

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU
POLJOPRIVREDNI FAKULTET U OSIJEKU

Davor Balaž, univ. spec. oec., dipl. ing.

**KONKURENTNOST HRVATSKE PROIZVODNJE I PRERADE
PŠENICE NA TRŽIŠTU EUROPSKE UNIJE**

DOKTORSKI RAD

Osijek, 2015.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU
POLJOPRIVREDNI FAKULTET U OSIJEKU

Davor Balaž, univ. spec. oec., dipl. ing.

**KONKURENTNOST HRVATSKE PROIZVODNJE I PRERADE
PŠENICE NA TRŽIŠTU EUROPSKE UNIJE**

- Doktorski rad -

Osijek, 2015.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU
POLJOPRIVREDNI FAKULTET U OSIJEKU

Davor Balaž, univ. spec. oec., dipl. ing.

**KONKURENTNOST HRVATSKE PROIZVODNJE I PRERADE
PŠENICE NA TRŽIŠTU EUROPSKE UNIJE**

- Doktorski rad -

Mentor: prof. dr. sc. Krunoslav Zmaić

Povjerenstvo za ocjenu:

- 1. dr. sc. Ružica Lončarić, izvanredna profesorica Poljoprivrednog fakulteta u Osijeku, predsjednica**
- 2. dr. sc. Krunoslav Zmaić, redoviti profesor Poljoprivrednog fakulteta u Osijeku, mentor i član**
- 3. dr. sc. Marko Jukić, izvanredni profesor Prehrambeno tehnološkog fakulteta u Osijeku, član**

Osijek, 2015.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
U OSIJEKU
POLJOPRIVREDNI FAKULTET U OSIJEKU

Davor Balaž, univ. spec. oec., dipl. ing.

**KONKURENTNOST HRVATSKE PROIZVODNJE I PRERADE
PŠENICE NA TRŽIŠTU EUROPSKE UNIJE**

- Doktorski rad -

Mentor: prof. dr. sc. Krunoslav Zmaić

**Javna obrana doktorskog rada održana je 10. srpnja 2015. godine pred
Povjerenstvom za obranu:**

- 1. dr. sc. Ružica Lončarić, izvanredna profesorica Poljoprivrednog fakulteta u Osijeku, predsjednica**
- 2. dr. sc. Krunoslav Zmaić, redoviti profesor Poljoprivrednog fakulteta u Osijeku, mentor i član**
- 3. dr. sc. Marko Jukić, izvanredni profesor Prehrambeno tehnološkog fakulteta u Osijeku, član**

Osijek, 2015.

Veliku zahvalnost dugujem svom mentoru prof. dr. sc. Krunoslavu Zmaiću na nesebičnoj pomoći i podršci bez čijeg stručnog vodstva ova disertacija ne bi ni nastala.

Velika hvala mojoj obitelji Nikolini, Sari i Renati koji su imali strpljenja za sva moja „djelovanja“ na izradi ovog doktorskog rada

Hvala mojoj mami Duši, tati Imri i bratu Damiru što su mi uvijek pružali podršku tijekom mojih školovanja.

Hvala svim stručnim dragim ljudima koji su pomogli prilikom prikupljanja podataka za izradu ovog rada; Antunu, Branku, Darku, Draganu, Domagoju, Ernestu, Ivanu, Ivici, Josipu, Lidiji, Mariju, Mirti, Milici, Mirjani, Nataliji, Nives, Renati, Ružici, Svjetlani, Tanji, Željku, Željku...

Hvala kolegama na Zavodu za agroekonomiju, Katedri za tehnologije prerade žitarica i kolegi iz Instituta za antropologiju što su pomogli u tehničkom dijelu pripreme ove disertacije.

Izdvajam nesebičnu podršku i pomoć djelatnica Poljoprivrednog fakulteta u Osijeku; Danice, Danijela i Ivanka hvala Vam puno.

