontekstu istraživanja. Na primjer, ako se radi o predsjedničkim izborima i nadglasavanju jednog kandidata u usporedbi s drugim onda aritmetička sredina nema smisla. Sve tri navedene metode u našem istraživanju daju isti poredak alternativa uz neznatne razlike u vrijednostima potencijala.

4.3.2. Povezivanje poslovnih pokazatelja sa zadružnim načelima

Povezivanje poslovnih parametara sa zadružnim načelima realizirati ćemo uz pomoć nekoliko grafova preferencije. Ovdje ima puno grafova preferencije i svaki graf preferencije predstavlja subjektivne procjene vezane za zadružna načela kao atribute. To znači da za atribut *Briga za zajednicu* (Načelo 7) promatramo i uspoređujemo alternative u parovima u odnosu na atribute *dionici*, *zalihe*, *prihodi* i *rashodi*. Nakon toga provodi se agregiranje svih pojedinačnih grafova preferencije u multigraf (vidi potpoglavlje 3.7.6., str. 96). Problem koji se pri tome javlja je taj što nisu unaprijed zadane težine atributa (načela). U tu svrhu, za

[181] Kada je F_α negativan onda luk α mijenja smjer odnosno (*u*, *v*) se mijenja u (*v*, *u*).

računanje težina zadružnih načela ponovno se koristi Metoda potencijala koja se primjenjuje na *samodualnoj hijerarhiji* kako je to opisano u potpoglavlju (3.7.9., str. 100).

Tablica 4.11. Laplaceova matrica i vektor razlike toka za tri multigrafa preferencije

Multigraf preferencije (Samodualna hijerarhija - Razina 2)

Laplaceova matrica (L):

$$L = \begin{array}{c|cccc} & \mathbf{D} & \mathbf{Z} & \mathbf{P} & \mathbf{R} \\ \hline \mathbf{D} & 18 & -6 & -6 & -6 \\ \mathbf{Z} & -6 & 18 & -6 & -6 \\ \mathbf{P} & -6 & -6 & 18 & -6 \\ \mathbf{R} & -6 & -6 & -6 & 18 \end{array}$$

Vektor razlike toka (∇):

$$\nabla = \begin{pmatrix} 38 \\ -10 \\ 6 \\ -34 \end{pmatrix}$$

Multigraf preferencije (Samodualna hijerarhija - Razina 3)

Laplaceova matrica (L):

$$L = \begin{array}{c|cccccc} & \mathbf{N2} & \mathbf{N3} & \mathbf{N4} & \mathbf{N5} & \mathbf{N6} & \mathbf{N7} \\ \hline \mathbf{N2} & 24 & -4 & -4 & -4 & -4 & -4 \\ \mathbf{N3} & -4 & 24 & -4 & -4 & -4 & -4 \\ \mathbf{N4} & -4 & -4 & 24 & -4 & -4 & -4 \\ \mathbf{N5} & -4 & -4 & -4 & 24 & -4 & -4 \\ \mathbf{N6} & -4 & -4 & -4 & -4 & 24 & -4 \\ \mathbf{N7} & -4 & -4 & -4 & -4 & -4 & 24 \end{array}$$

Vektor razlike toka (∇):

$$\nabla = \begin{pmatrix} -13 \\ 22 \\ -17 \\ -27 \\ 37 \\ -2 \end{pmatrix}$$

Multigraf preferencije (Samodualna hijerarhija - Razina 4)

Laplaceova matrica (L):

$$L = \begin{array}{c|cccccc} & \mathbf{N2} & \mathbf{N3} & \mathbf{N4} & \mathbf{N5} & \mathbf{N6} & \mathbf{N7} \\ \hline \mathbf{N2} & 20 & -4 & -4 & -4 & -4 & -4 \\ \mathbf{N3} & -4 & 20 & -4 & -4 & -4 & -4 \\ \mathbf{N4} & -4 & -6 & 20 & -4 & -4 & -4 \\ \mathbf{N5} & -4 & -4 & -4 & 20 & -4 & -4 \\ \mathbf{N6} & -4 & -4 & -4 & -4 & 20 & -4 \\ \mathbf{N7} & -4 & -4 & -4 & -4 & -4 & 20 \end{array}$$

Vektor razlike toka (∇):

$$\nabla = \begin{pmatrix} -9 \\ 45 \\ -15 \\ -21 \\ 33 \\ -33 \end{pmatrix}$$

Izvor: Autorska obrada podataka.

Tablica 4.12. Matrice incidencije za grafove preferencije samodualne hijerarhije

Samodualna hijerarhija (Razina 2)

Načelo 2 (N2)

	D	Z	P	R
α_1	1	−1	0	0
α_2	1	0	−1	0
α_3	1	0	0	−1
α_4	0	1	−1	0
α_5	0	1	0	−1
α_6	0	0	1	−1

Načelo 3 (N3)

	D	Z	P	R
α_7	1	−1	0	0
α_8	−1	0	1	0
α_9	1	0	0	−1
α_{10}	0	−1	1	0
α_{11}	0	1	0	−1
α_{12}	0	0	1	−1

Načelo 4 (N4)

	D	Z	P	R
α_{13}	1	−1	0	0
α_{14}	1	0	−1	0
α_{15}	1	0	0	−1
α_{16}	0	1	−1	0
α_{17}	0	1	0	−1
α_{18}	0	0	1	−1

Načelo 5 (N5)

	D	Z	P	R
α_{19}	1	−1	0	0
α_{20}	1	0	−1	0
α_{21}	1	0	0	−1
α_{22}	0	−1	1	0
α_{23}	0	−1	0	1
α_{24}	0	0	1	−1

Načelo 6 (N6)

	D	Z	P	R
α_{25}	1	−1	0	0
α_{26}	1	0	−1	0
α_{27}	1	0	0	−1
α_{28}	0	−1	1	0
α_{29}	0	1	0	−1
α_{30}	0	0	1	−1

Načelo 7 (N7)

	D	Z	P	R
α_{31}	1	−1	0	0
α_{32}	1	0	−1	0
α_{33}	1	0	0	−1
α_{34}	0	−1	1	0
α_{35}	0	−1	0	1
α_{36}	0	0	1	−1

Samodualna hijerarhija (Razina 3)

Dionici (D)

	N2	N3	N4	N5	N6	N7
α_1	−1	1	0	0	0	0
α_2	1	0	−1	0	0	0
α_3	1	0	0	−1	0	0
α_4	−1	0	0	0	1	0
α_5	1	0	0	0	0	−1
α_6	0	1	−1	0	0	0
α_7	0	1	0	−1	0	0
α_8	0	1	0	0	−1	0
α_9	0	1	0	0	0	−1
α_{10}	0	0	−1	1	0	0
α_{11}	0	0	−1	0	1	0
α_{12}	0	0	−1	0	0	1
α_{13}	0	0	0	−1	1	0
α_{14}	0	0	0	1	0	−1
α_{15}	0	0	0	0	1	−1

Zalihe (Z)

	N2	N3	N4	N5	N6	N7
α_{16}	−1	1	0	0	0	0
α_{17}	−1	0	1	0	0	0
α_{18}	1	0	0	−1	0	0
α_{19}	−1	0	0	0	1	0
α_{20}	1	0	0	0	0	−1
α_{21}	0	1	−1	0	0	0
α_{22}	0	1	0	−1	0	0
α_{23}	0	1	0	0	−1	0
α_{24}	0	1	0	0	0	−1
α_{25}	0	0	1	−1	0	0
α_{26}	0	0	−1	0	1	0
α_{27}	0	0	1	0	0	−1
α_{28}	0	0	0	−1	1	0
α_{29}	0	0	0	1	0	−1
α_{30}	0	0	0	0	1	−1

Prihodi (P)

	N2	N3	N4	N5	N6	N7
α_{31}	−1	1	0	0	0	0
α_{32}	−1	0	1	0	0	0
α_{33}	−1	0	0	1	0	0
α_{34}	−1	0	0	0	1	0
α_{35}	1	0	0	0	0	−1
α_{36}	0	1	−1	0	0	0
α_{37}	0	1	0	−1	0	0
α_{38}	0	1	0	0	−1	0
α_{39}	0	1	0	0	0	−1
α_{40}	0	0	1	−1	0	0
α_{41}	0	0	−1	0	1	0
α_{42}	0	0	1	0	0	−1
α_{43}	0	0	0	−1	1	0
α_{44}	0	0	0	1	0	−1
α_{45}	0	0	0	0	1	−1

Rashodi (R)

	N2	N3	N4	N5	N6	N7
α_{46}	−1	1	0	0	0	0
α_{47}	1	0	−1	0	0	0
α_{48}	1	0	0	−1	0	0
α_{49}	−1	0	0	0	1	0
α_{50}	−1	0	0	0	0	1
α_{51}	0	1	−1	0	0	0
α_{52}	0	1	0	−1	0	0
α_{53}	0	1	0	0	−1	0
α_{54}	0	1	0	0	0	−1
α_{55}	0	0	1	−1	0	0
α_{56}	0	0	−1	0	1	0
α_{57}	0	0	−1	0	0	1
α_{58}	0	0	0	−1	1	0
α_{59}	0	0	0	−1	0	1
α_{60}	0	0	0	0	1	−1

Samodualna hijerarhija (Razina 4)

Načelo 2 (N2)

	N3	N4	N5	N6	N7
α_1	1	−1	0	0	0
α_2	1	0	−1	0	0
α_3	1	0	0	−1	0
α_4	1	0	0	0	−1
α_5	0	1	−1	0	0
α_6	0	−1	0	1	0
α_7	0	1	0	0	−1
α_8	0	0	−1	1	0
α_9	0	0	−1	0	1
α_{10}	0	0	0	1	−1

Načelo 3 (N3)

	N2	N4	N5	N6	N7
α_{11}	−1	1	0	0	0
α_{12}	1	0	−1	0	0
α_{13}	−1	0	0	1	0
α_{14}	−1	0	0	0	1
α_{15}	0	1	−1	0	0
α_{16}	0	−1	0	1	0
α_{17}	0	1	0	0	−1
α_{18}	0	0	−1	1	0
α_{19}	0	0	−1	0	1
α_{20}	0	0	0	1	−1

Načelo 4 (N4)

	N2	N3	N5	N6	N7
α_{21}	−1	1	0	0	0
α_{22}	1	0	−1	0	0
α_{23}	−1	0	0	1	0
α_{24}	1	0	0	0	−1
α_{25}	0	1	−1	0	0
α_{26}	0	1	0	−1	0
α_{27}	0	1	0	0	−1
α_{28}	0	0	−1	1	0
α_{29}	0	0	1	0	−1
α_{30}	0	0	0	1	−1

Načelo 5 (N5)

	N2	N3	N4	N6	N7
α_{31}	1	−1	0	0	0
α_{32}	1	0	−1	0	0
α_{33}	−1	0	0	1	0
α_{34}	−1	0	0	0	1
α_{35}	0	1	−1	0	0
α_{36}	0	−1	0	1	0
α_{37}	0	−1	0	0	1
α_{38}	0	0	−1	1	0
α_{39}	0	0	−1	0	1
α_{40}	0	0	0	1	−1

Načelo 6 (N6)

	N2	N3	N4	N5	N7
α_{41}	−1	1	0	0	0
α_{42}	−1	0	1	0	0
α_{43}	−1	0	0	1	0
α_{44}	−1	0	0	0	1
α_{45}	0	1	−1	0	0
α_{46}	0	1	0	−1	0
α_{47}	0	−1	0	0	1
α_{48}	0	0	−1	1	0
α_{49}	0	0	−1	0	1
α_{50}	0	0	0	−1	1

Načelo 7 (N7)

	N2	N3	N4	N5	N6
α_{51}	−1	1	0	0	0
α_{52}	1	0	−1	0	0
α_{53}	−1	0	0	1	0
α_{54}	−1	0	0	0	1
α_{55}	0	1	−1	0	0
α_{56}	0	1	0	−1	0
α_{57}	0	−1	0	0	1
α_{58}	0	0	−1	1	0
α_{59}	0	0	−1	0	1
α_{60}	0	0	0	−1	1

U tablici se nalaze matrice incidencije za grafove preferencije na slikama 4.3. (lijevo), 4.4. (u sredini) i 4.5. (desno). Grafovi se nalaze na stranici 139.
D, **Z**, **P** i **R** (poslovni pokazatelji) = elementi Razine 3 samodualne hijerarhije (rangiranje poslovnih pokazatelja u odnosu na zadružna načela).
N2, **N3**, **N4**, **N5**, **N6** i **N7** (zadružna načela) = elementi Razine 2 i Razine 4 samodualne hijerarhije (rangiranje načela u odnosu na zadružna načela).
Izvor: Autorska obrada podataka.

4.3.3. Konkretizacija vrednovanja hijerarhije

Pojmovi samodualna hijerarhija, revizija prioriteta i cijeli postupak vrednovanja hijerarhije potrebni za razumijevanje rezultata našeg empirijskog istraživanja su detaljno objašnjeni u potpoglavlju (3.7.8., str. 99) i (3.7.9., str. 100).

Prvu skupinu podataka čini šest pokazatelja koji opisuju zadružna načela: *Demokratičnost* (N2), *Gospodarsko sudjelovanje* (N3), *Poslovna autonomija* (N4), *Zadružna edukacija* (N5), *Međuzadružna suradnja* (N6) i *Briga za lokalnu zajednicu* (N7). Drugu skupinu podataka čine četiri poslovna pokazatelja: *dionici* (D), *zalihe* (Z), *ukupni prihodi* (P) i *ukupni rashodi* (R). Navedene skupine socijalnih i poslovnih pokazatelja zajedno čine ulazne pokazatelje u vrednovanju hijerarhije i njih stavljamo u razine.

Za svakog roditelja u hijerarhiji konstruira se zaseban graf preferencije među njegovom djecom i računaju se njihovi potencijali i težine po formuli (3.44.). Grafovi preferencije za svakog roditelja su prikazani na slikama (4.3.), (4.4.) i (4.5.). Svi matematički izračuni su napravljeni pomoću *R programskog jezika* i softvera kreiranog od autora Metode potencijala (Čaklović, 2002) koji je u završnoj fazi testiranja i još uvijek nije prikladan za komercijalnu upotrebu. Za konstrukciju i vizualni prikaz grafova i multigrafova preferencije koristili smo *igraph* paket u sklopu R programskog jezika (Csárdi i Nepusz, 2006). Rezultati analize za sva tri provedena koraka u Metodi potencijala su detaljno objašnjeni u potpoglavlju (5.4., str. 150), (5.5., str. 157) i (5.6., str. 162) koji se nalaze u odjeljku Rasprava.

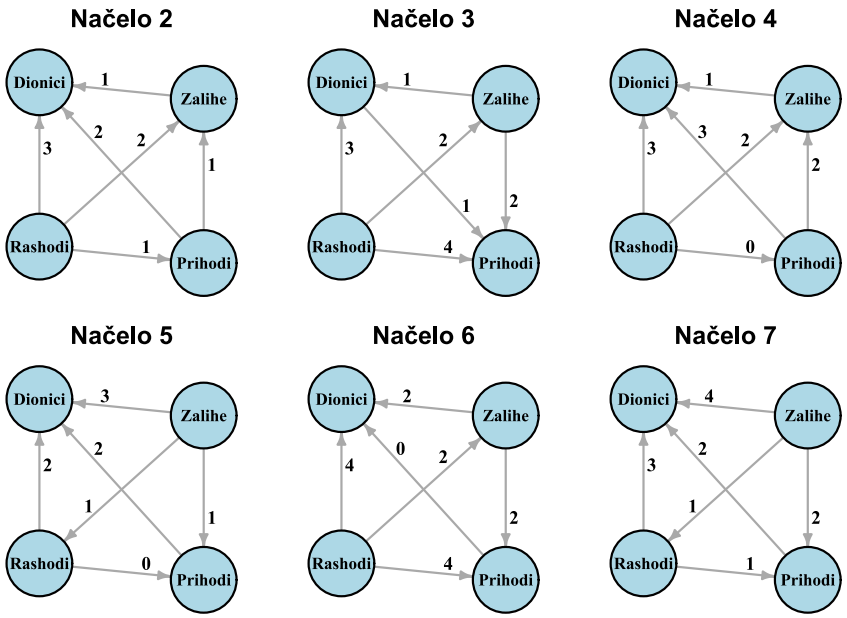

Slika 4.3. Grafovi preferencije za svako načelo zasebno (Razina 2).

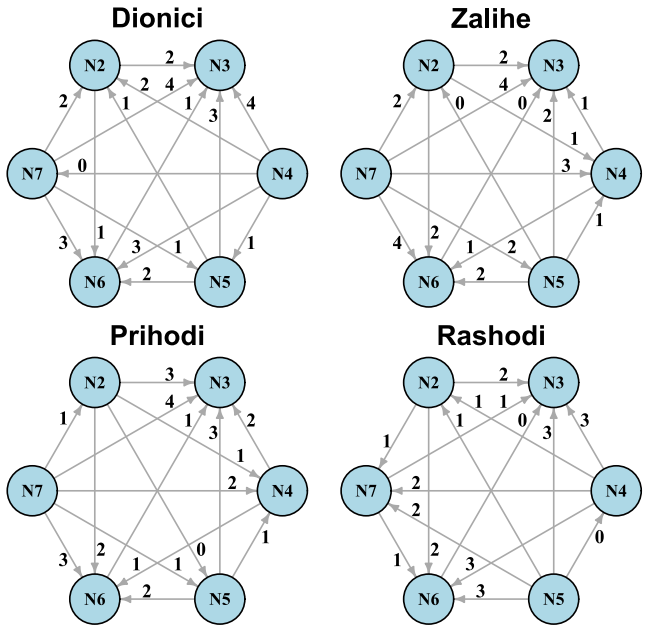

Slika 4.4. Grafovi preferencije za svaki poslovni pokazatelj zasebno (Razina 3).

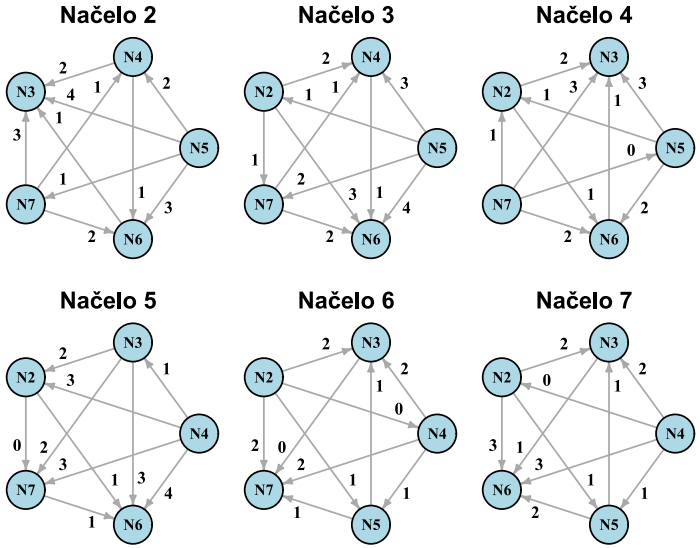

Slika 4.5. Grafovi preferencije za svako načelo zasebno (Razina 4).

5. RASPRAVA

5.1. Efikasnost zadružnog poslovanja po godinama

Korištenjem podataka FINA-e za vremensko razdoblje od 2009.-2013. godine analizirani su poslovni podaci 26 poljoprivrednih zadruga. Kako bi se zaštitila privatnost podataka u predstavljanju rezultata poljoprivrednim zadrugama smo dodijelili odgovarajuće kodove.[182] Zbog nepotpunih financijskih izvješća iz AOMP su uklonjene tri zadruge (z8, z15 i z18) tako da konačan uzorak istraživanja čine 23 poljoprivredne zadruge. Za utvrđivanje da li ulazni i izlazni podaci odgovarajuće izražavaju financijski profil zadružnog poslovanja koristili smo Analizu glavnih komponenata i promatrali kretanje varijance nakon uklanjanja pokazatelja (vidi potpoglavlje 4.1.2., str. 104). Na kraju je postavljen model koji sadrži dva ulazna (*dionici* i *zalihe*) i dva izlazna podatka (*ukupni prihodi* i *rashodi*). U tablici 4.1. (str. 103) su prikazane informacije o podacima koje smo koristili za ispitivanje robustnosti i slaganje AOMP modela.

Da bi se procijenila efikasnost poljoprivrednih zadruga uzorak smo promatrali u razdoblju od 2009.-2013. godine. U tablici 5.1. je prikazano kretanje rezultata efikasnosti zadružnog poslovanja koji su dobiveni AOMP i njihove srednje vrijednosti za svaku godinu. Iz tablice je vidljivo da srednje vrijednosti rezultata efikasnosti (aritmetička sredina i medijana) u prve dvije godine općenito padaju, a zatim u naredne dvije godine dolazi do značajnog povećanja vrijednosti svih rezultata efikasnosti. Trend početnog pada rezultata efikasnosti zadružnog poslovanja se podudara s pojavom gospodarske krize koja je u RH započela krajem 2008. godine. Navedeno ukazuje na negativan utjecaj globalne ekonomske situacije i paralelno s time na smanjenje rezultata efikasnosti zadružnog poslovanja.

Početak rasta srednjih vrijednosti rezultata efikasnosti u 2011. godini se poklapa s pojavom novog Zakona o zadrugama (NN, br. 34/2011). Zakon je postavio zadovoljavajuće pravne okvire koji su većoj mjeri bili u skladu sa zapadnoeuropskim standardima (vidi potpoglavlja 2.5.2. i 2.5.3.). Rast srednjih vrijednosti efikasnosti je bio još intenzivniji u 2012. godini što se podudara sa zakonskim rokom do kojeg su zadruge trebale uskladiti opće akte i poslovati u skladu s odredbama ovog Zakona. Iste godine najveći broj zadruga je ostvario ukupnu tehničku efikasnost (3), čistu tehničku efikasnost (6) i efikasnost razmjera (4). Međutim, već

[182] Stvarne nazive poljoprivrednih zadruga zamijenili smo jednostavnim kodovima koje koristimo u prikazivanju rezultata (z1, z2, z3,... do z26).

Tablica 5.1. Efikasnost poslovanja poljoprivrednih zadruga po godinama

Godine	**2009**			**2010**			**2011**			**2012**			**2013**		
Mjere efikasnosti	**UTE**	**ČTE**	**ER**	**UTE**	**ČTE**	**ER**	**UTE**	**ČTE**	**ER**	**UTE**	**ČTE**	**ER**	**UTE**	**ČTE**	**ER**
z1	0,068	0,069	0,994	0,037	0,054	0,684	0,065	0,069	0,940	0,248	0,458	0,542	0,065	0,066	0,995
z2	0,031	0,264	0,116	0,035	0,260	0,136	0,095	0,260	0,365	0,206	0,260	0,793	0,083	0,260	0,320
z3	0,028	0,260	0,106	0,014	0,260	0,055	0,003	0,260	0,012	0,018	0,260	0,070	0,006	0,260	0,023
z4	0,390	**1,000**	0,390	0,087	0,087	0,997	0,089	0,128	0,696	0,266	0,840	0,317	0,154	0,823	0,187
z5	0,375	**1,000**	0,375	0,050	0,594	0,084	0,059	**1,000**	0,059	0,220	0,478	0,461	0,135	0,874	0,154
z6	0,360	**1,000**	0,360	0,131	0,441	0,296	0,069	0,584	0,118	0,642	**1,000**	0,642	0,086	0,565	0,152
z7	0,148	0,382	0,388	0,037	0,188	0,195	0,047	0,452	0,104	0,214	0,372	0,574	0,125	0,893	0,140
z9	0,009	0,129	0,071	0,012	0,128	0,096	**1,000**	**1,000**	**1,000**	0,739	0,980	0,754	0,490	0,520	0,941
z10	0,050	**1,000**	0,050	0,095	**1,000**	0,095	0,396	**1,000**	0,396	**1,000**	**1,000**	**1,000**	0,644	**1,000**	0,644
z11	0,088	0,542	0,163	0,038	0,542	0,070	0,046	0,542	0,086	**1,000**	**1,000**	**1,000**	0,158	0,542	0,291
z12	0,008	0,643	0,012	0,000	0,643	0,000	0,062	0,643	0,097	0,643	0,643	**1,000**	0,010	0,643	0,015
z13	0,000	0,391	0,000	0,058	0,391	0,149	0,082	0,391	0,211	0,288	0,391	0,735	0,300	0,391	0,768
z14	**1,000**	**1,000**	**1,000**	1,000	**1,000**	**1,000**	0,174	0,776	0,224	0,288	0,776	0,371	**1,000**	**1,000**	**1,000**
z16	0,008	0,260	0,032	0,008	0,260	0,032	0,032	0,260	0,123	0,220	0,276	0,797	0,164	0,260	0,630
z17	0,127	0,344	0,368	0,087	0,120	0,724	0,047	0,047	0,999	0,112	0,149	0,754	0,026	0,026	0,964
z19	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**	**1,000**
z20	0,216	0,584	0,369	0,067	0,584	0,115	0,074	0,584	0,126	0,217	0,584	0,372	0,144	0,584	0,246
z21	0,240	**1,000**	0,240	0,081	**1,000**	0,081	0,060	**1,000**	0,060	0,374	**1,000**	0,374	0,097	**1,000**	0,097
z22	0,576	**1,000**	0,576	0,184	**1,000**	0,184	0,157	**1,000**	0,157	0,512	**1,000**	0,512	0,289	**1,000**	0,289
z23	0,287	0,858	0,334	0,074	0,468	0,159	0,083	0,585	0,141	0,332	0,624	0,531	0,180	0,904	0,199
z24	0,275	0,532	0,517	0,072	0,164	0,442	0,054	0,164	0,328	0,135	0,164	0,823	0,073	0,164	0,444
z25	0,474	0,915	0,517	0,131	0,227	0,577	0,071	0,227	0,311	0,695	0,745	0,933	0,278	0,279	0,998
z26	0,000	0,703	0,000	0,000	0,703	0,000	0,079	0,703	0,112	0,515	0,703	0,733	0,234	0,703	0,333
Broj efikasnih DMU	**2**	**8**	**2**	**2**	**5**	**2**	**2**	**6**	**2**	**3**	**6**	**4**	**2**	**5**	**2**
Aritmetička sredina	**0,250**	**0,647**	**0,347**	**0,143**	**0,483**	**0,312**	**0,167**	**0,551**	**0,333**	**0,430**	**0,639**	**0,656**	**0,250**	**0,598**	**0,471**
Medijana	**0,148**	**0,643**	**0,360**	**0,067**	**0,441**	**0,149**	**0,071**	**0,584**	**0,157**	**0,288**	**0,643**	**0,733**	**0,154**	**0,584**	**0,320**
Standardna devijacija	**0,290**	**0,332**	**0,313**	**0,274**	**0,334**	**0,341**	**0,274**	**0,337**	**0,340**	**0,297**	**0,305**	**0,256**	**0,280**	**0,332**	**0,363**

UTE = ukupna tehnička efikasnost (engl. *overall technical efficiency*); **ČTE** = čista tehnička efikasnost (engl. *pure technical efficiency*); **ER** = efikasnost razmjera (engl. *scale efficiency*).
Izvor: Izračun autora na temelju službenih poslovnih podataka FINA-e.

u 2013. godini ponovno dolazi do pada rezultata efikasnosti. Smanjenje rezultata efikasnosti se podudara s donošenjem prvih Izmjena i dopuna Zakona o zadrugama (NN, br. 34/2011, 125/2013) koje nisu uspjele riješiti neke elementarne probleme hrvatskog zadrugarstva.[183]

Rezultati AOMP u skladu su s rezultatima analize legislative i financijskog poslovanja cijelog zadružnog sektora (vidi potpoglavlja 2.5.2. i 2.5.3.). Izvješće HCZP-o pokazuje na negativan trend smanjenja ukupnih prihoda na razini cijelog zadružnog sustava u razdoblju od 2012. do 2014. godine (HCZP, 2016: 11). Analiza po godinama je pokazala da trend kretanja rezultata efikasnosti odražava ekonomske i zakonske promjene koji su se odvijale u vrijeme ekonomske krize i utjecale na efikasnost zadružnog poslovanja u RH. Time je potvrđeno da AOMP može pružiti dragocjene informacije o efikasnosti zadružnog poslovanja i biti koristan dodatak klasičnim financijskim analizama vremenskih poslovnih ciklusa. Iz gornje tablice se također može vidjeti da je zadruga z19 najefikasnija u svim godinama, a zatim redom slijede zadruge z10 i z14. Usporedba efikasnosti poljoprivrednih zadruga je detaljnije analizirana u sljedećem potpoglavlju. Poredak rezultata efikasnosti poslovanja po godinama je u skladu s rezultatima efikasnosti zadružnog poslovanja ukupno gledajući u pet godina.

5.2. Efikasnost zadružnog poslovanja u cijelom razdoblju

U tablici 5.2. (str. 144) su prikazani izračunati rezultati efikasnosti poljoprivrednih zadruga u uvjetima nepromjenjivih i promjenjivih stopa povrata za cijelo petogodišnje razdoblje. Na temelju rezultata je napravljen poredak najefikasnijih zadruga i navedeni su konkretni uzori poslovanja koje trebaju slijediti neefikasne zadruge ako žele postići ukupnu ili čistu tehničku efikasnost. Korištenjem slack varijabli (engl. *slack variables*) u nastavku su obrazložene sugestije koje nudi softver i koji bi zadrugama trebao osigurati povećanje efikasnosti.

Iz tablice je vidljivo da u uzorku postoje dvije poljoprivredne zadruge (z10 i z19) čija ukupna tehnička efikasnost ostvaruje vrijednost jedan ($UTE_{z10,\ z19} = 1$). To znači da dvije zadruge ostvaruju i čistu tehničku efikasnost ($ČTE_{z10,\ z19} = 1$) i efikasnost razmjera ($ER_{z10,\ z19} = 1$) odnosno da navedene zadruge istodobno efikasno koriste resurse u proizvodnji i ostvaruju optimalnu razinu proizvodnje. Vrijednosti njihovih slack varijabli su jednake nuli (0), tj. ciljane

[183] Zadruga ima zakonsku obvezu reinvestiranja dobiti od 20% pri čemu ovaj izdatak nije priznat kao porezna olakšica prema važećem Zakonu o porezu na dobit, dok su društva kapitala oslobođena od plaćanja poreza na reinvestiranu dobit. Također, ostaje neriješeno pitanje zadružne imovine koje se ne može raspodijeliti članovima nego nakon stečaja i likvidacije zadruge ona ostaje u rukama jedinica lokalne samouprave, a ne svojih pravih vlasnika. Potrebno je napomenuti da bankarski sektor nema razumijevanja za zadružni sektor pa se događa da za jamstva za poslovne kredite zadruge banke traže i jamstva članova na njihovu privatnu imovinu (Stanojević, 2015: 55).

vrijednosti inputa i outputa su jednake stvarnim vrijednostima. To znači da su ulazni i izlazni podaci zadruga postignuli maksimalnu učinkovitost i nema prostora za poboljšanje. Te dvije zadruge predstavljaju idealan obrazac poslovanja ostalim poljoprivrednim zadrugama u uzorku jer postižu maksimalnu srednju produktivnost i ostvaruju maksimalne stopa povrata. Zadruga z19 predstavlja idealan obrazac poslovanja za 21 zadrugu, a zadruga z10 za 16 poljoprivrednih zadruga u uzroku (stupac 5 i 6 u Tablici 5.2.).[184]

Potrebno je naglasiti da tri zadruge (z22, z5 i z21) ostvaruju čistu tehničku efikasnost unatoč tome što nisu postigle Pareto-Koopmansovu efikasnost. Ove tri zadruge efikasno raspolažu dionicima i zalihama ($ČTE_{z22}$ = $ČTE_{z5}$ $ČTE_{z21}$ = 1,000), a neefikasnost njihova poslovanja proizlazi iz neadekvatnog volumena proizvodnje (ER_{z22} = 0,263, ER_{z5} = 0,124 i ER_{z21} = 0,105). To potvrđuju slack varijable čije su vrijednosti za promatrane zadruge jednake nula (0). To dokazuje da zadruge surađuju s optimalnim brojem dionika i raspolažu s optimalnim količinama zalihama. Usporedba vrijednosti čiste tehničke efikasnosti i tehničke efikasnosti u uvjetima padajućih stopa povrata ukazuje da je obujam poslovanja iznad optimalne razine zbog čega ove tri zadruge postižu niže stopa povrata i povećavanje prosječnih troškova proizvodnje u promatranom razdoblju (*disekonomija razmjera*).

Čak 18 zadruga u uzorku ne doseže niti jednu razinu efikasnosti. Među njima 10 zadruga posluje ispod optimalnog volumena i postižu rastuće stope povrata (*ekonomija razmjera*).[185] Kod ove podskupine zadruga svako povećanje volumena proizvodnje trebalo bi rezultirati smanjenjem troškova po jedinici proizvoda i poboljšanjem tehničke efikasnosti.[186] Međutim, proširenje proizvodnje nije najbolje rješenje za osam zadruga ove podskupine (z3, z11, z12, z13, z14, z16, z20 i z26). Veće vrijednosti čiste tehničke efikasnosti u odnosu na vrijednosti efikasnosti razmjera sugeriraju da ovih 8 zadruga prvo trebaju poboljšati raspodjelu inputa i outputa, a tek onda u sljedećem koraku proširiti svoje poslovanje. Slack varijable potvrđuju navedeno i ukazuju da ova podskupina zadruga ako želi postići ukupnu tehničku efikasnost svoju strategiju poslovanja treba prvenstveno usmjeriti optimizaciji svojih ukupnih prihoda i ukupnih rashoda (stupac SY1 i SY2).[187]

---

[184] Prema BCC modelu, zadruga z19 je uzor za 18 zadruga, dok je zadruga z10 uzor za 11 zadruga.

[185] Radi se o zadrugama koje su označene kodovima: z2, z3, z11, z12, z13, z14, z16, z20, z24 i z26.

[186] Proširenje poslovanja dovesti će do povećanja efikasnosti zadruga z2 i z24 (ČTE < ER). Nakon što postigne optimalan volumen poslovanja, zadruga z2 može dodatno povećati ukupnu tehničku efikasnost ako smanji broj dionika za 0,42 i proda zalihe u protuvrijednosti od 18.434,38 kuna. Zadruga z24 treba prodati zalihe u vrijednosti od 162.131,52 kuna, povećati prihode za 3.758.463,00 kuna ili smanjiti rashode za 3.854.991,80 ako želi postići efikasnost kakvu imaju zadruge z10 i z19.

[187] Osim optimizacije ukupnih prihoda i ukupnih rashoda, zadrugama z13 i z20 se isto tako predlaže da smanje ili prodaju svoje zalihe ($SX2_{z13}$ = 15.499,93 i $SX2_{z20}$ = 62.396,43).

Tablica 5.2. Efikasnost poljoprivrednih zadruga u pet godina ukupno

	Rezultati efikasnosti			Slack varijable				Broj preporuka		Broj uzora		Uzori		Poredak zadruga	Stope povrata
				INPUTI		OUTPUTI									
	UTE	ČTE	ER	Dionici SX1	Zalihe SX2	Prihodi SY1	Rashodi SY2	CCR	BCC	CCR	BCC	CCR	BCC		
z1	0,123	0,130	0,944	9,87		61.072,31				2	2	z10, z19	z10, z19	13	Padajuće
z2	0,244	0,260	0,938	0,42			18.434,38			2	2	z10, z19	z10, z19	7	Rastuće
z3	0,011	0,260	0,039			2.861.578,62	2.855.142,05			2	2	z10, z19	z10, z19	23	Rastuće
z4	0,137	0,627	0,219				56.477,11			1	3	z19	z19, z21, z22	10	Padajuće
z5	0,124	**1,000**	0,124						3	2	0	z10, z19		12	Padajuće
z6	0,173	0,954	0,181	11,40			201.486,58			2	2	z10, z19	z5, z19	8	Padajuće
z7	0,093	0,557	0,167	44,58			965.554,09			2	2	z10, z19	z5, z19	17	Padajuće
z9	0,317	0,331	0,958	11,48			67.783,04			2	2	z10, z19	z10, z19	4	Padajuće
z10	**1,000**	**1,000**	**1,000**					16	11	0	0			2	Nepromjenjive
z11	0,076	0,542	0,140			3.350.256,59	3.279.154,02			2	2	z10, z19	z10, z19	20	Rastuće
z12	0,020	0,643	0,031			1.244.451,72	1.254.315,05			2	2	z10, z19	z10, z19	22	Rastuće
z13	0,129	0,391	0,330		15.499,93	5.487.160,00	5.491.885,00			1	1	z19	z19	11	Rastuće
z14	0,590	0,776	0,761			300.593,80	229.844,02			2	2	z10, z19	z10, z19	3	Rastuće
z16	0,064	0,260	0,246			745.113,66	737.179,94			2	2	z10, z19	z10, z19	21	Rastuće
z17	0,086	0,088	0,972	29,97		64.466,00				2	2	z10, z19	z10, z19	19	Padajuće
z19	**1,000**	**1,000**	**1,000**					21	18	0	0			1	Nepromjenjive
z20	0,112	0,584	0,192		62.396,43	6.618.584,80	6.573.618,80			1	1	z19	z19	14	Rastuće
z21	0,105	**1,000**	0,105						2	2	0	z10, z19		16	Padajuće
z22	0,263	**1,000**	0,263						1	1	0	z19		5	Padajuće
z23	0,109	0,600	0,182				32.239,26			2	3	z10, z19	z5, z19, z21	15	Padajuće
z24	0,089	0,164	0,541		162.131,52	3.758.463,00	3.854.991,80			1	1	z19	z19	18	Rastuće
z25	0,258	0,258	0,998	1,06			259.849,67			2	2	z10, z19	z10, z19	6	Padajuće
z26	0,142	0,703	0,202			5.322.768,40	5.391.066,83			2	2	z10, z19	z10, z19	9	Rastuće
Broj efikasnih DMU	**2**	**5**	**2**												
Aritmetička sredina	**0,229**	**0,571**	**0,458**												
Medijana	**0,124**	**0,584**	**0,248**												
Standardna devijacija	**0,272**	**0,317**	**0,380**												

UTE = ukupna tehnička efikasnost (engl. *overall technical efficiency*); **ČTE** = čista tehnička efikasnost (engl. *pure technical efficiency*); **ER** = efikasnost razmjera (engl. *scale efficiency*).
Zadruge **z10** i **z19** ostvaruju ukupnu tehničku efikasnost (CCR), čistu tehničku efikasnost (BCC) i efikasnost razmjera (idealan obrazac poslovanja za ostale zadruge u uzorku).
Zadruge **z5**, **z21** i **z23** ostvaruju čistu tehničku efikasnost (unatoč efikasnom korištenju resursa one posluju iznad svog optimalnog volumena poslovanja).
Izvor: Izračun autora na temelju službenih poslovnih podataka FINA-e.

Zadnju podskupinu čini 8 zadruga koje posluju iznad svojeg optimalnog volumena i postižu padajuće stope povrata (disekonomija razmjera).[188] Najbolje rješenje za upravitelje zadruga ove podskupine je smanjiti utrošak inputa i opseg poslovanja kako bi se smanjili troškovi i povećala ukupna efikasnost zadružne proizvodnje. Uspoređivanje vrijednosti čiste tehničke efikasnosti i efikasnosti razmjera ukazuje da 3 zadruge posljednje podskupine (z1, z9 i z17) prvo trebaju smanjiti opseg svojeg poslovanja, a zatim poboljšati raspodjelu broja dionika i količine zaliha. Dopunske varijable ukazuju na problem viška ljudskog kapitala u zadružnom poslovanju kod ove podskupine zadruga.[189] Ostalih 5 zadruga (z4, z6, z7, z23 i z25) imati će veće koristi ako u prvom koraku optimiziraju broj dionika i količinu zaliha kojima raspolažu, a zatim u drugom koraku pokušaju smanjiti volumen zadružne proizvodnje.[190]

Ograničenje doktorske disertacije je povezano s neprikladnom bazom financijskih podataka koja sadrži najosnovnije pokazatelje koji se uobičajeno koriste u standardnim financijskim analizama poslovanja investicijski usmjerenih poduzeća. Iz službenih financijskih podataka nemoguće je izračunati pokazatelje *likvidnosti*, *zaduženosti*, *aktivnosti* ili *investiranja*. Iako ovi financijski pokazatelji ne mogu vjerodostojno ocijeniti učinkovitost zadružnog poslovanja mogućnost njihovog izračunavanja ipak daje bolji uvid u ekonomske mogućnosti zadružnog poduzetništva. Nemogućnost računanja financijskih pokazatelja rezultira gubitkom interesa od strane istraživača, javnog mijenja, gubitkom političke i institucijske potpore, te razvojem nepotpune percepcije i predrasuda o ekonomskim mogućnostima zadružnog sektora.

5.3. CFA model za mjerenje stupnja usvojenosti zadružnih načela

Na temelju pokazatelja zadržanih u konačnom modelu (Model 1.8) analizirali smo odnose koje ispitanici i poljoprivredne zadruge razvijaju prilikom međusobne suradnje. U tablici 4.5. (str. 112) su prikazana pripadajuća zasićenja i komunaliteti svih zadržanih pokazatelja u konačnom CFA modelu sa šest latentnih faktora. Struktura CFA modela za mjerenje stupnja usvojenosti zadružnih načela je grafički prikazana na Slici 4.1. (str. 133). Analiza je potvrdila robustnost (invarijantnost) CFA modela, konvergentnu validnost konstrukata i pokazatelja,

[188] Radi se o zadrugama koje su označene kodovima: z1, z4, z6, z7, z9, z17, z23 i z25.

[189] Nakon smanjenja opsega proizvodnje zadruga z1 bi trebala smanjiti broj dionika za 9,87, zadruga z9 za 11,48, a zadruga z17 za 29,97. Rezultati analize predlažu povećanje prihoda (SX_{z1} = 61.072,31 i SX_{z17} = 64.466,00) i ukupnih rashoda (SX_{z7} = 965.554,09) ako se želi postići efikasnost kakvu imaju zadruge z10 i z19.

[190] Vrijednosti dopunskih varijabla sugeriraju smanjenje broja dionika (SX_{z6} = 11,40; SX_{z7} = 44,58 i SX_{z25} = 1,06) i rashoda u cilju postizanja ukupne tehničke efikasnosti poslovanja (SX_{z4} = 56.477,11; SX_{z6} = 201.486,58; SX_{z7} = 965.554,09; SX_{z23} = 32.239,26 i SX_{z25} = 259.849,67).

unutarnju konzistenciju skala koje opisuju sadržaj varijance zadružnih načela.[191] U nastavku su objašnjene karakteristike konačnog CFA modela (Model 1.8).

Rezultati EFA i CFA su pokazali da *Skala za mjerenje stupnja usvojenosti zadružnih načela* predstavlja višedimenzionalni konstrukt koji je definiran sa šest faktora: **F1** *Međuzadružna suradnja* (Načelo 6), **F2** *Poslovna autonomija* (Načelo 4), **F3** *Briga za lokalnu zajednicu* (Načelo 7), **F4** *Gospodarsko sudjelovanje* (Načelo 3), **F5** *Zadružna edukacija* (Načelo 5) i **F6** *Demokratičnost poslovanja* (Načelo 2). Struktura konačnog modela je u skladu s teorijom zadružnih načela (vidi potpoglavlje 2.1., str. 7).

Faktor 1 (Načelo 4. Poslovna autonomija). Strukturu prvog faktora definiraju pokazatelji *neovisnosti tijekom korištenja usluga kreditnih institucija* (autonomija2), *institucija nadležnih za promoviranje zadružnog poduzetništva* (autonomija4) i *resornih Ministarstava za razvoj zadružnog poslovanja* (autonomija5). Deskriptivna analiza je potvrdila da zadruga zadržava poslovnu neovisnost, odnosno da osigurava demokratsku kontrolu i provodi interese svojih članova.[192] Rezultati ukazuju da prilikom privlačenja vanjskih investitora i poslovnih partnera uloženi kapital ne regulira kontrolu nad poslovanjem, nego zadruge i dalje služe interesima svojih vjerovnika. Zadruge su organizacije koje autonomiju zadržavaju oslanjanjem na zajedničke resurse i rad svojih članova. U situacijama kada se sklapaju sporazumi s drugim organizacijama, ili prikuplja kapital iz vanjskih izvora, zadruge to čine na način koji osigurava demokratsku kontrolu članova i autonomiju poslovanja. U tome, državne inicijative i podrška su oduvijek bili neophodne za razvoj zadružnog poslovanja. Međutim, kao kod drugih oblika suradnje tako i tijekom suradnje s državnim institucijama zadruge i članovi moraju zadržati neovisnost i kontrolirati vlastitu sudbinu. Zadruga je samostalna i neovisna jedino kada je kontrola u rukama članova i kada je u skladu s otvorenom, transparentnom i odgovornom demokratskom praksom.

Faktor 2 (Načelo 3. Gospodarsko sudjelovanje). Strukturu faktora definiraju pokazatelji *važnost održavanja broja članova* (otvorenost1), *važnost ulaska novih članova u zadruge* (otvorenost2), *pomaganje članovima kada ne mogu samostalno djelovati* (gospSurad1), *važnost nastavka suradnje unatoč manjim novčanim prihodima* (gospSurad5), *suradnja između članova i Upravitelja* (gospSurad7) i *utjecaj povjerenja na stupanj suradnje između*

[191] Vrijednosti Cronbachov alfa koeficijenata za **F1** *Međuzadružna suradnja* iznosi 0,788 (3 čestice), za **F2** *Gospodarsko sudjelovanje* iznosi 0,764 (6 čestica), za **F3** *Poslovna autonomija* iznosi 0,788 (3 čestice), **F4** *Briga za lokalnu zajednicu* iznosi 0,721 (3 čestice), za **F5** *Zadružna edukacija* iznosi 0,835 (3 čestice), a za **F6** *Demokratičnost* iznosi 0,691 (3 čestice).

[192] Više od dvije trećine ispitanika se slaže, ili se u potpunosti slaže, da zadruga zadržava poslovnu neovisnost prilikom suradnje s kreditnim institucijama (79%), HCZP i zadružnim savezima (77%), te s ministarstvima nadležnim za razvoj zadružnog poduzetništva (75%).

članova i zadruge (gospSurad8). Pokazatelji naglašavaju važnost članova u gospodarskoj suradnji i utjecaj njihove brojnosti na poslovni rezultat zadruge. U poslovnoj suradnji važnim se pokazuje povjerenje i uzajamnost koji mogu imati presudan utjecaj na intenzitet suradnje unutar zadruge. Također, stupanj gospodarske suradnje ovisi o obliku komunikacije između skupštine (članova) zadruge i upravitelja u procesu poslovnog odlučivanja. Strukturu faktora također opisuju pokazatelji koji ukazuju na svjesnost dionika o važnosti nastavka zajedničke suradnje u uvjetima nepovoljnih tržišnih prilika.[193] Neki od rezultata deskriptivne analize su u skladu s istraživanjem Bruynisa i sur. (2001) koji potvrđuju da je volumen suradnje između zadruge i njenih članova od presudne važnosti za sposobnost preživljavanja novoosnovanih zadruga posebice u prve tri godine od osnutka. Osim toga, novoosnovane zadruge s većim volumenom poslovanja imaju veću vjerojatnost da ispune očekivanja svojih članova (38%).

Faktor 3 (Načelo 6. Međuzadružna suradnja). Strukturu trećeg latentnog faktora definiraju pokazatelji *suradnja s lokalnim zadružnim savezima* (zadSurad2), *suradnja s resornim Ministarstvima za razvoj zadrugarstva* (zadSurad4) i *sudjelovanje na skupovima iz područja zadružnog poduzetništva* (zadSurad8).[194] Deskriptivna statistika je pokazala na nezavidnu situaciju u hrvatskom zadružnom sektoru po pitanju uzajamne suradnje. Prema Putnamu (1993) to je dobar primjer slabije organizacijske povezanosti koja ukazuje na nedostatak povjerenja i niske zalihe socijalnog kapitala unutar hrvatskog zadružnog sustava. Učestalije organiziranje i održavanje formalno-pravnih oblika suradnji postavit će kvalitetne temelje za budući razvoj zadružnog poduzetništva. Surađujući na lokalnoj i nacionalnoj razini zadruge mogu najučinkovitije služiti svojim članovima i doprinositi jačanju zadružnog sustava. Prema Božiću i sur. (2020) suradnja unutar zadružnog sustava ubrzati će izgradnju nacionalne baze podataka koja će sadržavati sve moguće partnere i protokole suradnje. Na temelju toga replicirati će se primjeri dobre prakse i uspostaviti budući trajni sporazumi suradnje. Putem ovakvih oblika suradnji zadruge će dijeliti iskustva, te educirati upravitelje i dionike. Osim toga jačanje poslovne suradnje na principu solidarnosti, a ne tržišnog međusobnog

[193] Čak 160 ispitanika se slaže da zadruge aktivno sudjeluju u održavanju trenutnog broja članova (79%), dok se 93 ispitanika slaže da njihove zadruge odobravaju ulazak novih članova (46%). Od ukupnog broja, 138 ispitanika se slaže da zadruga pomaže u situacijama kada ne mogu samostalno poslovati (68%), 166 ispitanika je odgovorilo da im je suradnja sa zadrugom prioritet i u situacijama kada ona donosi manje prihoda (82%) i 140 ispitanika smatra da povjerenje utječe na svakodnevnu suradnju i izgradnju uzajamnosti (69%). Samo 59 ispitanika smatra da upravitelj zadruge uvažava mišljenja članova prilikom donošenja konačnih odluka (29%).

[194] Rezultati su pokazali da se suradnja unutar zadružnog sektora ne događa često ili je povremenog karaktera. Čak 92 ispitanika je odgovorilo da uopće ne koristi ili rijetko koristi usluge HCZP i lokalnih zadružnih saveza (46%), 73 ispitanika je odgovorilo da ne surađuje ili rijetko surađuje s nadležnim Ministarstvima (36%), dok 62 ispitanika rijetko sudjeluje na zadružnim konferencijama (31%).

nadmetanja povećati će prepoznatljivost zadružnih organizacija i konkurentnost zadružnih proizvoda na tržištu.[195]

Faktor 4 (Načelo 7. Briga za lokalnu zajednicu). Strukturu faktora definiraju pokazatelji *plaćanje zdravstvenog osiguranja za članove i zaposlene* (brigaZajed1), *ulaganje u zaštitu okoliša i ekološku proizvodnju* (brigaZajed4) i *ulaganje u inovativne tehnologije proizvodnje* (brigaZajed6).[196] Iz naše analize je vidljivo da se briga zadruga svodi na tri oblika ulaganja od čega su dva usmjerena na inovativne oblike proizvodnje koji u budućnosti mogu dovesti do novih izvora zarade. Osim toga, putem suradnje i pomaganja članovima, zapošljavanjem i osposobljavanjem lokalnog stanovništva, plaćanjem zdravstvenog osiguranja ove zadruge doprinose jačanju lokalne ekonomije. Načelo osigurava da fokus zadruge osim ekonomskih interesa uključuje i ciljeve koji izražavaju predanost zadruge lokalnoj zajednici. Svojstvena briga zadruga može se očitovati u naporima koje provodi na terenu. Veliki broj članaka i istraživanja pokazuje da zadruge u svijetu uspješno pomažu lokalnim zajednicama u obliku zaposlenja, povećanja lokalne štednje, unapređenja okoliša i zaštite prirode, promoviranja aktivnog stanovništva i izgradnje potrebne društvene infrastrukture (HSZ, 2005; Simmons i sur., 2010). Na taj način zadruge doprinose održivom razvoju u kojem se isprepliću različiti ekonomski, društveni, sociokulturološki i politički interesi članova. Zadruge mogu uspješno voditi brigu i politiku o održivom razvoju lokalnih zajednica, ali uz preduvjet da je prethodno odobre i prihvate svi njeni članovi (skupština).

Faktor 5 (Načelo 5. Zadružna edukacija). Strukturu petog faktora definiraju pokazatelji *samoinicijativno informiranje članova* (edukacija1), *informiranje korištenjem usluga HCZP i zadružnih saveza* (edukacija2) i *informiranje korištenjem usluga nadležnih Ministarstava* (edukacija3).[197] Edukacija dionika unutar zadruge je podijeljena na dvije razine. Prva razina

---

[195] Zadnjih dvadesetak godina zadruge diljem svijeta za promociju vlastitih proizvoda koriste internet domenu (*.coop*). Internet domena predstavlja zajednički zadružni logo i dodjeljuje se organizacijama koje promoviraju zadružno organiziranje (ICA, 2021). U RH je do sada ukupno tri zadruge koristilo domenu *.coop* za promoviranje svojih usluga. Trenutno je koriste dvije zadruge iz Zagreba: Zadruga za etičko financiranje i Zelena energetska zadruga za usluge.

[196] Na pitanje o ulaganju u zdravstveno osiguranje dionika zadružnog poslovanja dobili smo oprečne odgovore. S jedne strane, 82 ispitanika je odgovorilo da zadruga ne plaća zdravstveno osiguranje (41%), dok je 60 ispitanika odgovorilo da zadruga plaća zdravstveno osiguranje (30%). Od ukupnog broja ispitanika, njih 78 se slaže da zadruga ulaže dio prihoda u zaštitu okoliša (39%), dok se 42 ispitanika s time ne slaže (21%). Najujednačeniji odgovori su dobiveni na pitanje o ulaganjima u nove tehnologije proizvodnje gdje se 102 ispitanika složilo da zadruga ulaže dio prihoda u nove tehnologije proizvodnje (50%), dok se s druge strane 29 ispitanika s time ne slaže (14%).

[197] Od ukupnog broja ispitanika, njih 88 barem jednom ili više puta godišnje samoinicijativno pročita neku stručnu literaturu (44%), a samo 16 ispitanika barem jednom mjesečno koristi stručnu literaturu (8%). S druge strane, 108 ispitanika barem jednom godišnje sudjeluje na radionicama koje organizira HCZP i zadružni savezi (54%), dok 110 ispitanika barem jednom godišnje koristi usluge relevantnih Ministarstava (55%).

se svodi na vlastitu želju dionika da si pomogne u uklanjanju eventualnih problema, a druga razina se svodi na korištenje literature i pohađanje strukovnih radionica koje organiziraju institucije nadležne za promociju i razvoj zadrugarstva. Međutim, organizacija skupova je prigodnog i povremenog karaktera zbog čega se edukacija u zadrugama prvenstveno svodi na samopomoći i uzajamnosti. Strukovni i formalni oblici obrazovanja, organizirani od strane javnih institucija, mogu biti važna okosnica za efikasnost zadružnog poslovanja. Time bi se povećalo razumijevanje vlasničkih prava i odgovornosti dionika unutar zadruge, pozitivno utjecalo na aktivnost članova i informiralo vodstvo zadruge o upravljačkim vještinama koje osiguravaju dugoročne interese zadruge i dionika. Nedostatak formalnih oblika obrazovanja smanjuje vjerojatnost budućeg uspješnog razvoja hrvatskog zadružnog sustava. Bruynis i sur. (2001) su empirijski utvrdili da *kontinuirani treninzi za upravitelja i nadzorni odbor* imaju značajan utjecaj na povećanje dugovječnosti zadružnog poslovanja (15%), rast plasmana proizvoda od strane članova (41%) i zadovoljstva članova zadruge (26%).

Faktor 6 (Načelo 2. Demokratičnost poslovanja). Strukturu posljednjeg faktora definiraju pokazatelji *briga o interesima članova* (demokratičnost2), *postojanje unutrašnjih pravilnika koji reguliraju stabilnost poslovanja i sigurnost članova* (demokratičnost3) i *osiguravanje zajedničkog vlasništva članova nad zadružnom imovinom* (demokratičnost5).[198] Ovo načelo garantira da svaki član u zadruzi ima jedan glas u odlučivanju bez obzira na visinu kapitala koji je uložio ili volumen proizvodnje koji je plasirao putem zadruge. Na taj način se potiče da cijela skupština zadruge bude informirana o svim relevantnim dijelovima poslovanja i svi članovi budu aktivno uključeni u razumno donošenje odluka. Također, načelo ima za cilj sprječavati koncentraciju kontrole u rukama nekolicine. Međutim odgovori ispitanika dovode u pitanje ispravnost provođenja demokratske kontrole. Zadruge nemaju kvalitetno uređene unutrašnje pravilnike koji bi precizno regulirali cijene i provizije za korištenje usluga, ali i sigurnost interesa svojih članova. Njihova politika poslovanja dovodi u pitanje da li vodstvo zadruga pogoduje povećanju udjela zajedničkog ili privatnog vlasništva. Zbog toga možemo zaključiti da zadruge predstavljaju neuređeno društvo osoba gdje svatko tumači načela na svoj način, te posluje i odgovara za vlastite postupke. Dionici zadružnog poslovanja načelo demokratske kontrole prepoznaju jedino u slobodi odabira hoće li plasirati svoju proizvodnju putem zadruga. Način poslovanja koji pogoduje interesima kapitala, a ne članova zadruge (Nedanov i sur., 2013), kao i pitanje plasmana robe mimo zadruge (engl. *free-rider problem*)

[198] Samo 40 ispitanika se slaže da zadruga vodi brigu o interesima svojih članova (19%), 24 ispitanika se slaže da zadruga ima definirane unutrašnje pravilnike koji reguliraju norme ponašanja i stabilnost poslovanja (12%) i 34 ispitanika se slaže da zadruga svojim načinom poslovanja podupire zajedničko upravljanje članova zadružnom imovinom (17%). Treba napomenuti da je 32 ispitanika zaposleno u zadruzi i još 8 ispitanika surađuje sa zadrugom. Za razliku od punopravnih članova ove dvije skupine ispitanika ne sudjeluju u donošenju odluka i nemaju vlasnička prava nad zadružnom imovinom.

su učestali problemi zadružnog poduzetništva koji su zabilježeni diljem svijeta pa tako i na našim prostorima (Božić i sur., 2020).

Potrebno je napomenuti da jedino prvo zadružno načelo *otvorenosti i dragovoljnosti* (N1) nije prepoznato kao zaseban konstrukt jer pokazatelji otvorenosti neprecizno objašnjavaju odnose u modelu ili se sadržajno povezuju s drugim zadružnim načelom (vidi potpoglavlje 4.2.2., str. 113). Pokazatelj da *zadruga treba biti otvorena prema svim zainteresiranim osobama bez obzira na njegovu spolnu, nacionalnu (etničku), socijalnu, političku ili vjersku pripadnost* (otvorenost3) nema statistički značaj u objašnjavanju ukupne varijance modela zbog čega je uklonjen iz konačnog CFA modela (vidi Tablica 4.5., str. 112). [199] Njegovo neuklapanje u konačan CFA model je potvrdila SEPC statistika i MI indeksi prilagodbe. Preostala dva pokazatelja otvorenosti (otvorenost1 i otvorenost2) imaju statistički značaj u objašnjavanju ukupne varijance četvrtog faktora koji opisuje zadružno načelo *Gospodarsko sudjelovanje* (N3). Sadržajni značaj ova dva pokazatelja otvorenosti ima logičku i sadržajnu povezanost s četvrtim faktorom zbog čega su zadržani i predstavljaju sastavni dio konačnog CFA modela. Struktura konačnog CFA modela s dvadeset i jednim pokazateljem koji opisuju šest latentnih faktora je u potpunosti u skladu s teorijom zadružnih načela.

5.4. Rangiranje poslovnih varijabli obzirom na zadružna načela

Problem složenog sustava može imati mnogo uzroka koji su često međusobno povezani na načine koji mogu biti logički neshvatljivi za istraživača. U tim situacijama potrebno je koristiti iskustvo, intuiciju ili osjećaje kako bi se procijenili učinci problema i odredila mjesta gdje bi se, prema prioritetu, trebali uložiti napori istraživača u cilju uspješnog rješavanja problema. Unatoč vještinama i poznavanju problematike kojom se bave, mnogi istraživači, danas nisu u mogućnosti eksplicitno izmjeriti i razumjeti složenost odnosa koje istražuju. U tome može pomoći Metoda potencijala (Čaklović, 2002), pouzdana matematička metoda koja povezuje subjektivne prosudbe sa znanstvenim, ekonomskim, socijalnim, političkim i drugim vrstama podataka koji mogu imati utjecaj na razumijevanje istraživačkog problema.[200] Za potrebe

[199] Deskriptivna analiza je pokazala da se 149 ispitanika slaže, ili se u potpunosti slaže, da zadruga treba biti otvorena prema svim zainteresiranim pojedincima bez obzira na njihovu pripadnost (74%). Nasuprot njima, 15 ispitanika se ne slaže, ili se u potpunosti ne slaže, s navedenom tvrdnjom (7%). Čak 38 ispitanika nema jasno izražene stavove tj. niti se slažu, niti se ne slažu s tvrdnjom (19%).

[200] Metoda potencijala (Čaklović, 2002) je sposobna matematički povezivati kvantitativne empirijske i anketne podatke, kao i subjektivne stavove, iskustva, osjećaje i spoznaje relevantne za istraživanje. Metoda potencijala može pomoći u razvijanju okvira za analizu faktora koji utječu na ishod složene odluke, izvršiti mjerenje troškova i koristi te sukladno tome rasporediti resurse, predvidjeti vrijednost očekivanog ishoda kao što je očekivana otkupna cijena mlijeka, utvrditi prioritete za skup aktivnosti i

našeg empirijskog istraživanja Metoda potencijala (MP) se koristi za spajanje ekonomskih parametara i zadružnih načela koji zajedno čine ulazne podatke u vrednovanju hijerarhije.

Značaj četiri poslovna pokazatelja u mjerenju tehničke efikasnosti poljoprivrednih zadruga je potvrdila AOMP. Na efikasnost zadružnog poslovanja najveći utjecaj imaju pokazatelji: *dionici* (D), *zalihe* (Z), *ukupni prihodi* (P) i *ukupni rashodi* (R). Diskriminativnu i konvergentnu validnost korištenih skala za mjerenje stupnja usvojenosti šest zadružnih načela je potvrdila CFA. Faktorska analiza je potvrdila važnost šest zadružnih načela: *poslovna autonomija* (N4), *gospodarsko sudjelovanje* (N3), *međuzadružna suradnja* (N6), *briga za lokalnu zajednicu* (N7), *zadružna edukacija* (N6) i *demokratičnost poslovanja* (N3).

U prvom koraku samodualne hijerarhije rangirali smo ekonomske pokazatelje obzirom na zadružna načela (Razina 2), dok je u drugom koraku napravljen poredak zadružnih načela obzirom na ekonomske pokazatelje (Razina 3). U trećem koraku samodualne hijerarhije je napravljen konačan poredak važnosti zadružnih načela koji uvažava postojanje sinergije između zadružnih načela (Razina 4). Sve dobivene vrijednosti su objašnjene u nastavku i rezultat su iterativnog postupka koji je opisan u potpoglavlju 3.7.9 (str. 100).

U Tablici 5.2. se nalaze vrijednosti potencijala poslovnih pokazatelja (alternative) u odnosu na svako zadružno načelo (atributi) i vrijednosti ukupnog potencijala za agregirani multigraf preferencije.[201] Svi grafovi preferencije su prikazani na slici 4.3. (str. 139), a multigraf preferencije se nalazi na slici 4.2. (lijevi graf, str. 134). U nastavku su objašnjene izračunate vrijednosti potencijala na temelju kojih je napravljen konačan poredak. Poredak ekonomskih pokazatelja obzirom na zadružna načela kao kriterije čine redom: *dionici* (X_{UK2} = 1,583), *prihodi* (X_{UK2} = 0,25), *zalihe* (X_{UK2} = -0,417) i *rashodi* (X_{UK2} = -1,417).

Prvo rangirani ekonomski pokazatelj u konačnom poretku su *dionici* zadružnog poslovanja (D). Vrijednost potencijala potvrđuje njegovu izrazitu dominaciju nad ostalim ekonomskim pokazateljima (X_{UK2} = 1,583). Važnost pokazatelja *dionici* je najviše izražena u kontekstu načela demokratičnosti poslovanja (X_{N2} = 1,5), poslovne autonomije (X_{N4} = 1,75), zadružnog obrazovanja (X_{N5} = 1,75) i brige za lokalnu zajednicu (X_{N7} = 2,25) gdje se nalazi na vodećem mjestu u poretku. Pokazatelj se nalazi na drugom mjestu u poretku kada ga promatramo u

napraviti najbolji izbor, ili kombinaciju izbora, na temelju tih prioriteta, pa čak i izmjeriti dosljednost podataka odnosno koliko osobe koje donose odluke dobro razumiju odnose.

[201] Potencijal ekonomskih pokazatelja za svako zadružno načelo zasebno je dobiven iz pojedinačnih grafova preferencije (engl. *individual rankings*), dok je ukupni potencijal izračunat na isti način nakon agregiranja pojedinačnih grafova preferencije u multigraf preferencije (engl. *global rankings*).

kontekstu načela gospodarsko sudjelovanje (X_{N3} = 0,75) i dijeli prvo mjesto s pokazateljem *ukupni prihodi* u kontekstu poslovne suradnje s lokalnim zadrugama (X_{N6} = 1,5).

Tablica 5.3. Potencijal i poredak poslovnih pokazatelja (Razina 2)

	X_{N2}	X_{N3}	X_{N4}	X_{N5}	X_{N6}	X_{N7}	X_{UK2} [202]	Poredak
X_{UK3}	− 0,375	1,875	− 0,625	− 0,875	1,375	− 1,375		
Dionici	1,5	0,75	1,75	1,75	1,5	2,25	**1,583**	**1**
Zalihe	0,5	− 0,25	0,75	− 1,25	− 0,5	− 1,75	**− 0,417**	**3**
Prihodi	-0,5	1,75	− 1,25	− 0,25	1,5	0,25	**0,25**	**2**
Rashodi	-1,5	− 2,25	− 1,25	− 0,25	− 2,5	− 0,75	**− 1,417**	**4**
Suma	**0,00**	**0,00**	**0,00**	**0,00**	**0,00**	**0,00**	**− 0,001**	

X_{N2}, X_{N3}, X_{N4}, X_{N5}, X_{N6} i **X_{N7}** = potencijal poslovnih pokazatelja u odnosu na zadružna načela.
X_{UK2} = ukupni potencijal na temelju kojeg se radi konačan poredak Razine 2 (stupac 9).
X_{UK3} = ukupni potencijal zadružnih načela na Razini 3 (vidi tablicu 5.4., str. 157).
Izvor: Autorska obrada podataka.

Vrijednost ukupnog potencijala i poredak obzirom na navedena zadružna načela ukazuju na važnost participiranja dionika u svim segmentima zadružnog poslovanja. Sudjelovanje dionika je izravno povezano s poslovnim uspjehom zadruge koji uvelike ovisi o volumenu proizvodnje koju dionici odluče plasirati na tržište putem zadruge. Osim navedenog, dionici su važan čimbenik zadružnog poslovanja jer sudjeluju u preuzimanju odgovornosti, kontroli, poslovnom odlučivanju i financiranju zadruge. Osim poslovnih prednosti zadruga dionicima pruža mogućnost stručnog osposobljavanja u području profesionalnog djelovanja zadruge i njenih dionika. Na taj način se dugoročno gledajući mogu povećati koristi za zadrugu i članove. Zato se promicanje znanja, protok informacija i obrazovanje dionika smatra važnim zadatkom upravitelja zadruge. Takav pristup, osim stručnog i profesionalnog usavršavanja dionika, pospješuje društveni razvoj lokalnih zajednica i osigurava razumijevanje zadružnih organizacija, njihovih prednosti i razlika u odnosu na druge poslovne subjekte.

Vodeće mjesto u poretku i velika razlika u vrijednosti potencijala pokazatelja *dionici* (X_{UK2} = 1,583), u odnosu na preostale poslovne pokazatelje, je logična za očekivati obzirom da je zadruga posebna vrsta trgovačkog društva koja se pravno klasificira kao *društvo osoba*.[203]

[202] Vrijednost ukupnog potencijala (stupac X_{UK2}) je aritmetička sredina pojedinačnih potencijala za svaki poslovni pokazatelj koji se promatra u odnosu na zadružna načela (X_{N2},… , X_{N7}). Navedeno vrijedi samo u slučaju kada je graf preferencije potpun. Također, u konzistentnom grafu preferencije razlika između ukupnog toka koji ulazi i ukupnog toka koji izlazi iz čvora je uvijek jednaka nuli (0). U našem slučaju, zbog zaokruživanja vrijednosti na tri decimalna mjesta zbroj ukupnih potencijala za svaki poslovni pokazatelj u stupcu X_{UK2} iznosi (−0,001) što je približno jednako nuli ($X_{UK2} \approx 0$).

[203] Trgovačka društva se klasificiraju u dvije osnovne skupine: *društvo kapitala* (d.d., d.o.o.) i *društvo osoba* (zadruga, udruga). Za postojanje društva osoba nije bitan kapital, a u društvo se ulazi obzirom

Za razliku od društva kapitala zadruge obilježava osobnost, zajednički rad i doprinos njenih dionika. Razlozi ulaska dionika u zadruge jesu prvenstveno ekonomske prirode, međutim ljudski potencijali i socijalni kapital oduvijek su bili neizostavne karike zadružnog poslovanja. Unutarnja koordinacija i alokacija zadružnih resursa je određena kvalitetom međuljudskih odnosa između članova, uprave, kooperanata i zaposlenika unutar zadruge. Veliku ulogu u tome imaju zadružna načela demokratičnosti (N2), poslovne autonomije (N4), obrazovanja (N5) i brige za lokalnu zajednicu (N7) koja predstavljaju upravljačke instrumente usmjerene jačanju socijalnog kapitala unutar zadruga (engl. *social capital*). Ova načela zajedno utječu na akumulaciju i distribuciju povjerenja, solidarnosti, stopa reciprociteta i uzajamnosti na svim razinama zadružnog poslovanja. Što su odnosi kvalitetnije uređeni, to će komunikacija, koordinacija i zajedničko odlučivanje biti fleksibilnije i jednostavnije za provesti. Na kraju to će rezultirati kvalitetnijim poslovnim rezultatima i većim materijalnim koristima od zadružne suradnje jer socijalni kapital za zadruge ima istu važnost kao što investicije i upravljačka struktura imaju za društva kapitala. Zadruge se oslanjanju na ljude i socijalni kapital koji ih povezuje. To je u skladu s istraživanjem Bruynisa i sur. (2001) koji su empirijski dokazali da *postojanje* i *distribucija točnih financijskih izvještaja* imaju pozitivan učinak na profitabilnost i povećanje obujma zadružnog poslovanja. Nadalje, oni su dokazali da *odnosi upravitelja i nadzornog odbora* imaju pozitivan utjecaj na zadovoljstvo članova, dok negativan utjecaj može imati *unajmljivanje vanjskog upravitelja* kojeg ne poznaju i u kojeg nemaju povjerenja.

Drugo rangirani poslovni pokazatelj u kontekstu zadružnih načela su *ukupni prihodi* (P). Prihodi se pokazuju najvažnijim poslovnim pokazateljem kada govorimo o gospodarskom sudjelovanju (X_{N3} = 1,75) i međuzadružnoj suradnji (X_{N6} = 1,5). Nasuprot tome, u kontekstu demokratičnosti (X_{N2} = -0,5) i poslovne autonomije (X_{N4} = -1,25) ovaj poslovni pokazatelj se nalazi na pretposljednjem mjestu ili dijeli zadnje mjesto u poretku. Vrijednost potencijala ukazuje na važnost pokazatelja *ukupni prihodi* i u kontekstu načela zadružne edukacije (X_{N5} = -0,25) i brige za zajednicu (X_{N7} = 0,25) gdje pokazatelj zauzima drugu poziciju.

Visoke vrijednosti potencijala pokazatelja *ukupni prihodi* u kontekstu dva zadružna načela (N3 i N6) koja uređuju poslovne aktivnosti zadruge mogu se lako objasniti. Uloga zadruge je da pomaže u poboljšanju poslovne održivosti i uklanjanju organizacijskih nedostataka s kojima se susreću članovi na konkurentskom tržištu. Zadruge djeluju kao tržišni posrednik

---

na osobna svojstva članova između kojih postoji jača povezanost interesa. Od njih se očekuje osobni angažman i prinos koji ne mora biti u obliku kapitala. Načelno postoji osobna neograničena solidarna odgovornost članova vlastitom imovinom za obveze društva. Svaki član ima jednaka prava neovisno o visini kapitala koji su unijeli u društvo. U načelu se bez suglasnosti ostalih članova udio u društvu ne može prenijeti na drugoga, što vrijedi i za nasljeđivanje, a ni novi članovi ne mogu pristupiti društvu bez suglasnosti svih njegovih članova. Članovi imaju široku autonomiju uređenja odnosa u društvu.

između potreba svojih članova i njihovih aktivnosti. Ukupni prihodi koje zadruga ostvaruje su izravno povezani s raspoređivanjem viškova između članova sukladno razmjeru njihova poslovanja sa zadrugom. Visina prihoda zadruge prvenstveno ovisi o volumenu zadružne proizvodnje, plasmanu proizvoda putem zadruge, tržišnoj cijeni proizvoda, ali i cijeni koju zadruga nudi članovima u zamjenu za poljoprivredne proizvode. Preuzimanjem troškova plasmana i zajedničkim nastupom na tržištu zadruga smanjuje transakcijske troškove i kompenzira druge nedostatke zbog kojih članovi ne mogu samostalno konkurirati na tržištu. Razumna i poštena cijena koju zadruga nudi dionicima za proizvode veće kvalitete utječe na stupanj povjerenja i spremnost dionika da svoju proizvodnju nastave i u buduće plasirati isključivo putem zadruge. Povećanje razmjera poslovanja između dionika i zadruge na kraju rezultira većim prihodima zadruge i dionika. Međutim, vrijedi i obrnuto. Manja ili nepravedna cijena koju uprava zadruge nudi dionicima može rezultirati jačanjem nepovjerenja na relaciji dionici-upravitelj i gubitka uzajamnosti unutar zadružnog poslovanja što posljedično dovodi do sve manjeg plasmana robe i novčanih prihoda za zadruge i njene dionike. To je skladu s istraživanjima Staatza (1983) i Sextona (1986) koji u svojim modelima dokazuju da će postojanje jedne cijene za sve članove potaknuti članove s boljim tržišnim mogućnostima da napuste zadrugu. U takvim situacijama se preporuča uvođenje *promjenjivih* i *minimalno potrebnih cijena* koje će isto tako regulirati raspodjelu troškova i dobiti zadruge.

Drugo mjesto poslovnog pokazatelja *ukupni prihodi* u kontekstu zadružne edukacije (X_{N5} = -0,25) i brige za lokalnu zajednicu (X_{N7} = 0,25) ukazuje da načela predstavljaju prednosti zadružnog poduzetništva koje dugoročno gledajući mogu dovesti do stvaranja ekonomske koristi. Na primjer, stručnim osposobljavanjem dionika se može podići kvaliteta proizvoda ili produktivnost proizvodnje što posljedično dovodi do veće otkupne/prodajne cijene koju dionici/zadruga postiže na tržištu. Isto tako, izgradnja poslovne infrastrukture, zapošljavanje lokalnog stanovništva, ulaganja u inovativne tehnologije proizvodnje koje štite prirodu samo su neki primjeri aktivnosti koje potiču stvaranje ekonomskih i društvenih koristi. Istraživanje Bruynisa i sur. (2001) empirijski potvrđuje da *kontinuirani treninzi* imaju pozitivan utjecaj na dugovječnost, profitabilnost i povećanje obujma zadružnog poslovanja.

Slabija preferencija pokazatelja ukupnih prihoda u kontekstu demokratičnosti (X_{N2} = -0,5) i autonomije poslovanja (X_{N4} = -1,25) već je djelomično objašnjena zajedno s važnošću prvo rangiranog pokazatelja *dionici* (D). Postojanje većih razlika u poslovnim interesima članova narušava stabilnost poslovnih rezultata i utječe na slabiji plasman proizvoda putem zadruge što u konačnici dovodi do manjih prihoda. Što su razlike u interesima dionika izraženije to je vjerojatnije da će u uvjetima plasmana različitih količina robe doći do sukoba interesa oko raspodjele zajedničkih troškova. Isto tako, određivanje otkupnih cijena za proizvode različite kakvoće može izazvati različite stavove i reakcije dionika zadružnog poslovanja. Navedeno

je u skladu s brojnim istraživanjima (Kaarlehto, 1955; Ohm, 1956) i drugom ekonomskom školom koja zadruge promatra kao koalicije dionika (vidi potpoglavlje 2.2.1., str. 11).

Treće rangirani poslovni pokazatelj po važnosti su *zalihe* (Z) kojima raspolaže i rukovodi zadruga. Važnost pokazatelja *zalihe* u rješavanju poslovnih pitanja zadruge potvrđuju veće vrijednosti potencijala kada ga promatramo u kontekstu demokratske kontrole (X_{N2} = 0,5) i poslovne autonomije (X_{N4} = 0,75). U kontekstu ova dva načela važnost pokazatelja *zalihe* je najviše izražena i ovdje je rangiran kao drugi najvažniji pokazatelj. Nasuprot tome, manje vrijednosti potencijala i posljednje mjesto u poretku ukazuju na slabiju važnost pokazatelja *zalihe* u kontekstu dva neekonomska načela obrazovanja članova (X_{N5} = -1,25) i brige za zajednicu (X_{N7} = -1,75). Iz toga zaključujemo da se informiranje članova o važnosti zaliha u financijskom poslovanju ili trenutnim količinama s kojima zadruga raspolaže ne provodi na radionicama, već najvjerojatnije putem neformalnih oblika komunikacije s drugim dionicima ili tijekom rada skupštine zadruge. Zalihe su resurs koji se isključivo koristi u svrhu održivosti i likvidnosti zadružnog poslovanja i ne čudi njegovo zadnje mjesto u poretku kada govorimo u kontekstu održivog lokalnog razvoja (N7). Važnost zaliha je potvrđena i u kontekstu dva zadružna načela koja naglasak stavljaju na održivost zadružnog poslovanja. U kontekstu zadružnog načela međuzadružne suradnje (X_{N6} = -0,5) zalihe se nalaze na trećem, a u kontekstu gospodarskog sudjelovanja (X_{N3} = -0,25) na diobi drugog mjesta.

Visoka pozicija poslovnog pokazatelja *zalihe* u kontekstu demokratskog odlučivanja (N2) ukazuje da su zalihe važan čimbenik financijske neovisnosti zadruga. To je logično obzirom da se zadruge u pravnom prometu oslanjaju na rad svojih članova i zajedničke resurse koji su pod neposrednim nadzorom članova (N4). Na taj način se zadruge ograđuju od vanjskih izvora financiranja i štite od privatnih interesa, a njihovi članovi zadržavaju vlasnička prava i demokratsku kontrolu nad svojim poslovanjem. Zato je za zadruge od neizmjerne važnosti odrediti optimalne razine zaliha kako bi se smanjili troškovi, zaštitila zajednička proizvodnja u uvjetima neizvjesnosti i osiguralo kontinuirano odvijanje poslovnih procesa. Zalihe su oblik kratkotrajne imovine koji može povećati troškove ili smanjiti ubrzanu likvidnost zadružnog poslovanja (engl. *quick ratio*) ako se ne provodi njihova optimizacija. Kvalitetna optimizacija zaliha osigurati će kontinuiranu proizvodnju i umanjiti negativne učinke tržišne neizvjesnosti. Redovito praćenje zaliha i troškova njihova skladištenja osigurati će ekonomski prosperitet i nastavak neovisnog poslovanja zadruga na tržištu.

Istraživanja o efikasnosti poslovanja zadruga pokazuju proturječne rezultate na koje utječe odabir financijskih pokazatelja koji se koriste za mjerenje veličine i efikasnosti poslovanja. Istraživanje Arcasa i sur. (2011) koje je najsličnije našem obzirom na pokazatelj kratkotrajne imovine (zalihe) pokazuje da veličina zadruga, mjerena ukupnom imovinom i materijalnom

dugotrajnom imovinom, ima pozitivan utjecaj na efikasnost poljoprivrednih zadruga. Velike zadruge imaju konkurentsku prednost zbog resursa s kojima raspolažu, ali istodobno imaju manju sposobnost prilagodbe i veće probleme vezane za koordinaciju i kontrolu.

Na posljednjem mjestu u konačnom poretku važnosti poslovnih pokazatelja se nalaze *ukupni rashodi* (R). Vrijednost potencijala ukazuje na potpunu inferiornost ukupnih rashoda u odnosu na ostale poslovne pokazatelje (X_{UK2} = −1,417). Pokazatelj rashoda je rangiran kao posljednji u konačnom poretku kada govorimo u kontekstu demokratičnosti poslovanja (X_{N2} = -1,5), gospodarskog sudjelovanja (X_{N3} = -2,25), autonomije poslovanja (X_{N4} = -1,25) i međuzadružne suradnje (X_{N6} = -2,5). Jedino u kontekstu zadružne edukacije (X_{N5} = -0,25) i brige za zajednicu (X_{N7} = -0,75) pokazatelj ukupnih rashoda se nalazi na pretposljednjem mjestu u poretku, a posljednje mjesto prepušta pokazatelju *zalihe*.

Slabija preferencija pokazatelja *ukupni rashodi* u kontekstu svih zadružnih načela neizravno ukazuje na prednosti zadružnog organiziranja. Posljednje mjesto u poretku zapravo ukazuje da demokratska kontrola (N2), gospodarsko sudjelovanje (N3), autonomija poslovanja (N4) i suradnja s lokalnim zadrugama (N6) ne predstavljaju ekonomski trošak, već organizacijske prednosti zadružnog poduzetništva. Korištenjem djelatnosti koje zadruga pruža njeni dionici smanjuju vlastite troškove poslovanja. To je u skladu s objašnjenjima vezanim za pokazatelj *ukupni prihodi* (P) čija se važnost ogleda u drugom mjestu konačnog poretka.

U kontekstu zadružne edukacije (N5) i brige za lokalnu zajednicu (N7) poslovni pokazatelj *ukupni rashodi* ima bolje mjesto u poretku nego u kontekstu ostalih načela. Promatrajući iz perspektive ukupnih rashoda ova dva zadružna načela predstavljaju aktivnosti koje dovode do neplaniranih troškova. Već smo prethodno napomenuli da potencijal pokazatelja *ukupni prihodi* ukazuje na važnost ovih načela (X_{N5} = -0,25 i X_{N7} = 0,25). Istodobnim promatranjem potencijala pokazatelja *ukupni prihodi* i *ukupni rashodi* može se zaključiti da edukacija i briga za zajednicu istodobno donose koristi i troškove. Samim time načela stvaraju manje izravnih koristi i ne predstavljaju glavne prednosti zadružnog načina organiziranja. Sukladno tome, teorijska pozadina koja se nalazi iza ova dva načela ne predstavlja glavne motive za ulazak dionika u poljoprivredne zadruge. To je u skladu s prethodnim istraživanjima koja su provedena na istim zadrugama (Nedanov i sur., 2016; Nedanov i Žutinić, 2018).

Ova povezanost je izraženija u kontekstu zadružne edukacije (N5) gdje dva pokazatelja *ukupni prihodi* i *ukupni rashodi* imaju isti potencijal (X_{N5} = -0,25) i dijele drugo tj. treće mjesto u poretku. Međutim, u kontekstu brige za zajednicu (N7) pokazatelj *ukupni prihodi* ima veći potencijal i bolje mjesto u poretku u odnosu na pokazatelj *ukupni rashodi*. To ukazuje da je načelo brige za lokalnu zajednicu ipak na kraju donosi veće ekonomske koristi. Zadruge se

temelje na *samopomoći* i u povijesti su osnivane kao reakcija poduzetnih poljoprivrednika na nepovoljne tržišne situacije (Mooney i Majka, 1995). Na taj način zadruge su pomagale sebi i lokalnoj zajednici u kojoj djeluju. Važnost ovih zadružnih načela je dodatno ispitana u sljedećim potpoglavljima (5.5. i 5.6.) gdje se na dvije razine samodualne hijerarhije rangiraju zadružna načela obzirom na poslovne pokazatelje (Razina 3) i uvažavanjem sinergije među zadružnim načelima (Razina 4).

5.5. Rangiranje zadružnih načela obzirom na poslovne varijable

U Tablici 5.3. su prikazane vrijednosti ukupnog potencijala i vrijednosti potencijala zadružnih načela u odnosu na poslovne pokazatelje (kriteriji). Grafovi preferencije za treću razinu samodualne hijerarhije se nalaze na slici 4.4. (str. 139), a multigraf preferencije je prikazan na slici 4.2 (desni graf, str. 134). Konačan poredak važnosti načela u kontekstu poslovnih pokazatelja čine: *Gospodarsko sudjelovanje* (X_{UK3} = 1,875), *Međuzadružna suradnja* (X_{UK3} = 1,375), *Demokratičnost poslovanja* (X_{UK3} = -0,375), *Poslovna autonomija* (X_{UK3} = -0,625), *Zadružna edukacija* (X_{UK3} = -0,875) i *Briga za lokalnu zajednicu* (X_{UK3} = -1,375). U nastavku su objašnjeni rezultati poretka zadružnih načela i njihova važnost u kontekstu poslovnih pokazatelja.

Tablica 5.4. Potencijal i poredak zadružnih načela (Razina 3)

	X_D	X_Z	X_P	X_R	X_{UK3}	Poredak
X_{UK2}	1,583	− 0,417	0,25	− 1,417		
N2	0,333	− 0,5	− 0,833	− 0,5	**− 0,375**	**3**
N3	2,333	1,5	2,166	1,5	**1,875**	**1**
N4	− 1,666	0,5	0,166	− 1.5	**− 0,625**	**4**
N5	− 0,666	− 0,5	− 0,833	− 1.5	**− 0,875**	**5**
N6	1,333	1,5	1,166	1,5	**1,375**	**2**
N7	− 1,666	− 2,5	− 1,833	0,5	**− 1,375**	**6**
Suma	**0,001**	**0,0**	**− 0,001**	**0,0**	**0,000**	

X_D, **X_Z**, **X_P** i **X_R** = potencijal zadružnih načela u odnosu na poslovne pokazatelje.
X_{UK3} = ukupni potencijal na temelju kojeg se radi konačan poredak Razine 3 (stupac 7).
X_{UK2} = ukupni potencijal poslovnih pokazatelja na Razini 2 (vidi tablicu 5.3., str. 152).
Izvor: Autorska obrada podataka.

Na **prvom mjestu** u konačnom poretku važnosti se nalazi načelo *gospodarsko sudjelovanje* (N3). Ovo zadružno načelo se nalazi na prvom mjestu u poretku kada govorimo u kontekstu poslovnih pokazatelja dionika (X_D = 2,333) i ukupnih prihoda (X_P =2,166), dok u kontekstu

zaliha (X_Z = 1,5) i ukupnih rashoda (X_R = 1,5) prvu poziciju dijeli sa šestim načelom *suradnja među zadrugama* (N6).

Upravo se načelo *međuzadružna suradnja* (N6) nalazi na **drugom mjestu** u konačnom poretku. Ovo zadružno načelo opisuje suradnju zadruga na lokalnoj razini i njegova važnost u kontekstu poslovnih pokazatelja je veoma slična prvo rangiranom načelu *gospodarsko sudjelovanje* (N3). Osim diobe prvog mjesta u kontekstu pokazatelja *zalihe* i *ukupni rashodi*, načelo suradnje među zadrugama se nalazi na drugom mjestu kada govorimo u kontekstu dionika (X_D = 1,333) i ukupnih prihoda (X_P = 1,166). Ova dva najvažnije rangirana zadružna načela definiraju ulogu zadruga u odnosu na interese članova. Zadruge uklanjanju tržišne nedostatke i smanjuju visoke transakcijske troškove koje članovi ostvaruju individualnim nastupom na tržištu. Pri tome, treće zadružno načelo definira unutarnja pravila organiziranja kao što su podmirenje obveza i potraživanja, raspodjela dobiti i gubitaka razmjerno obujmu suradnje, uspostavljanje rezervi, izdvajanje dobiti za unapređenje poslovanja i u obvezne zakonske pričuve, te podržavanje aktivnosti koje odobrava skupština (članovi) zadruge. S druge strane šesto načelo potiče poslovnu suradnju unutar zadružnog sustava, od lokalne do međunarodne razine, u istim ili različitim sektorima djelatnosti. Takav način umrežavanja zadrugama osigurava prednosti horizontalnog i vertikalnog povezivanja poput efikasne ekonomije razmjera i stvaranja poljoprivrednih proizvoda s dodanom vrijednosti. Koncept načela *gospodarsko sudjelovanje* (N3) je više usmjeren prema ekonomskim aktivnostima, dok definicija zadružnog načela *suradnja među zadrugama* (N6) može podrazumijevati i druge oblike suradnje koji ne donose nužno izravnu materijalnu korist. Na taj način zadruge putem zajedničkog rada s drugim zadrugama istodobno služe svojim članovima i doprinose jačanju zadružnog sustava na lokalnoj, regionalnoj, nacionalnoj i međunarodnoj razini. Vrijednosti potencijala načela *gospodarsko sudjelovanje* (X_{N3} = 1,875) i *međuzadružna suradnja* (X_{N6} = 1,375) i njihova razlika u odnosu na vrijednosti potencijala ostalih zadružnih načela ukazuje na ekonomski značaj zadružnog poduzetništva. Ova dva zadružna načela možemo svrstati u kategoriju ***poslovna načela*** (N3 i N6).

Za razliku od kategorije *poslovna načela* koja određuje ulogu zadruga u odnosu na njene dionike, druga kategorija zadružnih načela oblikuje kvalitetu međuljudskih odnosa unutar zadruge. Načela druge kategorije bave se problemima unutarnje organizacije i imaju za cilj smanjiti mogućnosti malverzacija uprave ili manjih interesnih skupina (klika). Obzirom da načela druge kategorije reguliraju upravljanjem vlastitih transakcijskih troškova koji nastaju kao posljedica međuljudskih odnosa možemo ih svrstati u kategoriju ***društvena načela***. U kategoriju ulaze četiri načela: *demokratičnost poslovanja* (N2), *neovisnost poslovanja* (N4), *zadružna edukacija* (N5) i *briga za lokalnu zajednicu* (N7).

Zadružno načelo *demokratičnost poslovanja* (N2) nalazi se na **trećem mjestu** u konačnom poretku i najbolje je rangirani pokazatelj iz kategorije *društvena načela*. Najbolje je rangiran u kontekstu pokazatelja dionika (X_D = 0,333) gdje se nalazi na trećem mjestu. U kontekstu ukupnih rashoda (X_R = -0,5) se nalazi na četvrtom, a u kontekstu zaliha (X_Z = -0,5) i ukupnih prihoda (X_P = -0,833) na diobi četvrtog mjesta u poretku. Treća pozicija ovog zadružnog načela u konačnom poretku pokazuje da je članovima zadruge nakon poslovne uspješnosti važno zadržati vlasnička prava i kontrolu nad svojim poslovanjem.

Mjesto u poretku načela *demokratičnost poslovanja* je u skladu s konceptom zadružnog poslovanja gdje svaki član sudjeluje s jednakim glasačkim pravima u donošenju odluka i rukovođenju zalihama, a raspodjela dobiti ili potraživanja se raspoređuje razmjerno obujmu poslovanja između članova i zadruge. Načelo demokratičnosti podrazumijeva manji rizik za pojedinca da će biti zanemaren od strane ostalih dionika i jamči mu jednakost u odlučivanju. S druge strane, nemogućnost postizanja dogovora ili sporo donošenje odluka dovodi do smanjenja operativne fleksibilnosti poslovanja. Razilaženje u interesima između uprave i članova dovodi do problema kontrole (engl. *control problem*) i problema utjecaja na troškove (engl. *influence costs problem*).[204] Nepravovremene odluke rezultiraju većim troškovima poslovanja, gubitkom zaliha, smanjenjem likvidnosti ili manjim ukupnim prihodima. Čest je slučaj da u uvjetima demokratičnosti dolazi do prekomjernog korištenja zajedničke imovine i resursa u osobnu korist od strane pojedinaca. To na posljetku dovodi do nezadovoljstva ostalog dijela članstva koje prestaje plasirati svoje proizvode putem zadruge (engl. *free rider problem*). Tortia i sur. (2013) navode da je to jedan od najpoznatijih problema koji se javlja u zadrugama koje nemaju jasno definirana imovinska prava, niti unutrašnje pravilnike koji će na pravedan način naplaćivati korištenje imovine, mehanizacije i drugih pogodnosti koje zadruga nudi. Ova je situacija tipična za zadruge s otvorenim članstvom. Konkretni primjeri navedenih problema su zabilježeni i na našim prostorima (vidi Božić i sur., 2020).

Načelo demokratičnosti poslovanja (N3) uz *poslovna načela* (N3 i N6) predstavlja važan čimbenik zadružnog poduzetništva koji mora biti transparentno reguliran putem unutarnjih pravilnika ako zadruga i njeni članovi žele efikasno poslovati.

Na **četvrtom mjestu** u konačnom poretku se nalazi zadružno načelo *poslovna autonomija* (N4). Načelo neovisnosti zadružnog poslovanja je najbolje rangirano u kontekstu zaliha (X_Z = 0,5) i ukupnih prihoda (X_P = 0,166) gdje zauzima treće mjesto u poretku. U kontekstu ukupnih rashoda (X_R = -1,5) i dionika (X_D = -1,666) se nalazi na diobi pretposljednjeg mjesta.

[204] U takvim situacijama pojedini članovi pokušavaju utjecati na kolektivno donošenje odluka u svoju korist. Pogotovo u zadrugama koje se bave širokim spektrom aktivnosti ovakve radnje kompliciraju zajedničko donošenje odluka i dovode do pogrešnih odluka ili ih uopće nema.

U kontekstu ukupnih rashoda predzadnje mjesto dijeli s načelom *zadružna edukacija* (N5), a u kontekstu dionika s načelom *briga za lokalnu zajednicu* (N7).

Ovdje je ponovno potvrđena značajna uloga poslovnog pokazatelja *zalihe* u osiguravanju *neovisnosti poslovanja* (N4). Isti rezultat je dobiven na drugoj razini samodualne hijerarhije (vidi potpoglavlje 5.4.). Očigledno je da se financijska neovisnost u zadružnom poslovanju osigurava korištenjem zajedničke imovine, mehanizacije, resursa i uzajamnim radom svih dionika. Upravo to je jedan od glavnih razloga zašto su poljoprivrednici diljem svijeta počeli surađivati sa zadrugama. Na taj način se izbjegava korištenje vanjskih izvora financiranja ili uzimanje komercijalnih kredita za nastavak poslovanja. U situacijama kada ipak dolazi do sklapanja ugovora s poduzećima ili vladom, zadruga osim poslovne neovisnosti, svojim vjerovnicima osigurava demokratsku kontrolu nad zajedničkim resursima u koje ne bi mogli individualno investirati. To je poslovna strategija na temelju kojeg zadružni sustav od samog početka osigurava svoju poslovnu neovisnost i održivost, te ostvaruje novčane prihode za članove. Tome u prilog idu vrijednosti potencijala i oprečna mjesta u konačnom poretku na kojem se nalazi načelo *poslovna autonomija* u kontekstu pokazatelja *ukupni prihodi* (X_P = 0,166) i *ukupni rashodi* (X_R = -1,5).

Na kraju je potrebno napomenuti da je zanimljiva pozicija i potencijal koji zadružno načelo *poslovne autonomije* ostvaruje u kontekstu pokazatelja *dionici* (X_D = -1,666). Slabija važnost načela autonomije u kontekstu dionika ukazuje na prividan gubitak samostalnosti od strane dionika unutar zadružnog poslovanja. To se može objasniti na način da se određene obveze kao što su: članski ulozi, obvezna izdvajanja za budući razvoj zadruge ili u pričuve, obvezno plasiranje proizvodnje putem zadruge ili potpuni gubitak zemljišta zadruge u slučaju njenog stečaja smatraju ograničenjima za razvojne mogućnosti dionika i zadružnog poslovanja.

Peto rangirano načelo u konačnom poretku važnosti je *zadružna edukacija* (N5). Njegova preferencija je podjednako rangirana u kontekstu svih promatranih poslovnih pokazatelja. U kontekstu dionika (X_D = -0,666) ovo zadružno načelo dijeli četvrto mjesto s načelom *briga za lokalnu zajednicu* (N7). Slična situacija je u kontekstu zaliha (X_Z = -0,5) i ukupnih prihoda (X_P = -0,833) gdje četvrto mjesto dijeli s načelom *demokratičnost poslovanja* (N2). Načelo obrazovanja se pokazuje najmanje važnim u kontekstu ukupnih rashoda (X_R = -1,5) gdje posljednju poziciju dijeli sa zadružnim načelom *neovisnost poslovanja* (N4).

Može se zaključiti da primjena načela *zadružna edukcija* po kojem se zadruge razlikuju od konvencionalnih oblika poduzetništva nema značaj u poslovanju poljoprivrednih zadruga. Upravo to se može smatrati jednim od glavnih razloga današnje nezavidne situacije unutar hrvatskog zadružnog sustava. Zbog toga se zadružna načela normativno razumijevaju, a

poslovne mogućnosti koje zadružno poduzetništvo u sebi sadrži poprima obilježja religije, ideologije ili populizma. Takav normativan pristup teško je uklopiti u znanstveni ili politički kontekst. Posljedica toga je da problem zadrugarstva u RH postaje povezan s nedostatkom stručnjaka koji posjeduju znanje. Načelo zadružne edukacije potrebno je promatrati kao presudan čimbenik koji je neophodan za uspješnu implementaciju ostalih načela u zadružno poslovanje. Obzirom da načelo obrazovanja treba biti podrška ostalim zadružnim načelima, posebice načelima demokratičnosti, gospodarskog sudjelovanja i neovisnosti poslovanja, ona treba postati svakodnevna praksa za sve dionike. Uprava zadružnog poduzetništva se treba baviti kontinuiranim i sveobuhvatnim obrazovanjem članova, a formalno obrazovanje poput učeničkih zadruga su dobrodošli oblici edukacije koji će podići svijest o prednostima zadružnog poduzetništva na nacionalnoj razini. S druge strane putem zadružne edukacije dionici mogu usavršavati profesionalne vještine i informirati se o aktualnostima iz sektora proizvodnje u kojem djeluju. Na taj način se doprinosi društvenom i profesionalnom razvoju dionika, zadruge i lokalne zajednice. Klasične načine informiranja treba upotpuniti dodatnim mjerama pretvaranja prakse suradnje u konkretne protokole suradnje koji će se prezentirati zadrugama kroz edukacijske radionice. Stvaranje baze podataka koja će sadržavati sve moguće partnere i protokole suradnje potaknuti će repliciranje broja primjera dobre prakse i uspostaviti trajne sporazume suradnje. Na taj način će se analitički objasniti koraci i mogući načini povezivanja zadruga na nacionalnoj razini, te stvoriti cjelovita slika koju pojedinačne zadruge često ne mogu same vidjeti.

Na posljednjem mjestu u konačnom poretku se nalazi zadružno načelo *briga za lokalnu zajednicu* (N7). Njena inferiornost u odnosu na ostala načela dolazi do izražaja u kontekstu većine poslovnih pokazatelja. Načelo se nalazi na posljednjem mjestu u poretku kada se promatra u kontekstu zaliha (X_Z = -2,5) i ukupnih prihoda (X_P = -1,833), a u kontekstu dionika (X_D = -1,666) zadnje mjesto dijeli s načelom *neovisnost poslovanja* (N4). Jedino u kontekstu ukupnih rashoda (X_R = 0,5) dolazi do značajnog odstupanja gdje se ovo zadružno načelo nalazi na trećem mjestu u poretku.

Slabija preferencija u kontekstu tri poslovna pokazatelja (Z, P i D) neizravno ukazuje da *briga za lokalnu zajednicu* ne predstavlja glavni razlog postojanja zadružnog poduzetništva što je u skladu s prethodnim rezultatima rangiranja koji u prvi plan stavljaju zadružna načela koja reguliraju ekonomsku održivost i unutarnju organizaciju zadružnog poslovanja. Najbolji statistički argument tome je slabija korelacija (manji potencijal i zadnje mjesto u poretku) s pokazateljem *ukupni prihodi* (X_P = -1,833) i jača korelacija (veći potencijal i treće mjesto) s pokazateljem *ukupni rashodi* (X_R = 0,5). Iz toga se može zaključiti da koncept načela brige za lokalnu zajednicu u većoj mjeri utječe na troškove nego što predstavlja organizacijsku

prednost zadružnog poduzetništva. Time se potvrđuje kako zadruge nemaju razumijevanja i htjenja oko uključivanja u radnje koje ne stvaraju izravne ekonomske koristi.

Sličan zaključak, ali s malim razlikama je donesen na drugoj razini samodualne hijerarhije (vidi potpoglavlje 5.4.) kada je u kontekstu dva ista poslovna pokazatelja također uočena slabija važnost načela *briga za lokalnu zajednicu* (N7). Međutim, tamo je veća vrijednost potencijala *ukupni prihodi* (X_{N7} = 0,25), u odnosu na potencijal *ukupni rashodi* (X_{N7} = -0,75), sugerirala da koncept zadružnog načela *briga za lokalnu zajednicu* ipak utječe na stvaranje drugih oblika koristi što može opravdavati eventualna ulaganja zadruge. Važnost ovog načela i njegovo mjesto u konačnom poretku biti će razjašnjeno u sljedećem koraku samodualne hijerarhije (Razina 4) koja u rangiranju zadružnih načela uvažava postojanje sinergije između zadružnih načela.

5.6. Sinergija zadružnih načela

Uvažavanje sinergije zadružnih načela u postupku rangiranja doveo je do promjene njihove važnosti. U desnom dijelu Tablice 5.3. se nalaze vrijednosti potencijala (X_{UK4}) koji je dobiven nakon međusobnog uspoređivanja zadružnih načela koja su istodobno definirana kao atributi i alternative.[205] Njihovi pojedinačni grafovi preferencije su prikazani na slici 4.5. (str. 139). Konačan poredak zadružnih načela nakon uvažavanja sinergije među njima čine redom: *međuzadružna suradnja* (X_{N6} = 1,233), *gospodarsko sudjelovanje* (X_{N3} = 0,733), *briga za zajednicu* (X_{N7} = -0,066), *demokratičnost* (X_{N2} = -0,433), *poslovna autonomija* (X_{N4} = -0,566) i *zadružna edukacija* (X_{N5} = -0,9). U nastavku su objašnjene razlike u poretku načela između treće (vidi potpoglavlje 5.5.) i četvrte razine samodualne hijerarhije.

Ovdje je poredak zadružnih načela nešto drugačiji. Isto kao u prethodnoj razini samodualne hijerarhije (Razina 3) i ovdje prva dva najpreferiranija zadružna načela uređuju ekonomske aktivnosti zadružnog poslovanja. Međutim, uvažavanjem sinergije između zadružnih načela (Razina 4) dolazi do zamjene njihovih pozicija u poretku. Zadružno načelo *međuzadružna suradnja* (X_{N6} = 1,233) se sada nalazi na prvoj, a načelo *gospodarsko sudjelovanje* (X_{N3} = 0,733) na drugom mjestu u konačnom poretku. Time je još jedanput potvrđena ekonomska važnost zadružnog poduzetništva. Međutim, najznačajnija promjena u konačnom poretku se pojavila na trećem mjestu gdje se sada nalazi načelo *briga za zajednicu* (X_{N7} = -0,066).

[205] Rangiranje na ovakav način omogućava uvažavanje možebitne sinergije koja eventualno postoji između ulaznih podataka. Međutim, Metoda potencijala ne može objasniti koji su izvori, razlozi ili posljedice njenog postojanja i u tu svrhu je potrebno provesti preciznija i ciljno usmjerena istraživanja.

U prethodnom koraku samodualne hijerarhije (Razina 3) načelo brige za lokalnu zajednicu se nalazilo na šestom (posljednjem) mjestu. Poredak preostala tri zadružna načela ostao je nepromijenjen u odnosu na treću razinu samodualne hijerarhije.

Tablica 5.5. Poredak zadružnih načela nakon treće i četvrte razine samodualne hijerarhije

	Stari potencijal (X_{UK3})	Stari poredak	Promjena u poretku	Novi potencijal (X_{UK4})	Novi poredak
X_{N6}	− 0,375	**2**	↑	1,233	**1**
X_{N3}	1,875	**1**	↓	0,733	**2**
X_{N7}	− 0,625	**6**	↑	− 0,066	**3**
X_{N2}	− 0,875	**3**	↓	− 0,433	**4**
X_{N4}	1,375	**4**	↓	− 0,566	**5**
X_{N5}	− 1,375	**5**	↓	− 0,9	**6**
Suma	**0,000**			**0,001**	

Stari potencijal (X_{UK3}) = potencijal zadružnih načela obzirom na poslovne pokazatelje (Razina 3).
Novi Potencijal (X_{UK4}) = novi potencijal koji se dobiva nakon uvažavanja sinergije (Razina 4).
Izvor: Autorska obrada podataka.

Vidljivo je da zadružna načela koju su popravila svoje pozicije u konačnom poretku važnosti stavljaju naglasak na lokalni karakter zadružnog djelovanja. Radi se o zadružnim načelima *međuzadružna suradnja* (N6) i *briga za lokalnu zajednicu* (N7). Njihova pozicija u konačnom poretku ukazuje na ulogu zadružnog poduzetništva u održivom razvoju lokalnih zajednica.

Iz konačnog poretka koji uvažava postojanje sinergije između zadružnih načela možemo zaključiti da su poljoprivredne zadruge prvenstveno poslovne organizacije koje nastaju povezivanjem lokalnih poljoprivrednika koji često zbog svojih resursno limitiranih obiteljskih gospodarstva ne mogu samostalno konkurirati zahtjevima tržišta. Navedeno potvrđuju prve **dvije vodeće pozicije** u konačnom poretku koje zauzimaju zadružna načela *gospodarsko sudjelovanje* (N3) i *međuzadružne suradnje* (N6). Ova zadružna načela naglasak stavljaju na važnost efikasne organizacije unutarnjeg poslovanja i na važnost horizontalnog odnosno vertikalnog povezivanja lokalnih zadruga. U tome zadruge svojim poslovanjem doprinose cjelovitom održivom razvoju dionika, okruženja i ukupne privrede lokalne zajednice u kojoj poslovno djeluju. Ovakav pristup uključuje ekonomsku, društvenu, kulturološku, ali političku održivost lokalnih zajednica. Brojni konkretni primjeri, u nas i svijetu, svjedoče o integralnom djelovanju zadružnog poduzetništva na okruženje u kojem djeluju (HSZ, 2005; Simmons i sur., 2010). Tome u prilog ide **treće mjesto** u konačnom poretku načela *briga za lokalnu zajednicu* (N7). Tri zadružna načela u konačnom poretku zajedno opisuju utjecaj djelovanja poljoprivrednih zadruga na ekonomski razvoj dionika, njihovih obitelji i lokalnih zajednica.

Na **četvrtom i petom mjestu** se nalaze zadružna načela *demokratičnost poslovanja* (N2) odnosno *poslovna autonomija* (N4). Ova dva načela su usmjerena na reguliranje unutarnje organizacije u cilju povećanja njene poslovne fleksibilnosti, ubrzavanja donošenja odluka, definiranja pravila ponašanja i korištenja usluga. Načela zajedno predstavljaju upravljačke mehanizme koji su usmjereni jačanju kvalitete međuljudskih odnosa i ekonomskih rezultata. Zadruga je demokratsko društvo čiji rad nadziru članovi koji imaju jednaka glasačka prava s kojima sudjeluju u stvaranju poslovne politike. Kao samostalna i neovisna pravna osoba zadruga se u prometu s drugim pravnim osobama i državnim tijelima oslanja na rad svojih članova i zadružne resurse koji su pod neposrednim nadzorom članova. Iz toga je vidljivo da osim ekonomskih koristi zadružno poduzetništvo istodobno omogućuje zadržavanje vlasničkih prava i kontrole nad vlastitom i zajedničkom proizvodnjom. Zadruge osiguravaju financijsku neovisnost od vanjskih izvora financiranja. Na taj način dionici zadržavaju svoje obiteljsko nasljeđe, a prirodni resursi ostaju u vlasništvu lokalnih zajednica i njenih članova koji će sigurno više pažnje posvećivati njihovom korištenju u cilj održivog lokalnog razvoja. Na taj način se osim ekonomskog razvoja, doprinosi izgradnji socijalnog kapitala i jačanju društvene kohezije unutar zadruge i lokalnih zajednica.

Na **posljednjem (šestom) mjestu** se nalazi načelo *Zadružna edukacija* (N5). Prema rezultatima analize možemo kazati da je ovo načelo sporedno, ali nužno obilježje zadružnog poduzetništva. Učinkovita kontrola zadružnog poslovanja zahtijeva pravilnu kombinaciju dionika koji su upoznati sa zadružnim i poslovnim konceptima, mehanizama koji olakšavaju kontrolu članova, te snažnu orijentaciju i pozitivan stav zaposlenika i kooperanata prema članskoj kontroli u zadruzi. Ovo zadružno načelo sadrži mnoge aktivnosti ili karakteristike koje su često izostavljene s popisa koji opisuje aktivnosti i jedinstvenost zadružne suradnje. Obrazovanje se u literaturi često spominje kao osnovni princip suradnje. Stajalište je autora da je obrazovanje presudan element potreban za provođenje tri osnovna načela u uspješnu poslovnu organizaciju. Obzirom da se zadružna edukacija često provodi samo kao podrška osnovnim načelima, posebno načelu demokratske kontrole, ovo načelo mora biti pravilno klasificirano i postati neizostavan dio zadružne prakse. Zadruga bi trebala provodi stručno osposobljavanje svojih članova, izabranih predstavnika, upravitelja i zaposlenika kako bi svi zajedno pridonijeli razvitku zadruge. Ona izvješćuje svoje članove i javnost, posebice mlade ljude o naravi, koristima i prednostima zadrugarstva. To je važna uloga i obveza zadružnog poduzetništva koje se ne smije zapostaviti.

5.7. Potvrđivanje istraživačkih hipoteza

AOMP i CFA su nam poslužile da se objasni smislenost anketnih i poslovnih podataka, ali i ispita u kakvom su međusobnom odnosu ove dvije kategorijski različite skupine varijabli. Metoda potencijala (MP) je pokazala da poslovne varijable i zadružna načela međusobno snažno koreliraju i da su duboko ukorijenjene jedna u drugu.

Iz ekonomske perspektive *zadružna dobit* (D) računa se kao razlika između varijabli *ukupni prihodi* (P) i *ukupni rashodi* (R), ali u širem smislu ona može predstavljati i varijablu *dionici* (D) koji svojim sudjelovanjem doprinose stvaranju ***ekonomske (zadružne) dobiti***. Veći broj dionika znači da će u pravilu veći volumen članske proizvodnje biti plasiran putem zadruge, što će rezultirati većim prihodima i održivosti poslovanja. Vrijedi i obrnuto, manji broj dionika znači manje prihode za zadrugu, teže pokrivanje fiksnih troškova i smanjenje održivosti poslovanja. *Zadružnu dobit* (D) može opisivati i varijabla *zalihe* (Z) čija odabrana poslovna politika upravljanja može imati značajan utjecaj na visinu rashoda i konačnu ***ekonomsku (zadružnu) dobit***. Iz svega navedenog može se zaključiti da pojam zadružne dobiti kojeg u ovoj doktorskoj disertaciji povezujemo s poslovnim pokazateljima zapravo predstavlja mnogo širi pojam koji osim ekonomskih koristi opisuje dobrobit i blagostanje koje zadruge donose članovima, njihovim obiteljima i lokalnoj zajednici. Upravo to je glavni cilj zadružnog poduzetništva da se osim ekonomskog kapitala i poslovne održivosti osiguraju i drugi oblici koristi koje relevantna literatura prepoznaje pod pojmom socijalni kapital (vidi potpoglavlje 2.4., str. 33). Socijalni kapital je komponentna ***društvene (zadružne) dobiti*** koja se unutar zadruga osigurava putem sedam zadružnih načela (vidi potpoglavlje 2.1., str. 7). U nastavku su objašnjene poveznice između ekonomskog i socijalnog kapitala, tj. između pokazatelja koje je AOMP i CFA potvrdila da čine njihove sastavnice. Metoda potencijala je ukazala na mjesta u modelu koja potvrđuju hipoteze našeg istraživanja (vidi potpoglavlje 1.1., str. 5).

H1: Povezanost između zadružne dobiti i stupnja usvojenosti zadružnih načela

Povezanost ekonomskih pokazatelja i stupnja usvojenosti zadružnih načela je očigledna na svakoj razini samodualne hijerarhije koja je postignuta Metodom potencijala. Opisivanjem mjesta u modelu gdje je potvrđena hipoteza **H2** na neizravan način opisujemo i mjesta koja potvrđuju hipotezu **H1** da *postoji povezanost između pokazatelja zadružne dobiti i stupnja usvojenosti zadružnih načela*.

H2: Viši stupanj usvojenosti zadružnih načela rezultira većom zadružnom dobiti

Druga hipoteza je potvrđena na više mjesta u prethodna tri potpoglavlja gdje se raspravljalo o rezultatima Metode potencijala (vidi potpoglavlja 5.4., 5.5. i 5.6.). Iz tablice 5.3. (str. 152) vidimo da je visoki stupanj usvojenosti načela *Gospodarsko sudjelovanje* (N3) potvrđen prvim mjestom u poretku zadružnih načela. Kada promatramo vrijednosti potencijala i poredak poslovnih varijabli u trećem stupcu X_{N3} može se vidjeti da su *ukupni prihodi* (P) najvažnija, a *ukupni rashodi* (R) najmanje važna varijabla u kontekstu načela *Gospodarsko sudjelovanje*. Na taj način je potvrđena hipoteza **H2,** tj. da viši stupanj usvojenosti načela *Gospodarsko sudjelovanje* (N3) rezultira većom ekonomskom (zadružnom) dobiti.

Slična situacija je i kada promatramo varijable *ukupni prihodi* i *ukupni rashodi* u kontekstu načela *Međuzadružna suradnja* (N6). I ovdje su *ukupni prihodi* visoko rangirani i prvo mjesto dijele s varijablom *dionici* (D), dok se *ukupni rashodi* nalaze na zadnjem mjestu. Iz toga je vidljivo da zadružna načela (N3 i N6) koja smo svrstali u kategoriju *Poslovnih načela* najjače koreliraju s varijablom *ukupni prihodi* i najslabije koreliraju s varijablom *ukupni rashodi*. Iz toga možemo kazati da viši stupanj usvojenosti zadružnih načela koja reguliraju poslovnu održivost zadruga (N3 i N6) istodobno rezultiraju većim prihodima i manjim rashodima za zadrugu i članove. Time je potvrđena hipoteza **H2** da viši stupanj usvojenosti zadružnog načela *Međuzadružna suradnja* (N6) rezultira većom ekonomskom (zadružnom) dobiti.

Situacija je drugačija kada promatramo varijable *ukupni prihodi* (P) i *ukupni rashodi* (R) u kontekstu preostala četiri načela koja smo svrstali u drugu kategoriju *Društvena načela* (N2, N4, N5 i N7). Ova četiri načela imaju manju težinu (potencijal) i slabiji doprinos u poslovnom odlučivanju i drugoj hipotezi našeg empirijskog istraživanja (vidi Tablicu 5.3., str. 152).

U kontekstu načela *Demokratičnost poslovanja* (N2) i *Poslovna autonomija* (N4) varijable *ukupni prihodi* (P) i *ukupni rashodi* (R) zauzimaju posljednja dva mjesta u poretku. Međutim, potrebno je napomenuti da se u kontekstu ova dva načela (N2 i N4) varijabla *dionici* nalazi na prvom mjestu u poretku. Vrijednost potencijala (X_{N2} = 1,5 i X_{N4} = 1,75) ukazuje na snažnu korelaciju i preferenciju u odnosu na ostale poslovne varijable. Iz toga se može zaključiti da viši stupanj usvojenosti načela *Demokratičnost poslovanja* (N2) i *Poslovna autonomija* (N4) zapravo rezultira većom društvenom (zadružnom) dobiti.

Isto vrijedi i u kontekstu načela *Zadružna edukacija* (N5) i *Briga za lokalnu zajednicu* (N7) gdje se dvije varijable *ukupni prihodi* i *ukupni rashodi* nalaze na drugom i trećem mjestu u poretku. Izrazita preferencija varijable *dionici* (X_{N5} = 1,75 i X_{N7} = 2,25) u odnosu na ostale poslovne pokazatelje ukazuje da viši stupanj usvojenosti načela *Zadružna edukacija* (N5) i *Briga za lokalnu zajednicu* (N7) rezultira većom društvenom (zadružnom) dobiti.

6. ZAKLJČCI ISTRAŽIVANJA

Konačni rezultati, rasprava i zaključak doktorske disertacije se temelje na prigodnom uzorku od 202 ispitanika koji poslovno surađuju s 23 poljoprivredne zadruge. Demografski podaci ispitanika i podaci za mjerenje stupnja usvojenosti zadružnih načela su prikupljeni metodom ankete. Podaci su prikupljeni terenskim istraživanjem na području pet županija Slavonije, Baranje i zapadnog Srijema (Brodsko-posavska, Osječko-baranjska, Požeško-slavonska, Virovitičko-podravska i Vukovarsko-srijemska županija). Svi financijski podaci o poslovanju zadruga su dobiveni od Hrvatskog centar za zadružno poduzetništvo (HCZP) i središnje Financijske agencije (FINA).

Ciljevi doktorske disertacije su bili: (1) empirijski ustanoviti stupanj usvojenosti zadružnih načela među članovima poljoprivrednih zadruga, (2) razviti hibridni socioekonomski model optimizacije zadružnog poslovanja i (3) utvrditi postojanje povezanosti između pokazatelja zadružne dobiti i pokazatelja usvojenosti zadružnih načela.

- Analizirani su poslovni podaci za 23 poljoprivredne zadruge. Uzorkovane zadruge su podvrgnute Analizi omeđivanja podataka kako bi se preciznije odredile relativno učinkovite DMU obzirom na korištene poslovne pokazatelje. Model relativne AOMP efikasnosti je dobiven promatranjem parcijalne korelacije i kretanja varijance nakon uklanjanja pojedinih poslovnih pokazatelja. Na taj način se postigao minimalan gubitak informacija i mijenjanje rezultata efikasnosti. Na kraju je definiran konačan AOMP model koji sadrži dva ulazna podataka (*dionici* i *zalihe*) i dva izlazna podataka (*ukupni prihodi* i *ukupni rashodi*).
- Samo dvije poljoprivredne zadruge u uzorku ostvaruju efikasnost u kontekstu CCR i BCC modela, tj. one postižu *ukupnu tehničku efikasnost*, *čistu tehničku efikasnost* i *efikasnost razmjera* (θ^*_{z10} = θ^*_{z19} = 1). One postižu maksimalnu srednju produktivnost i ostvaruju maksimalne stope povrata. Dvije zadruge predstavljaju idealan obrazac poslovanja za preostale zadruge u uzorku jer efikasno koriste svoje resurse i ostvaruju optimalan volumen proizvodnje. Zadruga z19 predstavlja idealan obrazac poslovanja za 21 zadrugu u uzorku, a zadruga z10 predstavlja idealan obrazac poslovanja za 16 poljoprivrednih zadruga u uzorku.
- Tri poljoprivredne zadruge u uzorku ostvaruju *čistu tehničku efikasnost* (z22, z5 i z21). Njihova neefikasnost je posljedica poslovanja iznad optimalnog volumena zbog čega imaju padajuće stope povrata i rastuće prosječne troškove proizvodnje (*disekonomija razmjera*).

- Osamnaest poljoprivrednih zadruga u uzorku ne doseže niti jednu razinu efikasnosti. Među njima, čak četrnaest zadruga posluje ispod optimalne razine i ostvaruje rastuće stope povrata (*ekonomija razmjera*). Ova skupina zadruga može smanjiti troškove po jedinici proizvoda i poboljšati svoju efikasnost povećanjem razmjera proizvodnje (z1, z2, z3, z9, z11, z12, z13, z14, z16, z17, z20, z24, z25 i z26).
- Posljednja skupina od četiri zadruge (z4, z6, z7, z23) posluje iznad optimalne razine zbog čega će svako povećanje broja dionika ili zaliha rezultirati smanjenjem stopa povrata i povećavanjem prosječnih troškova proizvodnje u promatranom razdoblju. Njihovo poslovanje u prvom redu treba pronaći način kako smanjiti volumen zadružne proizvodnje uz korištenje idealnog razmjera broja dionika i zaliha u skladištima.
- Konfirmatorna faktorska analiza je potvrdila da prvo zadružno načelo *otvorenosti i dragovoljnosti* ne predstavlja važan čimbenik poslovanja kod poljoprivrednih zadruga. Reproduciranje rezultata je potvrdilo validnost mjernih konstrukata i pokazatelja koji najvjerodostojnije opisuju sadržaj varijance zadružnih načela. Konačan CFA model čija je potpuna i djelomična robustnost testirana na nekoliko razina sadrži šest faktora koji tematski odgovaraju i opisuju zadružna načela: *Demokratičnost poslovanja* (N2), *Gospodarsko sudjelovanje* (N3), *Poslovna autonomija* (N4), *Zadružna edukacija* (N5), *Međuzadružna suradnja* (N6) i *Briga za lokalnu zajednicu* (N7).
- Metoda potencijala je potvrdila ekonomsku važnost i ulogu zadružnog poduzetništva u lokalnom razvoju. Analiza je pokazala da se dva zadružna načela koja se tematski odnose na ekonomiku i organizaciju poslovanja smatraju najvažnijim načelima. Riječ je o zadružnim načelima *Gospodarsko sudjelovanje* (N3) i *Međuzadružna suradnja* (N6) koja zauzimaju prva dva mjesta u poretku na obje razine samodualne hijerarhije.
- Kada se zadružna načela rangiraju obzirom na poslovne pokazatelje *Gospodarsko sudjelovanje* (N3) zauzima prvo mjesto, a *Međuzadružna suradnja* (N6) drugo mjesto u poretku. Ova načela predstavljaju dva najvažnija principa zadružnog poslovanja. Nakon njih redom slijede: *Demokratičnost poslovanja* (N2), *Poslovna autonomija* (N4), *Zadružna edukacija* (N5) i *Briga za lokalnu zajednicu* (N7).
- Rangiranje načela obzirom na druga zadružna načela (sinergija) je uvjetovalo još jednu promjenu u poretku. Načelo *Briga za lokalnu zajednicu* je skočilo s posljednjeg na treće mjesto u ukupnom poretku. Načela koju su popravila pozicije u konačnom poretku stavljaju naglasak na lokalni karakter zadružnog djelovanja. Time je osim ekonomske važnosti potvrđen lokalni karakter djelovanja zadružnog poduzetništva. Odnos u poretku između preostala tri načela je ostao nepromijenjen te redom slijede načela *Demokratičnost* (N2), *Poslovna autonomija* (N4) i *Zadružna edukacija* (N5).

7. POPIS LITERATURE

Agrell P.J., Karantininis K. (2000). Cooperative Supply Chains in Peace and at War. The Royal Veterinary and Agricultural University Food and Resource Economic Institute, Copenhagen, Denmark.

Anderson J.C., Gerbing D.W. (1988). Structural Equation Modeling in Practice: A Review and Recommended Two-Step Approach. *Psychological Bulletin,* Vol. 103(3): 411-423.

Antonić M. (2007). “Agrojapra” zadružni putokaz u Podgrmeč. *Sociologija i prostor: časopis za istraživanje prostornoga i sociokulturnog razvoja,* Vol. 45(2): 219-223.

Arcas N., García D., Guzmán I. (2011). Effect of Size on Performance of Spanish Agricultural Cooperatives. *Outlook on Agriculture,* Vol. 40(3): 201-206.

Aresvik O. (1955). Comments on "Economic Nature of the Cooperative Association". *Journal of Farm Economics,* Vol. 37(1): 140-144.

Babić Z., Račić D. (2011). Zadrugarstvo u Hrvatskoj: trendovi, pokazatelji i perspektiva u europskom kontekstu. *Sociologija i prostor: časopis za istraživanje prostornoga i sociokulturnog razvoja,* Vol. 49(3): 287-311.

Bagozzi R.P., Yi Y., Phillips L.W. (1991). Assessing Construct Validity in Organizational Research. *Administrative Science Quarterly,* Vol. 36(3): 421-458.

Bahovec V., Neralić L. (2001). Relative Efficiency of Agricultural Production in County Districts of Croatia. *Mathematical Communications,* Vol. 1(1): 111-119.

Banker R.D. (1984). Estimating Most Productive Scale Size Using Data Envelopment Analysis. *European Journal of Operational Research,* Vol. 17(1): 35-44.

Banker R.D., Charnes A., Cooper W.W. (1984). Some Models for Estimating Technical and Scale Inefficiencies in Data Envelopment Analysis. *Management Science,* Vol. 30(9): 1078-1092.

Barrett P. (2007). Structural Equation Modeling: Adjudging Model Fit. *Personality and Individual Differences,* Vol. 42(5): 815-824.

Beaujean A.A. (2014). *Latent Variable Modeling Using R: A Step-by-Step Guide.* Routledge, New York City, New York.

Ben-Porath Y. (1980). The F-Connection: Families, Friends, and Firms and the Organization of Exchange. *Population and development review,* Vol. 6(1): 1-30.

Bogetoft P., Otto L. (2011). *Benchmarking with DEA, SFA, and R.* Springer Science+Business Media, New York City, New York.

Bonus H. (1986). The Cooperative Association as a Business Enterprise: A Study in the Economics of Transactions. *Journal of Institutional and Theoretical Economics,* Vol. 142(2): 310-339.

Bourdieu P. (1984). *Distinction: A Social Critique of the Judgement of Taste.* Harvard University Press, Cambridge, Massachusetts.

Božić J., Srbljinović A., Lučan L. (2020). Croatian Co-operatives' Story of Revival: Overcoming Internal Obstacles. *Socijalna ekologija: časopis za ekološku misao i sociologijska istraživanja okoline,* Vol. 29(3): 335-361.

Brookings J.B., Bolton B. (1988). Confirmatory Factor Analysis of the Interpersonal Support Evaluation List. *American Journal of Community Psychology,* Vol. 16(1): 137-147.

Brown T.A. (2006). *Confirmatory Factor Analysis for Applied Research. Methodology in the Social Sciences.* Guilford Publications, New York City, New York.

Bruynis C.L., Goldsmith P.D., Hahn D.E., Taylor W.J. (2001). Key Success Factors for Emerging Agricultural Marketing Cooperatives. *Journal of Cooperatives,* Vol. 16(1): 14-24.

Budin T. (1992). Agrarna struktura kao činitelj razvitka Hrvatske. *Sociologija sela,* Vol. 30(1-2): 45-52.

Čaklović L. (2012). Measure of Inconsistency for the Potential Method. Springer Berlin Heidelberg, Berlin, Heidelberg, str. 102-114.

Čaklović L. (2014). *Teorija vrednovanja s naglaskom na metodu potencijala: Principi, metode, primjene.* Naklada Slap, Jastrebarsko, Hrvatska.

Čaklović L., Šego V. (2002). Potential Method Applied on Exact Data. *U:* Šorić, K., Hnjak, T. & Scitovski, R., ur. 9th International Conference on Operational Research KOI2002, Croatian Operational Research Society (CRORS), October 2-4, Trogir, Croatia, str. 237-248.

Chaddad F.R., Cook M.L. (2004). Understanding New Cooperative Models: An Ownership–Control Rights Typology. *Review of Agricultural Economics,* Vol. 26(3): 348-360.

Charnes A., Cooper W.W., Rhodes E. (1978). Measuring the Efficiency of Decision Making Units. *European Journal of Operational Research,* Vol. 2(6): 429-444.

Chaves Avila R., Luis Monzón Campos J. (2010). Socijalna ekonomija u Europskoj uniji. *Revija za socijalnu politiku,* Vol. 17(1): 113-138.

Chen F.F., Sousa K.H., West S.G. (2005). Teacher's Corner: Testing Measurement Invariance of Second-Order Factor Models. *Structural Equation Modeling: A Multidisciplinary Journal,* Vol. 12(3): 471-492.

Chloupková J. (2003). European Cooperative Movement: Background and Common Denominators. Royal Veterinary and Agricultural University, Copenhagen, Denmark.

Chloupková J., Svendsen G.L.H., Svendsen G.T. (2003). Building and Destroying Social Capital: The Case of Cooperative Movements in Denmark and Poland. *Agriculture and Human Values: Journal of the Agriculture, Food, and Human Values Society,* Vol. 20(3): 241-252.

Coelli T.J., Rao D.S.P., Battese G.E. (2005). *An Introduction to Efficiency and Productivity Analysis.* Springer Science & Business Media, New York.

Coleman J.S. (1988). Social Capital in the Creation of Human Capital. *American Journal of Sociology,* Vol. 94(1): 95-120.

Collins R.A. (1991a). Analysis of Economic Motives for Cooperative Conversions to Corporations. (ur. Coppock, R.), Center for Cooperatives.

Collins R.A. (1991b). The Conversion of Cooperatives to Publicly Held Corporations: A Financial Analysis of Limited Evidence. *Western Journal of Agricultural Economics,* Vol. 16(2): 326-330.

Cooper W.W., Seiford L.M., Tone K. (2007). *Data Envelopment Analysis: A Comprehensive Text with Models, Applications, References and DEA-Solver Software.* Springer Science+Business Media, New York City, New York.

Cooper W.W., Seiford L.M., Zhu J. (2004). *Handbook on Data Envelopment Analysis.* Kluwer Academic Publishers, Boston.

Costa E., Carini C. (2016). Northern and Southern Italian Social Cooperatives during the Economic Crisis: A Multiple Factor Analysis. *Service Business,* Vol. 10(2): 369-392.

Csárdi G., Nepusz T. (2006). The igraph Software Package for Complex Network Research. *InterJournal, complex systems,* Vol. 1695(5): 1-9.

De Condorcet M. (1785). *Essai sur l'application de l'analyse à la probabilité des décisions: Rendues à la pluralité des voix.* L'imprimerie royale, Paris.

Dunn J.R. (1988). Basic Cooperative Principles and Their Relationship to Selected Practices. *Journal of Agricultural Cooperation,* Vol. 3(1): 83-93.

Emelianoff I.V. (1948). *Economic Theory of Cooperation: Economic Structure of Cooperative Organizations.* Center for Cooperatives University of California, Washington, D.C.

Emrouznejad A., Parker B.R., Tavares G. (2008). Evaluation of Research in Efficiency and Productivity: A Survey and Analysis of the First 30 Years of Scholarly Literature in DEA. *Socio-Economic Planning Sciences,* Vol. 42(3): 151-157.

Emrouznejad A., Yang G.-l. (2018). A Survey and Analysis of the First 40 Years of Scholarly Literature in DEA: 1978–2016. *Socio-Economic Planning Sciences,* Vol. 61(1): 4-8.

Enke S. (1945). Consumer Coöperatives and Economic Efficiency. *The American Economic Review,* Vol. 35(1): 148-155.

European Commision (2016). *Young People in Farming*. Brussels, Belgium: European Commision. (preuzeto s: https://ec.europa.eu/info/food-farming-fisheries/key-policies/common-agricultural-policy/income-support/young-farmers_en; pristupljeno: 26. ožujka 2021.).

European Parliament (2012). Izvješće o doprinosu zadruga prevladavanju krize (2012/2321(INI)). (ur. Patrizia, T.), Brussels, Belgium.

EUROSTAT (2016). *Poljoprivredna gospodarstva i poljoprivredno zemljište u Europskoj uniji – statistički podaci*. EUROSTAT. (preuzeto s: https://ec.europa.eu/eurostat/web/main/home; pristupljeno: 24. travnja 2021.).

Fairbairn B. (2003). *Three Strategic Concepts for the Guidance of Co-operatives: Linkage, Transparency, and Cognition.* Centre for the Study of Co-operatives University of Saskatchewan,

Fan X., Thompson B., Wang L. (1999). Effects of Sample Size, Estimation Methods, and Model Specification on Structural Equation Modeling Fit Indexes. *Structural Equation Modeling: A Multidisciplinary Journal,* Vol. 6(1): 56-83.

Farrell M.J. (1957). The Measurement of Productive Efficiency. *Journal of the Royal Statistical Society: Series A (General),* Vol. 120(3): 253-290.

Fazzini M., Russo A. (2014). Profitability in the Italian Wine Sector: An Empirical Analysis of Cooperatives and Investor-Owned Firms. *International Journal of Academic Research in Accounting, Finance and Management Sciences,* Vol. 4(3): 128-135.

Feng L., Friis A., Nilsson J. (2016). Social Capital among Members in Grain Marketing Cooperatives of Different Sizes. *Agribusiness,* Vol. 32(1): 113-126.

Ferrier G.D., Porter P.K. (1991). The Productive Efficiency of US Milk Processing Co-operatives. *Journal of Agricultural Economics,* Vol. 42(2): 161-173.

Fornell C., Larcker D.F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research,* Vol. 18(1): 39-50.

Franić R., Grgić Z., Njavro M. (2004). EU-integracijski pritisak i potraga za pravim akterima tržišnog razvoja poljoprivrede. *Društvena istraživanja: časopis za opća društvena pitanja,* Vol. 13(1-2): 49-71.

Franić R., Jurišić Ž., Gelo R. (2014). Food Production and Rural Development–Croatian Perspective within the European Context. *Agroeconomia Croatica,* Vol. 4(1): 16-24.

Fulton M., Vercammen J. (1995). The Distributional Impact of Non-Uniform Pricing Schemes for Cooperatives. *Journal of Cooperatives,* Vol. 10(1): 18-32.

Galanopoulos K., Aggelopoulos S., Kamenidou I., Mattas K. (2006). Assessing the Effects of Managerial and Production Practices on the Efficiency of Commercial Pig Farming. *Agricultural Systems,* Vol. 88(2-3): 125-141.

Gattoufi S., Oral M., Reisman A. (2004). Data Envelopment Analysis Literature: A Bibliography Update (1951–2001). *Journal of Socio-Economic Planning Sciences,* Vol. 38(2-3): 159-229.

Guzmán I., Arcas N. (2008). The Usefulness of Accounting Information in the Measurement of Technical Efficiency in Agricultural Cooperatives. *Annals of Public and Cooperative Economics,* Vol. 79(1): 107-131.

Hair J.F., Black W.C., Babin B.J., Anderson R.E. (2010). *Multivariate data analysis: a global perspective.* Prentice Hall, Upper Saddle River, New Jersey.

Hansen M.H., Morrow Jr J.L., Batista J.C. (2002). The Impact of Trust on Cooperative Membership Retention, Performance, and Satisfaction: An Exploratory Study. *International Food and Agribusiness Management Review,* Vol. 5(1): 41-59.

Harte L.N. (1997). Creeping Privatisation of Irish Co-operatives: A Transaction Cost Explanation. U: *Strategies and Structures in the Agro-food Industries* (ur. Nilsson, J. & van Dijk, G.), Van Gorcum & Comp. B.V., Assen, Netherlands, str. 32-54.

Hayton J.C., Allen D.G., Scarpello V. (2004). Factor Retention Decisions in Exploratory Factor Analysis: A Tutorial on Parallel Analysis. *Organizational Research Methods,* Vol. 7(2): 191-205.

HCZP (2016). Godišnje izvješće o stanju zadružnog poduzetništva za 2016. godinu. Hrvatski centar za zadružno poduzetništvo, Zagreb, Hrvatska.

Helmberger P., Hoos S. (1962). Cooperative Enterprise and Organization Theory. *Journal of Farm Economics,* Vol. 44(2): 275-290.

Henseler J., Ringle C.M., Sarstedt M. (2015). A New Criterion for Assessing Discriminant Validity in Variance-Based Structural Equation Modeling. *Journal of the Academy of Marketing Science,* Vol. 43(1): 115-135.

Hill R. (2000). The Case of the Missing Organizations: Co-Operatives and the Textbooks. *The Journal of Economic Education,* Vol. 31(3): 281-295.

HNB (2020). *Popis kreditnih unija upisanih u sudski registar (stanje 17. studenog 2020.)*. Zagreb, Hrvatska: Hrvatska narodna banka. (preuzeto s: https://www.hnb.hr/; pristupljeno: April 19 2021.).

Hollingsworth B., Smith P. (2003). Use of Ratios in Data Envelopment Analysis. *Applied Economics Letters,* Vol. 10(11): 733-735.

Horn J.L. (1965). A Rationale and Test for the Number of Factors in Factor Analysis. *Psychometrika,* Vol. 30(2): 179-185.

HSZ (2005). *Promicanje razvoja zadrugarstva u Hrvatskoj: neke smjernice za institucije koje se bave lokalnim i regionalnim gospodarskim razvojem.* Hrvatski savez zadruga, Zagreb.

Hu L.-t., Bentler P.M. (1998). Fit Indices in Covariance Structure Modeling: Sensitivity to Underparameterized Model Misspecification. *Psychological Methods,* Vol. 3(4): 424-453.

Hu L.-t., Bentler P.M. (1999). Cutoff Criteria for Fit Indexes in Covariance Structure Analysis: Conventional Criteria versus New Alternatives. *Structural Equation Modeling: A Multidisciplinary Journal,* Vol. 6(1): 1-55.

ICA (2015). *Economic contribution of cooperative sector*. International Co-operative Alliance. (preuzeto s: https://www.ica.coop/en; pristupljeno: 15. ožujka 2015.).

ICA (2021). *Identity .coop*. Oxford, United Kingdom: International Co-operative Alliance. (preuzeto s: https://identity.coop/; pristupljeno: 03. svibnja 2021.).

Iliopoulos C. (2005). New Generation Cooperatives: The Potential of an Innovative Institutional Arrangement for Mediterranean Food Supply Chains. *New Medit,* Vol. 4(1): 14-20.

Jenkins L., Anderson M. (2003). A Multivariate Statistical Approach to Reducing the Number of Variables in Data Envelopment Analysis. *European Journal of Operational Research,* Vol. 147(1): 51-61.

Jones D.C., Kalmi P. (2012). Economies of Scale versus Participation: A Co-operative Dilemma? *Journal of Entrepreneurial and Organizational Diversity,* Vol. 1(1): 37-64.

Kaarlehto P. (1955). Cooperation as a Form of Economic Integration. *Acta Agriculturae Scandinavica,* Vol. 5(1): 85-97.

Kaiser H.F. (1974). An Index of Factorial Simplicity. *Psychometrika,* Vol. 39(1): 31-36.

Kalmi P. (2007). The Disappearance of Cooperatives from Economics Textbooks. *Cambridge Journal of Economics,* Vol. 31(4): 625-647.

Kelley K., Pornprasertmanit S. (2016). Confidence Intervals for Population Reliability Coefficients: Evaluation of Methods, Recommendations, and Software for Composite Measures. *Psychological Methods,* Vol. 21(1): 69-92.

Kline P. (1994). *An Easy Guide to Factor Analysis.* Routledge, London, England.

Knoeber C.R., Baumer D.L. (1983). Understanding Retained Patronage Refunds in Agricultural Cooperatives. *American Journal of Agricultural Economics,* Vol. 65(1): 30-37.

Kumar S., Gulati R. (2008). An Examination of Technical, Pure Technical, and Scale Efficiencies in Indian Public Sector Banks Using Data Envelopment Analysis. *Eurasian Journal of Business and Economics,* Vol. 1(2): 33-69.

Kyriakopoulos K., Meulenberg M., Nilsson J. (2004). The Impact of Cooperative Structure and Firm Culture on Market Orientation and Performance. *Agribusiness,* Vol. 20(4): 379–396.

Lee C.-C. (2009). Analysis of Overall Technical Efficiency, Pure Technical Efficiency and Scale Efficiency in the Medium-Sized Audit Firms. *Expert Systems with Applications,* Vol. 36(8): 11156-11171.

Leistritz F.L. (2004). Measuring the Economic Impact of Producer Cooperatives. *Cooperatives and Local Development: Theory and Applications for the 21st Century,* Vol.: 247-261.

Lerman Z., Parliament C. (1991). Size and Industry Effects in the Performance of Agricultural Cooperatives. *Agricultural Economics,* Vol. 6(1): 15-29.

López-Espinosa G., Maddocks J., Polo-Garrido F. (2009). Equity-Liabilities Distinction: The Case for Co-operatives. *Journal of International Financial Management & Accounting,* Vol. 20(3): 274-306.

Lopez A., Marcuello C. (2006). Agricultural Cooperative and Economic Efficiency. *New Medit: A Mediterranean Journal of Economics, Agriculture and Environment,* Vol. 5(3): 16-23.

Lynch L., Urban M., Sommer R. (1989). De-emphasis on Cooperatives in Introductory Economics Textbooks. *Journal of Agricultural Cooperation,* Vol. 4(89-92.

MacCallum R.C., Browne M.W., Sugawara H.M. (1996). Power Analysis and Determination of Sample Size for Covariance Structure Modeling. *Psychological Methods,* Vol. 1(2): 130-149.

Marsh H.W., Hocevar D. (1985). Application of Confirmatory Factor Analysis to the Study of Self-Concept: First-and Higher Order Factor Models and Their Invariance Across Groups. *Psychological Bulletin,* Vol. 97(3): 562-582.

Mataga Ž. (2009). *Etičke vrijednosti i gospodarski značaj zadrugarstva: hrvatsko zadrugarstvo na povijesnim razmeđima.* MAK GOLDEN d.o.o., Zagreb, Hrvatska.

Mateos-Ronco A., Lajara-Camilleri N. (2014). Capital Structure and Financing Decisions of Agricultural Cooperatives: Spanish Evidence. 88th Annual Conference AgroParisTech, Agricultural Economics Society, April 9-11, Paris, France, str. 1-14.

Matijašević A. (2009). Zadružno zakonodavstvo u Hrvatskoj: razvoj i problemi legislative poljoprivrednog zadrugarstva. *Sociologija i prostor : časopis za istraživanje prostornoga i sociokulturnog razvoja,* Vol. 43(1): 153-170.

McCoach B.D., Black A.C., O'Connell A.A. (2007). Errors of Inference in Structural Equation Modeling. *Psychology in the Schools,* Vol. 44(5): 461-470.

Merrett C.D., Walzer N. (2003). *Cooperatives and Local Development: Theory and Applications for the 21st Century.* M.E. Sharpe, Armonk, New York.

Meštrović M., Štulhofer A. (1998). *Sociokulturni kapital i tranzicija u Hrvatskoj.* Hrvatsko sociološko društvo, Zagreb, Hrvatska.

Mihalj P. (1998). Posjedovna struktura hrvatske poljoprivrede – limitirajući činitelj agrarne proizvodnje. *Politička misao: časopis za politologiju,* Vol. 35(4): 224-238.

Milfont T.L., Fischer R. (2010). Testing Measurement Invariance across Groups: Applications in Cross-Cultural Research. *International Journal of Psychological Research,* Vol. 3(1): 111-121.

Monzón Campos J.L., Chaves Ávila R. (2012). The Social Economy in the European Union. (ur. Demoustier, D., Spear, R., Zevi, A., Carini, C. & Huncova, M. (eds.), International Centre of Research and Information on the Public, Social and Cooperative Economy (CIRIEC), Brussels, Belgium.

Mooney P., Gray T.W. (2002). Cooperative Conversion and Restructuring in Theory and Practice. United States Department of Agriculture, Washington, D.C.

Mooney P.H., Majka T.J. (1995). *Farmers' and Farm Workers' Movements: Social Protest in American Agriculture.* Twayne Publishers, New York.

Narodne novine-NN (1993). Uredba o zabrani raspolaganja zadružnom imovinom (NN, br. 16/1993). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

Narodne novine-NN (1995). Zakon o zadrugama (NN, br. 36/1995). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

Narodne novine-NN (1998). Zakon o štedno-kreditnim zadrugama (NN, br. 47/1998). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

Narodne novine-NN (2002). Zakon o izmjenama i dopunama Zakona o zadrugama (NN, br. 12/2002). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

Narodne novine-NN (2011). Zakon o zadrugama (NN, br. 34/2011). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

Narodne novine-NN (2012). Pravilnik o evidenciji zadruga, zadružnih saveza i ostalih članova Hrvatskog saveza zadruga (NN, br. 56/2012). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

Narodne novine-NN (2013). Zakon o izmjenama i dopunama Zakona o zadrugama (NN, br. 125/2013). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

Narodne novine-NN (2014). Zakon o izmjenama i dopunama Zakona o zadrugama (NN, br. 76/2014). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

Narodne novine-NN (2018). Zakon o izmjenama Zakona o zadrugama (NN, br. 114/2018). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

Narodne novine-NN (2019). Zakon o izmjeni Zakona o zadrugama (NN, br. 98/2019). (preuzeto s: http://narodne-novine.nn.hr/; pristupljeno: 08. ožujka 2021.).

NCBA (2015). *Economic Contribution of Cooperative Sector*. National Cooperative Business Association. (preuzeto s: https://ncbaclusa.coop/; pristupljeno: 15. ožujka 2015.).

Nedanov A., Franić R., Gugić J. (2012). Analiza zadružnog zakonodavstva Republike Hrvatske. *U:* Pospišil, M., ed. 47th Croatian and 7th International Symposium on Agriculture, University of Zagreb, Faculty of Agriculture, February 13 - 17, Opatija, Hrvatska, str. 212-216.

Nedanov A., Jerebić V., Čaklović L. (2016). Analysis of Effective Motivation Factors Among Members on Entry in Agricultural Cooperatives. *U:* Dumičić, K., Erjavec, N. & Mirjana, P.B., ur. ISCCRO'16: The 1st International Statistical Conference in Croatia, Hrvatsko statističko društvo, Zagreb, str. 20.

Nedanov A., Ljubaj T., Zrakić M. (2013). Hrvatsko zadrugarstvo na primjeru poljoprivredne zadruge Sveti Križ Začretje. *U:* Marić, S. & Lončarić, Z., ur. 48th Croatian and 8th

International Symposium on Agriculture, Poljoprivredni fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku, February 17 - 22, Dubrovnik, Hrvatska, str. 195-199.

Nedanov A., Žutinić Đ. (2015). Cooperative Organization as a Factor of Competitiveness and Sustainability in Croatian Agriculture. *The Journal Agriculture and Forestry,* Vol. 61(1): 113-120.

Nedanov A., Žutinić Đ. (2018). A Correspondence Analysis of Motivational Factors for Joining Agricultural Cooperatives in Croatia. *New Medit, A Mediterranean Journal of Economics, Agriculture and Environment,* Vol. 17(3): 79-92.

Neralić L. (1996). O nekim primjenama analize omeđivanja podataka u bankarstvu. *Ekonomija,* Vol. 2(3): 493-521.

Nilsson J. (1998). The Emergence of New Organizational Models for Agricultural Cooperatives. *Swedish Journal of Agricultural Research,* Vol. 28(1): 39-48.

Nilsson J., Kihlén A., Norell L. (2009). Are Traditional Cooperatives an Endangered Species? About Shrinking Satisfaction, Involvement and Trust. *International Food Agribusiness Management Review,* Vol. 12(4): 101-122.

Nilsson J., Svendsen G.L.H., Svendsen G.T. (2012). Are Large and Complex Agricultural Cooperatives Losing Their Social Capital? *Agribusiness,* Vol. 28(2): 187-204.

Nourse E.G. (1922). The Economic Philosophy of Co-operation. *The American Economic Review,* Vol. 12(4): 577-597.

Nunnally J.C., Bernstein I.H. (1994). *Psychometric Theory.* McGraw-Hill, Inc., New York.

Ohm H. (1956). Member Behavior and Optimal Pricing in Marketing Cooperatives. *Journal of Farm Economics,* Vol. 38(2): 613-621.

Ollila P. (1984). Member Influence in Cooperatives: Contributions of Scandinavian Studies to the Research Conducted in the United States. *Agricultural and Food Science,* Vol. 56(2): 101-129.

Ollila P., Nilsson J., von Brömssen C. (2011). Changing Member Loyalty in Producer Cooperatives. Paper for the 5th international conference on economics and Management of Networks (EMNet), December 1-3, Limassol, Cyprus, str. 1-9.

Österberg P., Nilsson J. (2009). Members' Perception of their Participation in the Governance of Cooperatives: The Key to Trust and Commitment in Agricultural Cooperatives. *Agribusiness,* Vol. 25(2): 181-197.

Paldam M., Svendsen G.T. (2000). An Essay on Social Capital: Looking for the Fire Behind the Smoke. *European Journal of Political Economy,* Vol. 16(2): 339-366.

Pavličević D. (2010). *Hrvatske kućne/obiteljske zadruge I. (do 1881).* Golden Marketing, Zagreb, Hrvatska.

Phillips R. (1953). Economic Nature of the Cooperative Association. *Journal of Farm Economics,* Vol. 35(1): 74-87.

Piesse J., Doyer T., Thirtle C., Vink N. (2005). The Changing Role of Grain Cooperatives in the Transition to Competitive Markets in South Africa. *Journal of Comparative Economics,* Vol. 33(1): 197-218.

Putnam R.D. (2000). *Bowling Alone: The Collapse and Revival of American Community.* Simon & Schuster, New York City, New York.

Putnam R.D., Leonardi R., Nanetti R. (1993). *Making Democracy Work: Civic Traditions in Modern Italy.* Princeton University Press, Princeton, New Jersey.

R Core Team (2021). *R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing*. Vienna, Austria. (preuzeto s: https://www.R-project.org/; pristupljeno: 15. veljače 2021.).

Rabar D. (2010). Ocjenjivanje efikasnosti poslovanja hrvatskih bolnica metodom analize omeđivanja podataka. *Ekonomski pregled,* Vol. 61(9-10): 511-533.

Radinović S., Žutinić Đ. (2007). Može li Hrvatska imati konkurentnu obiteljsku poljoprivredu? Prilog istraživanju agrarne strukture. *Društvena istraživanja: časopis za opća društvena pitanja,* Vol. 16(1-2): 175-197.

Ramanathan R. (2003). *Introduction to Data Envelopment Analysis: A Tool for Performance Management.* Sage Publications, New Delhi, India.

Rhodes V.J. (1983). The Large Agricultural Cooperative as a Competitor. *American Journal of Agricultural Economics,* Vol. 65(5): 1090-1095.

Robotka F. (1947). A Theory of Cooperation. *Journal of Farm Economics,* Vol. 29(1): 94-114.

Saaty T.L. (2003). Decision-Making with the AHP: Why is the Principal Eigenvector Necessary. *European Journal of Operational Research,* Vol. 145(1): 85-91.

Saaty T.L., Vargas L.G. (1982). *The Logic of Priorities: Applications in Business, Energy, Health, and Transportation.* Springer-Science+Business Media, B.V., New York.

Sarkis J. (2007). Preparing your Data for DEA. U: *Modeling Data Irregularities and Structural Complexities in Data Envelopment Analysis* (ur. Zhu, J. & Cook, W.D.), Springer Science+Business Media, LLC, Boston, Massachusetts, str. 305-320.

Satorra A., Bentler P.M. (2010). Ensuring Positiveness of the Scaled Difference Chi-square Test Statistic. *Psychometrika,* Vol. 75(2): 243-248.

Schrader L.F. (1989). Equity Capital and Restructuring of Cooperatives as Investor-Oriented Firms. *Journal of Agricultural Cooperation,* Vol. 4(1141-2016-92571): 41-53.

Schreiber J.B., Nora A., Stage F.K., Barlow E.A., King J. (2006). Reporting Structural Equation Modeling and Confirmatory Factor Analysis Results: A Review. *The Journal of Educational Research,* Vol. 99(6): 323-338.

Schugurensky D., McCollum E. (2010). Notes in the Margins: The Social Economy in Economics and Business Textbooks. U: *Researching the Social Economy* (ur. Mook, L., Quarter, J. & Ryan, S.), University of Toronto Press, Toronto, Canada, str. 154-175.

Schumacker R.E., Lomax R.G. (2010). *A Beginner's Guide to Structural Equation Modeling.* Routledge, New York City, New York.

Sexton R.J. (1986). The Formation of Cooperatives: A Game-Theoretic Approach with Implications for Cooperative Finance, Decision Making, and Stability. *American Journal of Agricultural Economics,* Vol. 68(2): 214-225.

Sexton R.J., Iskow J. (1993). What Do We Know About the Economic Efficiency of Cooperatives: An Evaluative Survey. *Journal of Agricultural Cooperation,* Vol. 8(1): 15-27.

Sharifi O. (2013). Financial Management and Ratio Analysis for Agricultural Cooperatives. *Global Journal of Commerce & Management Perspective,* Vol. 2(4): 127-133.

Siisiäinen M. (2000). Two Concepts of Social Capital: Bourdieu vs. Putnam. ISTR Fourth International Conference The Third Sector: For What and for Whom?, Trinity College, July 5-8, Dublin, Ireland, str. 183-204.

Simmons R., Ševarlić M.M., Nikolić M.M. (2010). The Role and Potential of Co-operatives in Poverty Reduction and Local Economic Development in Serbia. U: *Agriculture in Late Transition - Experience of Serbia* (ur. Tomić, D. & Ševarlić, M.M.), Serbian Association of Agricultural Economists and Chamber of Economy of Vojvodina, Belgrade, Serbia, str. 177-193.

Singh S., Coelli T., Fleming E. (2001). Performance of Dairy Plants in the Cooperative and Private Sectors in India. *Annals of Public and Cooperative Economics,* Vol. 72(4): 453-479.

Smith P. (1997). Model Misspecification in Data Envelopment Analysis. *Annals of Operations Research,* Vol. 73(1): 233-252.

Soboh R.A.M.E. (2009). *Econometric Analysis of the Performance of Cooperatives and Investor Owned Firms in the European Dairy Industry.* Ph.D. Doctoral Thesis, Wageningen University.

Soboh R.A.M.E., Lansink A.O., Giesen G., Van Dijk G. (2009). Performance Measurement of the Agricultural Marketing Cooperatives: The Gap between Theory and Practice. *Review of Agricultural Economics,* Vol. 31(3): 446-469.

Soboh R.A.M.E., Lansink A.O., Van Dijk G. (2014). Efficiency of European Dairy Processing Firms. *NJAS - Wageningen Journal of Life Sciences,* Vol. 70-71(6): 53-59.

Staatz J.M. (1983). The Cooperative as a Coalition: A Game-Theoretic Approach. *American Journal of Agricultural Economics,* Vol. 65(5): 1084-1089.

Staatz J.M. (1989). Farmer Cooperative Theory: Recent Developments. Department of Agriculture and Applied Economics University of Minnesota, St. Paul, MN.

Stanojević I. (2015). Analiza zadružnog sustava u 2014. godini. *Agroeconomia Croatica,* Vol. 5(1): 51-57.

Stipetić V. (2005). Razvitak poljoprivredne proizvodnje u Hrvatskoj: tendencije, stanje i osnovni problemi. *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu,* Vol. 23(1): 25-50.

Svendsen G.L.H., Svendsen G.T. (2000). Measuring Social Capital: The Danish Co-operative Dairy Movement. *Sociologia Ruralis,* Vol. 40(1): 72-86.

Szabó G.G. (2010). The Importance and Role of Trust in Agricultural Marketing Co-operatives. *Studies in Agricultural Economics,* Vol. 112): 5-22.

Tabachnick B.G., Fidell L.S. (2007). *Using Multivariate Statistics.* Pearson Education, Inc., Boston, Massachusetts.

Taha H.A. (2006). *Operations Research: An Introduction.* Pearson Prentice Hall, Upper Saddle River, New Jersey.

Thompson B. (2004). *Exploratory and Confirmatory Factor Analysis: Understanding Concepts and Applications.* American Psychological Association, Washington, DC.

Thurstone L.L. (1927). A Law of Comparative Judgment. *Psychological Review,* Vol. 34(4): 273-286.

Torgerson R.E., Reynolds B.J., Gray T.W. (1998). Evolution of Cooperative Thought, Theory, and Purpose. *Journal of Cooperatives,* Vol. 13(1): 1-20.

Tortia E.C., Valentinov V.L., Iliopoulos C. (2013). Agricultural Cooperatives. *Journal of Entrepreneurial and Organizational Diversity,* Vol. 2(1): 23-36.

Tratnik M., Nedanov A., Stracenski Kalauz M., Radinović S. (2011). Hrvatski zadružni pokret - Pozadina i poveznice s europskim zadružnim pokretom. *U:* Pospišil, M., ed. 46th Croatian and 6th International Symposium on Agriculture, University of Zagreb, Faculty of Agriculture, February 14-18, Opatija, Hrvatska, str. 337-340.

Tratnik M., Radinović S., Žutinić Đ. (2007). Zadrugarstvo Hrvatske: Izazovi stabilnosti poljoprivrednih gospodarstava. *Agronomski glasnik,* Vol. 69(1): 63-76.

Valentinov V.L. (2004). Toward a Social Capital Theory of Cooperative Organisation. *Journal of Cooperative Studies,* Vol. 37(3): 5-20.

Valentinov V.L., Iliopoulos C. (2013). Economic Theories of Nonprofits and Agricultural Cooperatives Compared: New Perspectives for Nonprofit Scholars. *Nonprofit and Voluntary Sector Quarterly,* Vol. 42(1): 109-126.

van Dijk G. (1997). Implementing the Sixth Reason for Co-operation: New Generation Co-operatives in Agribusiness. U: *Strategies and Structures in the Agro-food Industries* (ur. Nilsson, J. & van Dijk, G.), Van Gorcum & Comp. B.V., Assen, Netherlands, str. 94-110.

Vennesland B. (2005). Measuring Rural Economic Development in Norway Using Data Envelopment Analysis. *Forest Policy and Economics,* Vol. 7(1): 109-119.

Viitala E.-J., Hänninen H. (1998). Measuring the Efficiency of Public Forestry Organizations. *Forest science,* Vol. 44(2): 298-307.

Vitaliano P. (1977). The Theory of Cooperative Enterprise-Its Development and Present Status. Agricultural Cooperatives and the Public Interest, College of Agricultural and Life Sciences, University of Wisconsin-Madison, June 6-8, St. Louis, Missouri, str. 21-42.

Voorhees C.M., Brady M.K., Calantone R., Ramirez E. (2016). Discriminant Validity Testing in Marketing: An Analysis, Causes for Concern, and Proposed Remedies. *Journal of the Academy of Marketing Science,* Vol. 44(1): 119-134.

Williams B., Onsman A., Brown T. (2010). Exploratory Factor Analysis: A Five-Step Guide for Novices. *Journal of Emergency Primary Health Care (JEPHC),* Vol. 8(3): 1-13.

Wilson P.N. (2000). Social Capital, Trust, and the Agribusiness of Economics. *Journal of Agricultural and Resource Economics,* Vol. 25(1): 1-13.

Worthington R.L., Whittaker T.A. (2006). Scale Development Research: A Content Analysis and Recommendations for Best Practices. *The Counseling Psychologist,* Vol. 34(6): 806-838.

WVS (2021). *The questionnaires (seven waves of the longitudinal World Value Survey fieldwork)*. Beč, Austrija: World Values Survey. (preuzeto s: http://www.worldvaluessurvey.org; pristupljeno: 16. ožujka 2021.).

Župančić M. (2005). Obiteljska poljoprivredna gospodarstva i ruralni razvitak u Hrvatskoj. *Sociologija i prostor: časopis za istraživanje prostornoga i sociokulturnog razvoja,* Vol. 43(1): 171-194.

Zusman P. (1982). Group Choice in an Agricultural Marketing Co-operative. *Canadian Journal of Economics,* Vol. 15(2): 220-234.

8. PRILOZI

8.1. Prilog 1: Anketni upitnik za dionike zadružnog poslovanja

SVEUČILIŠTE U ZAGREBU AGRONOMSKI FAKULTET
Zavod za agrarnu ekonomiku i ruralni razvoj
Svetošimunska cesta 25, 10000 Zagreb

Stavovi i mišljenja zadrugara o zadrugama kao konkurentnom obliku poduzetništva

- anketni upitnik za zadrugare -

2017

Poštovani zadrugari,

Zavod za agrarnu ekonomiku i ruralni razvoj, Agronomskog fakulteta Sveučilišta u Zagrebu, provodi znanstveno istraživanje o mišljenjima i stavovima članova zadruge prema zadruzi i radnoj okolini u kojoj njeni članovi poslovno djeluju i surađuju. Cilj je ovoga istraživanja da saznamo osnovne motive naših zadrugara prema zadrugama, ali i da dobijemo uvid u aktualne ekonomske i socijalne probleme članova zadruga.

Početak ovog istraživanja je anketni upitnik koji stoji pred Vama. Istraživanje se provodi u okviru projekta Ministarstva znanosti, obrazovanja i sporta pod nazivom „*Zadružno organiziranje u jačanju konkurentnosti obiteljske poljoprivrede*“. Podaci iz anketnog upitnika su u potpunosti anonimni i **bit će korišteni isključivo u znanstvene svrhe**. Osnovni rezultati ovoga istraživanja pomoći će kreatorima agrarne politike u definiranju novog dokumenta odnosno „*Strategije razvoja zadružnog poduzetništva Republike Hrvatske*“.

Molimo Vas da **sva** navedena pitanja u anketnom upitniku pozorno pročitate, te se osobno i iskreno odredite prema postavljenim pitanjima u upitniku i to tako da zaokružite broj koji je najbliži vašim osobnim stavovima i mišljenjima.

Unaprijed iskrena zahvalnost na suradnji i molimo Vas da u cijelosti popunjeni upitnik vratite anketaru !

Županija _____

Općina/naselje _____

Anketar _____

Broj anketnog upitnika _____

Datum provedbe ankete: _____

U Zagrebu, 2017. godine

A) OPĆE INFORMACIJE O ZADRUZI i MOTIVI PRISTUPA

A.1. Koje godine je s radom započela Vaša zadruga? Upišite: _____ godine

A.2. Jeste li sudjelovali u osnivanju Vaše zadruge? 1) Da 2) Ne

A.3. Da li je u Vašem mjestu stanovanja tijekom prošlosti poslovala koja zadruga? 1) Da 2) Ne 3) Ne znam

A.4. Koliko ste dugo član ove zadruge?
1) Od samog početka rada zadruge
2) Član sam od godine (*upišite godinu*) _____

A.5. Da li ste zaposleni u zadruzi? 1) Da 2) Ne

A.6. Koja je Vaša uloga/funkcija u zadruzi?
1) Samo sam član zadruge (član skupštine)
2) Član sam nadzornog odbora zadruge
3) Upravitelj (menadžer) zadruge
4) Zaposlen/a sam kao administrativno/tehničko osoblje
5) Pomoćni radnik
6) Samo poslovno surađujem sa zadrugom (*kooperant*), ali nisam njen član

A.7. Koliko je Vaše mjesto stanovanja prostorno udaljeno od uprave ili sjedišta zadruge?
1) Manje od 15 kilometara
2) Od 15 do 30 kilometara
3) Od 31 do 50 kilometara
4) Više od 50 kilometara

A.8. Koristeći navedenu skalu vrijednosti ocijenite <u>važnost pojedinih razloga</u> zbog kojih ste postali članom zadruge?

***1**= nevažan razlog; **2**= slabi razlog; **3**= dovoljan razlog; **4**= veliki razlog; **5**= izrazito veliki razlog*

Modaliteti odgovora:	**Skala vrijednosti:**				
1) Da smanjim rizik svojega poslovanja	1	2	3	4	5
2) Radi sigurnijeg plasmana i prodaje proizvoda	1	2	3	4	5
3) Radi smanjivanja troškova poslovanja	1	2	3	4	5
4) Radi lakšeg dobivanja poljoprivrednih potpora (poticaja)	1	2	3	4	5
5) Radi dostupnosti povoljnijih izvora financiranja moje proizvodnje	1	2	3	4	5
6) Iz osobnog zadovoljstva (osjećaj korisnosti)	1	2	3	4	5
7) Radi postojanja sličnih društvenih pozadina i uvjerenja između članova	1	2	3	4	5
8) Radi upoznavanje novih ljudi	1	2	3	4	5
9) Razvijanje novih vještina i razmjena poslovnih iskustava s drugim poljoprivrednim proizvođačima	1	2	3	4	5
10) Zbog želje da doprinesem razvoju našeg sela/kraja	1	2	3	4	5
11) Nešto drugo, molimo navedite i ocijenite: _____	1	2	3	4	5

A.9. Jeste li bili u mogućnosti samostalno poslovati prije ulaska u zadrugu?
1) Jesam
2) Nisam (zašto?) _____
3) Ne znam

A.10. Tko je najviše utjecao na Vašu odluku da postanete član ove zadruge odnosno s kim ste se najviše savjetovali?
1) Samostalno sam se odlučio na članstvo u zadruzi
2) Moja obitelj
3) Kolege poljoprivrednici u mojem selu/kraju
4) Upravitelj (menadžer) zadruge
5) To je bila zajednička inicijativa našeg sela (cijele lokalne zajednice)
6) Lokalna samouprava putem novčanih potpora i fondova
7) Nešto drugo, molimo upišite _____

A.11. Molimo procijenite koliki postotak Vaše proizvodnje plasirate putem zadruge?
1) Uopće ne plasiram svoju proizvodnju putem zadruge (**0%**)
2) Plasiram manje od polovice svoje ukupne proizvodnje
3) Plasiram polovicu svoje ukupne proizvodnje (**50%**)
4) Plasiram više od polovice svoje ukupne proizvodnje
5) Plasiram svoju cjelokupnu proizvodnju putem zadruge (**100%**)

A.12. Na temelju vašega iskustva, je li za Vas korisno što ste član ove zadruge?
1) U potpunosti je **ne** korisno
2) Uglavnom je **ne** korisno
3) Djelomično je korisno
4) Uglavnom je korisno
5) U potpunosti je korisno

B) PERCEPCIJA O RADU VLASTITE ZADRUGE

B.1. Koliko često se sastaje i raspravlja skupština zadruge (članovi zadruge) o poslovanju zadruge?
1) Jedanput mjesečno
2) Tri do četiri puta godišnje
3) Dva puta godišnje
4) Jedanput godišnje
5) Skupština se okuplja jedino u *izvanrednim* poslovnim situacijama

B.2. Tko donosi poslovne odluke unutar Vaše zadruge?

1) Uglavnom upravitelj (menadžer) zadruge
2) Skupština zadruge (svi članovi po principu 1član - 1 glas)
3) Skupština zadruge na prijedlog upravitelja zadruge
4) Vlasnici vanjskog kapitala (ne članovi zadruge)

B.3. Koliko često ste sudjelovali na sjednicama skupštine zadruge?

1) Sudjelovao sam na svim održanim sjednicama
2) Sudjelovao sam na 2/3 sjednica
3) Sudjelovao sam na otprilike 1/2 sjednica
4) Sudjelovao sam na otprilike 1/3 sjednica
5) Nisam sudjelovao na niti jednoj sjednici

B.4. Koristeći navedenu skalu vrijednosti procijenite stupanj (ne) povjerenja prema svim navedenim tijelima i institucijama?

1= nemam povjerenja; 2= nizak stupanj povjerenja; 3= srednji stupanj povjerenja; 4= visok stupanj povjerenja; 5= imam potpuno povjerenje

Modaliteti odgovora:	Skala vrijednosti:				
1) Povjerenje u ispravnost poslovanja Skupštine zadruge	1	2	3	4	5
2) Povjerenje u ispravnost poslovanja Nadzornog odbora zadruge	1	2	3	4	5
3) Povjerenje u ispravnost poslovanja Upravitelja zadruge	1	2	3	4	5
4) Povjerenje u ispravnost poslovanja zaposlenika i kooperanata (ne članovi zadruge)	1	2	3	4	5
5) Povjerenje u ispravnost rada Hrvatskog saveza zadruga (HSZ) i lokalnih zadružnih saveza	1	2	3	4	5
6) Povjerenje prema zadrugama i zadrugarstvu	1	2	3	4	5

B.5. Koristeći navedenu skalu vrijednosti procijenite stupanj (ne) slaganja sa svakom od navedenih tvrdnji?

1= uopće se ne slažem; 2= ne slažem se; 3= niti se slažem, niti se ne slažem; 4= slažem se; 5= u potpunosti se slažem

Modaliteti odgovora:	Skala vrijednosti:				
1) Zadruga svojim poslovnim aktivnostima podupire održavanje dosadašnjeg broja članova	1	2	3	4	5
2) Zadruga svojim poslovnim aktivnostima podupire ulazak novih članova u zadrugu	1	2	3	4	5
3) Zadruga omogućuje demokratsko upravljanje i rukovođenje poslova za koje samostalno najčešće nismo sposobni	1	2	3	4	5
4) Redovito plaćanje obveza od strane članova zadruge pridonosi održavanju poslovne aktivnosti zadruge	1	2	3	4	5
5) Plasiranjem i prodajom proizvoda članova putem zadruge pridonosi se poslovnoj održivosti zadruge	1	2	3	4	5
6) Skupština zadruge samostalno donosi pravilnik, poslovni i marketinški plan razvoja zadruge	1	2	3	4	5
7) Gospodarska suradnja članova sa zadrugom mora uvijek biti prioritet za člana zadruge čak ako to znači i manje prihoda za njega	1	2	3	4	5
8) Gospodarska suradnja članova uvelike ovisi o uzajamnosti odnosa i povjerenja između članova	1	2	3	4	5
9) Upravitelj zadruge obavještava skupštinu zadruge o planiranim poslovnim aktivnostima i uvažava njeno mišljenje prije donošenja konačne odluke	1	2	3	4	5
10) Zadruga organizira i provodi edukacijske programe namijenjene svim članovima zadruge	1	2	3	4	5
11) Upravitelj zadruge upoznat je s aktualnim istraživanjima i saznanjima iz područja zadrugarstva čije rezultate primjenjuje u svakodnevnom radu zadruge	1	2	3	4	5
12) Svakodnevna suradnja i rad s članovima zadruge izgradilo je povjerenje i uzajamnost odnosa	1	2	3	4	5

B.6. Koristeći navedenu skalu vrijednosti procijenite stupanj (ne) suradnje za svaku navedenu tvrdnju?

1= uopće ne surađuje; 2= rijetko surađuje; 3= povremeno surađuje; 4= često surađuje; 5= vrlo često surađuje

Modaliteti odgovora:	Skala vrijednosti:				
1) Svi članovi zadruge (Skupština) surađuju u donošenju zajedničkih poslovnih odluka	1	2	3	4	5
2) Zadruga surađuje s drugim zadrugama u ostvarivanju poslovnih ciljeva i interesa	1	2	3	4	5
3) Zadruga surađuje i koristi usluge Hrvatskog saveza zadruga (HSZ) i lokalnih zadružnih saveza	1	2	3	4	5
4) Zadruga surađuje i koristi financijske usluge kreditnih unija (*nekadašnje štedno-kreditne zadruge*) u ostvarivanju svojih budućih poslovnih planova i interesa	1	2	3	4	5
5) Zadruga surađuje s nadležnim ministarstvima u cilju poticanja razvoja zadrugarstva, te regionalnog razvoja malog i srednjeg poduzetništva	1	2	3	4	5
6) Zadruga surađuje s jedinicama lokalne samouprave u cilju poticanja razvoja zadrugarstva, te regionalnog razvoja malog i srednjeg poduzetništva	1	2	3	4	5
7) Zadruga surađuje i koristi usluge agencija za očuvanje okoliša i/ili sličnih organizacija	1	2	3	4	5
8) Zadruga surađuje s drugim neprofitnim organizacijama lokalnog kraja (*udruge, crkvene ili kulturološke organizacije*)	1	2	3	4	5
9) Predstavništvo zadruge redovito sudjeluje u razmjeni znanja i informacija s drugim zadrugama na skupovima i konferencijama iz područja zadrugarstva	1	2	3	4	5

B.7. Koristeći navedenu skalu vrijednosti procijenite stupanj (ne) korištenja svakog navedenog izvora podatka u poslovanju sa zadrugom?

1= nikada; 2= jednom godišnje; 3= nekoliko puta godišnje; 4= jednom mjesečno; 5= nekoliko puta mjesečno

Modaliteti odgovora:	Skala vrijednosti:				
1) Koristim međunarodnu znanstvenu i stručnu literaturu iz područja zadružnog poduzetništva	1	2	3	4	5
2) Koristim publiciranu literaturu i savjetodavne usluge Hrvatskog saveza zadruga i/ili lokalnih zadružnih saveza	1	2	3	4	5
3) Koristim informacije i usluge odgovarajućih Ministarstava i organa Vlade vezanih uz zadrugarstvo	1	2	3	4	5
4) Koristim informacije i usluge publicirane od strane jedinica lokalne samouprave	1	2	3	4	5
5) Koristim informativne medije i tisak poput dnevnih novina, radija, televizije (TV), interneta i slično	1	2	3	4	5
6) Kroz razgovor sa svim sudionicima poslovanja zadruge (*upravitelj, članovi i zaposleni u zadruzi*)	1	2	3	4	5

B.8. Iz prethodnog pitanja poredajte tri najvažnija (najčešće korištena) izvora podataka?

1) Najvažniji (najčešći) izvor podataka: _____ 2) Drugi najvažniji izvor podataka: _____ 3) Treći najvažniji izvor podataka: _____

B.9. Kako bi poredali po važnosti navedene edukacijske programe čije poznavanje teorije bitno utječe na uspješnost poslovanja zadruge?

Vrste edukacijskih programa iz područja zadrugarstva:	Rangiranje važnosti programa:
1) Poznavanje i razumijevanje osnova zadrugarstva i njenih sedam načela poslovanja	_____
2) Unapređivanje ekonomskih kapaciteta i okruženja za razvoj zadrugarstva (*infrastrukture, logistike, administracije*)	_____
3) Povećavanje obujma zadružne proizvodnje i poslovanje članova preko zadruge	_____
4) Razvijanje zajedničke marketinške strategije i promocije proizvoda svih članova zadruge	_____
5) Razvijanje društvenih mehanizama za promicanje zadrugarstva kod mlađih generacija	_____
6) Razvijanje mehanizama za jednostavnije i brže donošenja poslovnih odluka skupštine zadruge	_____
7) Podizanje kvalitete i dostupnosti poslovnih informacija za sve članove zadruge	_____
8) Njegovanje i održavanje kvalitete međuljudskih odnosa između članova zadruge	_____
9) Upravljačke (menadžerske) vještine u razvijanju ljudskih potencijala članova zadruge	_____

B.10. Koristeći navedenu skalu vrijednosti procijenite stupanj (ne) slaganja sa svakom od navedenih tvrdnji?

1= uopće se ne slažem; 2= ne slažem se; 3= niti se slažem, niti se ne slažem; 4= slažem se; 5= u potpunosti se slažem

Modaliteti odgovora:	Skala vrijednosti:				
1) Obrazovanje svih sudionika (*upravitelja, članova, zaposlenika*) treba prepustiti samoj zadruzi	1	2	3	4	5
2) Javno obrazovanje o zadružnom poduzetništvu uz zadruge trebale bi provoditi i druge obrazovne institucije (*npr. osnovne i srednje škole, sveučilišta*)	1	2	3	4	5
3) Potreban je veći broj znanstvenih istraživanja iz područja zadružnog poduzetništva	1	2	3	4	5
4) Osiguravanjem stipendija za obrazovanje iz područja zadružnog poduzetništva doprinosi se popularizaciji zadrugarstva kod mlađih generacija	1	2	3	4	5
5) Educiranje ljudi o mogućnostima zadrugarstva predstavlja opće dobro za svako društvo	1	2	3	4	5
6) Važnost pružanja zadružne edukacije danas je mnogo značajnije nego što je nekad bilo	1	2	3	4	5

B.11. Ocijenite slažete li se više s lijevom ili desnom stranom međusobno proturječnih tvrdnji koje se odnose na poslovanje Vaše zadruge?

1= u potpunosti se slažem s izjavom s lijeve strane; 2= slažem se s izjavom s lijeve strane; 3= niti se slažem s lijevom, niti se slažem s desnom stranom izjave; 4= slažem se s izjavom s desne strane; 5= u potpunosti se slažem s izjavom s desne strane

Modaliteti odgovora:	Skala vrijednosti:					Modaliteti odgovora:
1) Zadruga je demokratska organizacija gdje društveni status i razlike između članova ne dolaze do izražaja bez obzira na njihovu suradnju sa zadrugom	1	2	3	4	5	Zadruga je konkurentska organizacija gdje suradnja članova i zadruge utječe na podjelu zadružne dobiti i stvaranje društvenog statusa
2) Zadruga predstavlja društvo koje vodi brigu o interesima članova i zahtjeva novčana izdvajanja za obvezne pričuve	1	2	3	4	5	Zadruga je društvo gdje se članovi brinu sami za sebe s novčanim izdvajanjima za obvezne pričuve
3) Zadruga osigurava poslovnu stabilnost i sigurnost članova postojećim pravilnicima koje donosi	1	2	3	4	5	Zadruga predstavlja neuređeno društvo gdje svatko posluje i odgovara sam za svoje postupke
4) Zadruga stavlja veći naglasak na razvoj članova i razvitak njegovih profesionalnih i osobnih vještina	1	2	3	4	5	Zadruga stavlja veći naglasak na stvaranje ekonomskih rezultata i materijalne imovine
5) Zadruga svojim načinom poslovanja osigurava povećanje udjela zadružnog (zajedničkog) vlasništva	1	2	3	4	5	Zadruga svojim načinom poslovanja osigurava povećanje udjela privatnog vlasništva
6) Zadruga trebala preuzeti veću odgovornost u osiguravanju zadružnih (zajedničkih) interesa	1	2	3	4	5	Članovi zadruga trebaju preuzeti veću odgovornost u osiguravanju zajedničkih interesa

B.12. Koristeći navedenu skalu vrijednosti procijenite stupanj (ne)slaganja sa svakom od navedenih tvrdnji?

***1**= uopće se ne slažem; **2**= ne slažem se; **3**= niti se slažem, niti se ne slažem; **4**= slažem se; **5**= u potpunosti se slažem*

Modaliteti odgovora:	**Skala vrijednosti:**				
1) Zadruga ulaže dio prihoda u zdravstveno osiguranje svojih članova i zaposlenih	1	2	3	4	5
2) Zadruga ulaže dio prihoda u mirovinsko osiguranje svojih članova i zaposlenih	1	2	3	4	5
3) Zadruga ulaže dio prihoda u razvoj lokalne zajednice (*izgradnju infrastrukture, vrtića, škola, parkića*)	1	2	3	4	5
4) Zadruga ulaže dio prihoda u očuvanje okoliša (*zaštitu tla i voda, ekološku i organsku proizvodnju*)	1	2	3	4	5
5) Zadruga ulaže dio prihoda u razvijanje edukacijskih programa blagodati za članove (*osposobljavanje i upravljanje financijama, inovacijama, učinkovitije korištenje fondova*)	1	2	3	4	5
6) Zadruga ulaže dio prihoda u razvijanje novih tehnologija proizvodnje i novih inovativnih rješenja	1	2	3	4	5

B.13. Koristeći navedenu skalu vrijednosti procijenite stupanj (ne)slaganja sa svakom od navedenih tvrdnji?

***1**= uopće se ne slažem; **2**= ne slažem se; **3**= niti se slažem, niti se ne slažem; **4**= slažem se; **5**= u potpunosti se slažem*

Modaliteti odgovora:	**Skala vrijednosti:**				
1) Moja zadruga korištenjem poslovnih usluga drugih zadruga (npr. *marketinga*, *nabavke repromaterijala*, i slično) zadržava svoju autonomiju u poslovanju i provodi odluke skupštine	1	2	3	4	5
2) Moja zadruga korištenjem poslovnih usluga financijskih institucija (*klasičnih banaka*, *kreditnih unija)* zadržava svoju potpunu poslovnu autonomiju i provodi odluke skupštine	1	2	3	4	5
3) Moja zadruga pridržavanjem zakona Vlade zadržava svoju samostalnost u donošenju poslovnih pravilnika zadruge	1	2	3	4	5
4) Moja zadruga korištenjem poslovnih informacija zadružnih institucija (*HSZ*) u promicanju i razvijanju zadrugarstva zadržava svoju autonomiju u poslovanju i provodi odluke skupštine	1	2	3	4	5
5) Moja zadruga korištenjem poslovnih informacija *Ministarstva zaštite okoliša i prirode*, *Agencije za zaštitu okoliša* i slično samostalno određuje tehnologije proizvodnje koje će koristiti u proizvodnji s ciljem očuvanja prirode i okoliša	1	2	3	4	5

C) MIŠLJENJA ISPITANIKA O ZADRUŽNIM VRIJEDNOSTIMA

C.1. Koja tvrdnja najviše odgovara Vašem razumijevanju načela dragovoljnosti i otvorenosti u poslovanju zadruge (samo jedan odgovor)**?**

1) Idealan način za provođenje vlastitih poslovnih interesa povezivanjem i upoznavanjem s novim ljudima kroz zajednički rad i povjerenje
2) Poslovno povezivanje ekonomskih resursa članova zadruge radi provođenja poslovnih interesa za koje najčešće nismo samostalno sposobni
3) Podrazumijeva slobodu ulaska i izlaska člana iz zadruge, nakon podmirenja svih obveza i potraživanja, bez obzira na njegovu spolnu, rasnu, socijalnu, političku ili vjersku diskriminaciju
4) Nešto drugo, molimo upišite: _____

C.2. Koristeći navedenu skalu vrijednosti za svaku izjavu zaokružite jedan broj s desne strane koji je najbliži Vašem stupnju slaganja?

***1**= uopće se ne slažem; **2**= ne slažem se; **3**= niti se slažem, niti se ne slažem; **4**= slažem se; **5**= u potpunosti se slažem*

Modaliteti odgovora:	**Skala vrijednosti:**				
1) Zadruga treba biti otvorena svim zainteresiranim osobama bez obzira na njihovu spolnu, nacionalnu (etničku), socijalnu, političku ili vjersku pripadnost	1	2	3	4	5
2) Demokratsko rukovođenje i nadzor/kontrola poslovanja u zadruzi podrazumijeva aktivno sudjelovanje u donošenju odluka svih članova zadruge	1	2	3	4	5
3) Raspodjela zadružne dobiti među članovima treba se odvijati razmjerno njihovoj poslovnoj suradnji sa zadrugom	1	2	3	4	5
4) Raspodjela zadružnih obveza i dugovanja među članovima zadruge treba se odvijati razmjerno njihovom sudjelovanju u poslovanju sa zadrugom	1	2	3	4	5
5) Zadruga u pravnom prometu i poslovanju s drugim poslovnim subjektima i državnim tijelima treba zadržati svoju samostalnost i neovisnost	1	2	3	4	5
6) Zadruga treba osiguravati kontinuiranu edukaciju, stručno usavršavanje i informiranje svojih članova o novim inovativnim rješenjima u proizvodnji, ali i o koristima i prednostima zadrugarstva	1	2	3	4	5
7) Zadruga treba poticati i održavati poslovnu suradnju s drugim zadrugama na lokalnoj, državnoj i međunarodnoj razini	1	2	3	4	5
8) Zadruga treba voditi brigu o zajednici na način koji pridonosi održivom ekonomskom, socio-kulturološkom i ekološkom razvoju okruženja i cijele lokalne zajednice	1	2	3	4	5

C.3. Koja tvrdnja najviše odgovara Vašem razumijevanju načela demokratske kontrole članova u poslovanju zadruge (samo jedan odgovor)**?**

1) Podrazumijeva način rukovođenja koji ponekad usporava proceduru donošenja odluke skupštine zadruge
2) Podrazumijeva pristup važnim informacija za članove, što omogućuje brzo i učinkovito donošenje odluka o poslovanju zadruge
3) Podrazumijeva mogućnost članskog nadzora i rukovođenja (*1 član - 1 glas*) nad svim poslovnim aktivnostima zadruge u stvaranju njene politike razvoja i donošenju odluka
4) Nešto drugo, molimo upišite: _____

C.4. Koristeći navedenu skalu vrijednosti za svaku izjavu zaokružite jedan broj s desne strane koji je najbliži Vašem stupnju slaganja?

1= uopće se ne slažem; 2= ne slažem se; 3= niti se slažem, niti se ne slažem; 4= slažem se; 5= u potpunosti se slažem

Modaliteti odgovora:	Skala vrijednosti:				
1) Spreman sam izdvajati dio prihoda za održavanje brojnosti članstva radi ekonomske održivosti zadruge	1	2	3	4	5
2) Spreman sam izdvajati dio prihoda zadruge za povećanje brojnosti članstva radi ekonomskog razvitka zadruge	1	2	3	4	5
3) Spreman sam izdvajati dio prihoda zadruge za poticanje gospodarske suradnje članova sa zadrugom	1	2	3	4	5
4) Spreman sam izdvajati dio prihoda zadruge za pokrivanje dugovanja i obveza nastalih lošim poslovanjem zadruge	1	2	3	4	5
5) Spreman sam izdvajati dio prihoda zadruge za poticanje razvoja održivosti lokalne zajednice u kojem zadruga djeluje	1	2	3	4	5
6) Spreman sam izdvajati dio prihoda zadruge za jačanje povjerenja i uzajamnosti između članova zadruge	1	2	3	4	5
7) Spreman sam izdvajati dio prihoda zadruge za kontinuiranu edukaciju članova, iz područja zadrugarstva i sektora proizvodnje u kojem zadruge posluje	1	2	3	4	5

C.5. Koja tvrdnja najviše odgovara Vašem razumijevanju načela gospodarske suradnje članova u poslovanju zadruge (samo jedan odgovor)**?**

1) Podrazumijeva suradnju članova u ostvarivanju ekonomskih rezultata u uvjetima društvene solidarnosti i uzajamnog povjerenja
2) Podrazumijeva zajedničku člansku kontrolu i vlasništvo nad čitavom zadružnom imovinom (*zemlja, infrastruktura, mehanizacija)*
3) Podrazumijeva sudjelovanje članova u poslovanju zadruge što rezultira potpunom zaposlenošću, otvorenim članstvom i zapošljavanjem novih ljudi u zadruzi
4) Podrazumijeva raspodjelu prihoda, ali i obveza zadruge između članova razmjerno njihovom obujmu poslovanja sa zadrugom
5) Nešto drugo, molimo upišite: _____

C.6. Koja tvrdnja najviše odgovara Vašem razumijevanju načela samostalnosti i neovisnosti u poslovanju zadruge (samo jedan odgovor)**?**

1) Podrazumijeva zadržavanje vlasništva članova nad svojom imovinom i samostalnosti u poslovnom odlučivanju Skupštine zadruge
2) Podrazumijeva zakonski problem namjene zadružne imovine nakon prestanka poslovanja zadruge i rješavanje njenog prenošenja na jedinice lokalne samouprave
3) Podrazumijeva da se zadruga u pravnom prometu s drugim pravnim osobama i državnim tijelima isključivo oslanja na rad svojih članova i zadružne resurse pod neposrednim nadzorom svojih članova
4) Nešto drugo, molimo upišite: _____

C.7. Koja tvrdnja najviše odgovara Vašem razumijevanju načela obrazovanja, usavršavanja i informiranja članova zadruge (samo 1 odgovor)?

1) Iznošenje informacija koje razvijaju društvene i komunikacijske vještine članova zadruge na radnom mjestu radi učinkovitijeg donošenja odluka, povećanja zadovoljstva, uzajamnosti i povjerenja između članova
2) Iznošenje informacija i pravovremene distribucije točnih financijskih pokazatelja od strane Upravitelja zadruge
3) Iznošenje informacija koje razvijaju profesionalne i inovativne vještine članova zadruge s ciljem što učinkovitijeg upravljanja, smanjenja troškova proizvodnje i ostvarivanja prava na državne potpore i poticaje
4) Predstavlja svaki oblik obrazovanja i stručnog usavršavanja članova, izabranih predstavnika, upravitelja i zaposlenika zadruge kako bi se doprinijelo općem razvitku zadruge, te promicanju i razumijevanju zadružne tematike
5) Nešto drugo, molimo upišite: _____

C.8. Koja tvrdnja najviše odgovara Vašem razumijevanju načela suradnje među zadrugama u poslovanju zadruge (samo jedan odgovor)?

1) Međusobna kupovina zadružnih proizvoda, zajedničko korištenje informacija, mehanizacije i dijeljenje troškova distribucije između zadruga radi ostvarenja kvalitetnih ekonomskih rezultata
2) Kvaliteta međuljudskih odnosa, zajednička slavlja i organizacije svetkovina između zadruga s ciljem uključivanja svih sudionika u lokalni razvoj te smanjenja društvene isključenosti među njima
3) Svaki oblik suradnje između zadruga radi što učinkovitije službe svojim članovima i u svrhu jačanja zadrugarstva na lokalnoj, regionalnoj, državnoj i međunarodnoj razini
4) Nešto drugo, molimo upišite: _____

C.9. Koja tvrdnja najviše odgovara Vašem razumijevanju načela brige za zajednicu u poslovanju zadruge (samo jedan odgovor)?

1) Osjećaj odgovornosti prema njegovanju socio-kulturoloških i tradicijskih obilježja lokalnog kraja organiziranjem manifestacija i svetkovina, izgradnjom škola, parkića i vrtića i slično
2) Osjećaj odgovornosti brige o zaštiti okoliša novčanim ulaganjima u osposobljavanje članova iz područja organske i ekološke proizvodnje, zaštite tla i voda, recikliranje otpada i slično
3) Zadružna poslovna praksa koja vodi brigu o svim sudionicima lokalnog kraja organiziranjem edukacijskih programa iz područja zadrugarstva i poticanja gospodarske suradnje s drugim zadrugama u cilju razvoja čitave zajednice
4) Nešto drugo, molimo upišite: _____

D) OPĆE STANJE I PLANOVI ZA BUDUĆNOST

D.1. Koliko su u prosjeku Vaši ukupni novčani prihodi ostvareni u poljoprivrednoj proizvodnji?

1) Manje od 50.000 kuna
2) Od 50.001 do 100.000 kuna
3) Od 100.001 do 250.000 kuna
4) Od 250.001 do 500.000 kuna
5) Preko 500.000 kuna

D.2. Koliko ćete ove godine koristiti površina u poslovanju sa zadrugom? (*Ukoliko ne znate točne iznose površina, molimo Vas procijenite!*)

1) Vlastito zemljište _____ ha (1 jutro = 0,5755 ha)
2) U zakupu: _____ ha

D.3. Koliko su u prosjeku bili Vaši dosadašnji novčani prihodi u poslovanju sa zadrugom?

1) Manje od 50.000 kuna
2) Od 50.001 do 100.000 kuna
3) Od 100.001 do 250.000 kuna
4) Od 250.001 do 500.000 kuna
5) Preko 500.000 kuna

D.4. Koliko vlastite poljoprivredne proizvodnje planirate plasirati putem zadruge tijekom slijedeće sezone?

1) Uopće ne planiram plasirati svoju proizvodnju putem zadruge (**0%**)
2) Planiram plasirati manje od polovice svoje ukupne proizvodnje
3) Planiram plasirati polovicu svoje ukupne proizvodnje (**50%**)
4) Planiram plasirati više od polovice svoje ukupne proizvodnje
5) Planiram plasirati svoju cjelokupnu proizvodnju putem zadruge (**100%**)

D.5. Što planirate u slijedećih pet godina poslovanja učiniti s navedenim resursima i proizvodnjom? (*Ukoliko ne znate točne iznose, ili navedene mjerne jedinice nisu odgovarajuće (hektar, tona), molimo Vas da **procijenite iznose i mjerne jedinice** sukladno Vašim planiranim mogućnostima!*)

Modaliteti odgovora:	POVEĆATI ZA:	SMANJITI ZA:	BEZ PROMJENE (upišite X):
1) Planiram vlastite poljoprivredne površine	_____ hektara	_____ hektara	_____
2) Planiram poljoprivredne površine u zakupu	_____ hektara	_____ hektara	_____
3) Planiram volumen ukupne poljoprivredne proizvodnje	_____ tona	_____ tona	_____
4) Planiram ukupan plasman robe putem zadruge	_____ tona	_____ tona	_____

E) OPĆI PODACI O ISPITANIKU:

E.1. Spol:

1) Ženski
2) Muški

E.2. Koliko godina imate? Imam _____ godina

E.3. Vaša školska sprema je:

1) Završena prva četiri razreda osnovne škole
2) Završenih osam razreda osnovne škole
3) Završena srednja škola
4) Završena viša škola ili fakultet

E.4. Koliko članova broji Vaše kućanstvo (*molimo upišite odgovarajuće brojeve*)?

1) Ukupno u kućanstvu: _____
2) Radno *aktivnih* u poljoprivredi: _____
3) Radno *aktivnih* izvan poljoprivrede: _____
4) Radno ***ne** aktivnih* (djeca i umirovljeni): _____

E.5. Koje je Vaše sadašnje zanimanje, posao koji pretežno obavljate izvan zadruge?

1) Obrtnik ili samostalni poduzetnik (*ne poljoprivrednik*)
2) Poljoprivrednik u radnom odnosu (*registrirani poljoprivrednik*)
3) Umirovljeni radnik, službenik,… (*umirovljeni ne poljoprivrednik*)
4) Umirovljeni poljoprivrednik
5) Ostalo, molimo upišite: _____

E.6. U kojem sektoru poljoprivredne proizvodnje poslovno surađujete s Vašom zadrugom?

1) U ratarskoj proizvodnji
2) U povrtlarskoj proizvodnji
3) U voćarskoj proizvodnji
4) U stočarskoj proizvodnji
5) Mješovita proizvodnja
6) Ostalo, molimo upišite: _____

E.7. Koliko dugo se aktivno bavite poljoprivrednom proizvodnjom?

1) Od trenutka ulaska u zadrugu
2) Manje od 5 godina
3) Od 5 do 10 godina
4) Od 10 do 15 godina
5) Više od 15 godina

E.8. Koliko imate vlastitog obradivog zemljišta?

1) Do 1 hektara
2) Od 1,1 do 3,0 hektara
3) Od 3,1 do 5 hektara
4) Od 5,1 do 10,0 hektara
5) Od 10,1 do 20 hektara
6) Preko 20 hektara

E.9. Imate li zakupljenog zemljišta?

1) Da, _____ hektara
2) Ne

E.10. Koliki udio novčanih prihoda Vašeg kućanstva dolazi putem poslovanja sa zadruge?

1) Ne ostvarujem novčane prihode u poslovanju sa zadrugom (***0%** prihoda*)
2) Ostvarujem *manje* od polovice svojih ukupnih novčanih prihoda
3) Ostvarujem polovicu svojih ukupnih novčanih prihoda (***50%** prihoda*)
4) Ostvarujem više od polovice svojih ukupnih novčanih prihoda
5) Sve novčane prihode ostvarujem isključivo u poslovanju sa zadrugom (***100%** prihoda*)

8.2. Prilog 2. Deskriptivna analiza pokazatelja reduciranog skupa

	medijana	aritmetička sredina	standardna devijacija	standardna pogreška procjene atitmetičke sredine
Poslovna autonioma (F1)				
autonomija1	4	4,02	1,02	0,07
autonomija2	4	4,01	0,93	0,07
autonomija4	4	4,06	0,95	0,07
autonomija5	4	3,99	0,87	0,06
Gospodarsko sudjelovanje (F2)				
gospSurad1	4	3,74	0,77	0,05
gospSurad2	4	3,76	1,00	0,07
gospSurad5	4	3,58	0,95	0,07
gospSurad7	4	3,87	0,91	0,06
gospSurad8	4	3,77	0,89	0,06
Zadružna suradnja (F3)				
zadSurad2	3	2,76	1,11	0,08
zadSurad3	2	2,08	1,29	0,09
zadSurad4	3	2,99	1,21	0,09
zadSurad6	3	2,72	1,17	0,08
zadSurad8	3	3,00	1,06	0,07
Briga za zajednicu (F4)				
brigaZajed1	3	2,79	1,27	0,09
brigaZajed4	3	3,19	1,04	0,07
brigaZajed5	3	3,08	1,17	0,08
brigaZajed6	4	3,45	0,99	0,07
Zadružna edukacija (F5)				
edukacija1	2	1,88	1,06	0,07
edukacija2	2	2,36	1,18	0,08
edukacija3	2	2,55	1,22	0,09
edukacija4	3	2,96	1,14	0,08
Demokratičbist poslovanja (F6)				
demokraticnost2	3	2,70	0,98	0,07
demokraticnost3	2	2,39	0,94	0,07
demokraticnost5	3	2,66	0,95	0,07
demokraticnost6	3	3,10	1,14	0,08
Otvorenost i dragovoljnost poslovanja				
otvorenost1	4	4,03	0,82	0,06
otvorenost2	3	3,41	1,00	0,07
otvorenost3	4	3,96	0,96	0,07

Izvor: Izračun autora na temelju anketnih podataka.

9. ŽIVOTOPIS AUTORA I POPIS OBJAVLJENIH RADOVA

Aleksandar Nedanov je rođen u Zagrebu 22. prosinca 1983. godine. U rujnu 2009. godine završio je po predbolonjskom programu diplomski studij *Agroekonomike* na Agronomskom fakultetu Sveučilišta u Zagrebu. U razdoblju od 2010. do 2016. godine kao znanstveni novak radio je na Zavodu za agrarnu ekonomiku i ruralni razvoj na Agronomskom fakultetu. U tom razdoblju aktivno je sudjelovao u znanstvenom, nastavnom i stručnom radu Agronomskog fakulteta. Bio je suradnik na znanstvenim projektima (1) *Strukturna prilagodba poljoprivrede i seoskog područja Hrvatske* i (2) *Zadružno organiziranje u jačanju konkurentnosti obiteljske poljoprivrede*. U ožujku 2010. godine je upisao Poslijediplomski doktorski studij *Ekonomika poljoprivrede*. U sklopu doktorskog studija bio je na usavršavanjima u inozemstvu:

- U kolovozu 2010. godine usavršavao se na Montana State University u Bozemanu gdje je slušao predavanja iz četiri nastavna kolegija i bio aktivno uključen u provedbu projekta *Economic Contribution Montana Cooperatives Makes to the State Economy*;
- U lipnju 2012. godine u sklopu projekta *Value Chain Analysis in fresh fruit and vegetable supply sector, opportunities and risks for the small scale farmers* specijalizirao se u Nizozemskoj na Sveučilištu i istraživačkom centru u Wageningenu (WUR).

Od srpnja 2012. do rujna 2013. godine sudjeluje u radu uredništva mjesečnog časopisa *NOVA ZADRUGA Glasilo za zadružno poduzetništvo* gdje je u suradnji sa studentima objavljivao stručne članke. U lipnju 2014. godine kao glavni voditelj studentskog programa sudjeluje u organizaciji i provedbi *53. IALB dana i 1. EUFRAS konferencije poljoprivrednih savjetodavaca Europe* pod pokroviteljstvom *Savjetodavne službe*. U listopadu 2014. godine je odabran za glavnog predstavnika Agronomskog fakulteta da sudjeluje u radu uže Radne skupine za izradu nacionalne *Strategije razvoja zadruga 2015.-2020.* pod pokroviteljstovom *Ministarstva poduzetništva i obrta*.

Znanstveni interes doktoranda su agroekonomika, matematika, statistika, zadružno poduzetništvo i poslovno povezivanje u sektoru agrobiznisa. Do sada je ukupno objavio 17 znanstvenih i 15 stručnih članaka. Sudjelovao je na više od 20 konferencija, simpozija i radionica. Bio je gost predavač na 3 i voditelj sekcija na 2 konferencije. Kao neposredni voditelj sudjelovao je u izradi 10 završnih radova i 8 stručnih projekata. U suradnji sa studentima je objavio 8 stručnih, 2 znanstvena rada i 1 sažetak.

Popis svih radova iz Hrvatske znanstvene bibliografije (CROSBI):

https://bib.irb.hr/lista-radova?autor=321440

Popis objavljenih znanstvenih radova (kronološki redoslijed):

Nedanov A., Žutinić Đ. (2018). A Correspondence Analysis of Motivational Factors for Joining Agricultural Cooperatives in Croatia. New Medit: A Mediterranean Journal of Economics, Agriculture and Environment, Vol. 17(3): 79-92.

Nedanov A., Jerebić V., Čaklović L. (2016). Analysis of Effective Motivational Factors Among Members on Entry in Agricultural Cooperatives, U: *Book of Abstracts of the ISCRO-International Statistical Conference in Croatia*, (ur. Dumičić K., Erjavec N. i Pejić Bach M.), Hrvatsko statističko društvo (HSD), Hrvatska, Zagreb, str. 20.

Nedanov A., Žutinić Đ. (2015). Cooperative Organization as a Factor of Competitiveness and Sustainability in Croatian Agriculture. The Journal Agriculture and Forestry, Vol. 61(1): 113-120.

Đurđica Ž., Hadelan L., Tomić M., **Nedanov A.** (2015). Young Farmer's Attitudes Towards the Business Cooperation, U: *Book of Proceedings: Sixth International Scientific Agricultural Symposium "Agrosym 2015"*, (ur. Kovačević D.), University of East Sarajevo Faculty of Agriculture, BIH, Sarajevo, str. 1868-1873.

Hadelan L., Zrakić M., **Nedanov A.** (2015). Produktivnost hrvatske poljoprivrede i mogućnosti njezinog povećanja, U: *Zbornik radova 50. hrvatskog & 10. međunarodnog simpozija agronoma* (ur. Pospišil M), Sveučilište u Zagrebu Agronomski fakultet, Hrvatska, Opatija, str. 114-118.

Nedanov A., Žutinić Đ., Mihić I. (2015). Revizija u zadrugarstvu i zadružnom poduzetništvu, U: *Zbornik radova 50. hrvatskog & 10. međunarodnog simpozija agronoma* (ur. Pospišil M.), Sveučilište u Zagrebu Agronomski fakultet, Hrvatska, Opatija, str. 119-123.

Tratnik M., **Nedanov A.**, Knezić Ž. (2015). Jačanje konkurentskih sposobnosti sektora tekstila i kože kroz zadrugu kao organizacijsku formu, 8. znanstveno-stručno savjetovanje Tekstilna znanost i gospodarstvo, (ur. Bischof S. i Penava Ž.), Sveučilište u Zagrebu Tekstilno tehnološki fakultet, Hrvatska, Dubrovnik, str. 178-183.

Ljubaj T., **Nedanov A.** (2014). Važnost skladišnih kapaciteta u jačanju konkurentnosti obiteljske poljoprivredne proizvodnje: slučaj Međimurske županije i PZ Čakovec, U: *Proceedings of the 4th International Conference "Vallis Aurea" Focus on: Regional & Innovation Development*, (ur. Katalinić B.), Požega-Beč: Veleučilište u Požegi, DAAAM International Vienna, Hrvatska, Požega, str. 359-367.

Zrakić M., Grgić I., **Nedanov A.** (2014). Primjena metode modeliranja u sektorskoj analizi, U: *Zbornik radova 49. hrvatskog & 9. međunarodnog simpozija agronoma*, (ur. Marić S. i Lončarić Z.), Poljoprivredni fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku, Hrvatska, Dubrovnik, str. 191-196.

Nedanov A., Žutinić Đ., Kuš S. (2014). Uloga zadruga u promicanju socijalne ekonomije i socijalno odgovornog poduzetništva, U: *Zbornik radova 49. hrvatskog & 9. međunarodnog simpozija agronoma*, (ur. Marić S. i Lončarić Z.), Poljoprivredni fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku, Hrvatska, Dubrovnik, str. 166-170.

Nedanov A., Žutinić Đ., Bokan N. (2014). Cooperatives as a Social Pillar of Local Development, poster section, 14th EAAE Congress Ljubljana Agri-Food and Rural Innovations in Healthier Societies, Slovenia, Ljubljana.

Nedanov A., Volarević S., Ljubaj T. (2013). Uloga i utjecaj Međunarodnog saveza zadruga u razvoju zadrugarstva, U: *Zbornik sažetaka 48. hrvatskog & 8. međunarodnog simpozija agronoma*, (ur. Marić S., Lončarić Z.). Poljoprivredni fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku, Hrvatska, Dubrovnik, str. 47.

Stracenski Kalauz M., Ljubaj T., **Nedanov A.** (2013). Može li Hrvatska u kontekstu ovčarstva jugoistočne Europe profitirati štiteći prirodu-potencijali vune?, U: *Zbornik radova 48. hrvatski i 8. međunarodni simpozij agronoma*, (ur. Marić S. i Lončarić Z.), Poljoprivredni fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku, Hrvatska, Dubrovnik, str. 210-214.

Nedanov A., Ljubaj T., Zrakić M. (2013). Hrvatsko zadrugarstvo na primjeru poljoprivredne zadruge Sveti Križ Začretje, U: *Zbornik radova 48. hrvatskog & 8. međunarodnog simpozija agronoma*, (ur. Marić S. i Lončarić Z.), Poljoprivredni fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku, Hrvatska, Dubrovnik, str. 195-199.

Frick M., Sheehy J., **Nedanov A.** (2012). Economic Contribution Montana Cooperatives Make to the State Economy, Report, Montana State University (MSU), Division of Agricultural Education, USA, Montana, Bozeman, str. 1-15.

Stracenski Kalauz M., Tratnik M., **Nedanov A.**, Ljubaj T., Grilec Kaurić A. (2012). The Analysis of Jeans Purchase Factors and Consumption Choice Among Students Population of Zagreb University, U: *6th International Textile, Clothing & Design Conference: Magic World of Textiles: Book of Proceedings*, (ur. Dragčević Z., Hursa Šajatović A. i Vujasinović E.), University of Zagreb Faculty of Textile Technology, Hrvatska, Dubrovnik, str. 685-690.

Nedanov A., Franić R., Gugić J. (2012). Analiza zadružnog zakonodavstva Republike Hrvatske, U: *Zbornik radova 47. hrvatskog & 7. međunarodnog simpozija agronoma*, (ur. Pospišil M.), Sveučilište u Zagrebu Agronomski fakultet, Hrvatska, Opatija, str. 212-216.

Tratnik M., Stracenski Kalauz M., **Nedanov A.** (2011). Uloga zadružnog akademskog obrazovanja u pristupu EU-i, U: *Osposobljenost poljoprivrednika za ulazak u Europsku uniju: zbornik radova*, (ur. Erceg Z.). Zajednica ustanova za obrazovanje odraslih, Hrvatska, Opatija, str. 35-41.

Tratnik M., **Nedanov A.**, Stracenski Kalauz M., Radinović S. (2011). Hrvatski zadružni pokret - Pozadina i poveznice s europskim zadružnim pokretom, U: *Zbornik radova 46. hrvatskog & 6. međunarodnog simpozija agronoma*, (ur. Pospišil M.), Sveučilište u Zagrebu Agronomski fakultet, Hrvatska, Opatija, str. 337-340.

Tratnik M., Stracenski Kalauz M., **Nedanov A.** (2010). Personal Perception of the Most Important Conscious Restrained Factor of Young People for Apparel Purchase, U: *5th International Textile, Clothing & Design Conference: Magic World of Textiles: book of proceedings*, (ur. Dragčević Z., Hursa Šajatović A. i Vujasinović E.), University of Zagreb Faculty of Textile Technology, Hrvatska, Dubrovnik, str. 890-895.