Hvala Kraljevini Nizozemskoj, osoblju Veleposlanstva u Zagrebu, Odjela za poljoprivredu, jer su mi svojom nesebičnom pomoći omogućili pristup darovnici i realizaciju ovog doktorskog studija.

Bedankt voor het Koninkrijk der Nederland, het personeel van de ambassade in Zagreb, Ministerie van Landbouw, als wij Uw grote hulp toegang tot Grant en de realisatie van dit doctoraatswerk staat.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku

Doktorski rad

Poljoprivredni fakultet u Osijeku
Poslijediplomski doktorski studij: Poljoprivredne znanosti
Smjer: Agroekonomika

UDK: 631.15:633.11(497.5)EU
Znanstveno područje: Biotehničke znanosti
Znanstveno polje: Poljoprivreda
Grana: Agroekonomika

KONKURENTNOST HRVATSKE PROIZVODNJE I PRERADE PŠENICE NA TRŽIŠTU EUROPSKE UNIJE

Davor Balaž, univ.spec.oec., dipl. ing.

Rad je izrađen na Poljoprivrednom fakultetu Sveučilišta Josipa Jurja Strossmayera u Osijeku
Mentor: prof. dr. sc. Krunoslav Zmaić

Sažetak (do 2000 karaktera)

Broj stranica: 113

Broj slika: 5 grafikona, 4 slike

Broj tablica: 63

Broj literaturnih navoda: 69

Jezik izvornika: hrvatski

Analiza konkurentnosti je zahtjevan proces koji obuhvaća prikupljanje podataka i usporedbu na makro i mikro ekonomskoj osnovi. Za potrebe ovog rada obavljena je analiza prikupljanjem dostupnih podataka o proizvodnji i preradi pšenice u Republici Hrvatskoj i Europskoj Uniji (desk istraživanje), pet županija istočne Hrvatske (130 uzoraka proizvođača i 18 uzoraka prerađivača pšenice) i istraživanje ponude pšeničnog brašna na tržištu Republike Hrvatske. Na temelju prikupljenih podataka obavljena je analiza strukture uzoraka prema različitim varijablama, sukladno obavljenoj deskriptivnoj statističkoj analizi za varijable ordinalnog i kvantitativnog tipa (omjerne i intervalne). Analizom prikupljenih podataka obavljene su izračuni konkurentnosti primjenom metode troškovi domaćih resursa (DRC) te formiranjem analitičke matrice (PAM). Izračunom izdvojenog koeficijenta (DRC) nije potvrđena konkurentnost hrvatske proizvodnje pšenice za referentne godine, prema paritetnim domaćim cijenama. Za izdvojeni segment prerade pšenice, također primjenom navedene metode, utvrđen je neutralan status konkurentnosti prema DRC koeficijentu. Utvrđene su moguće potrebite prilagodbe standarda poslovanja, vanjske trgovine, vanjsko-trgovinske zaštite i domaće potpore u okviru Zajedničke poljoprivredne politike (ZPP). Obavljena je ocjena ekonomske učinkovitosti hrvatske proizvodnje i prerade pšenice u insceniranim uvjetima metodom izračuna koeficijenta DRC (održavanje proizvodnje na postojećoj razini; DRC proizvodnja 1,19 - ne konkurentnost, DRC prerada 1 - neutralni status, na razini smanjenja za 50% za oba proizvođačka faktora; DRC proizvodnja 2,39 - visoka ne konkurentnost, DRC prerada nepromijenjena - neutralna 1, minimiziranje mlinskog sektora uz održavanje proizvodnje pšenice na jednakoj razini; DRC proizvodnja 1,19 - nekonkurentnost, prerada DRC 0,45, što ukazuje na konkurentno poslovanje. Obavljeni izračuni pokazali su međusobnu disekonomsku međuovisnost proizvodnje i prerade pšenice u Republici Hrvatskoj, uz pozitivan utjecaj na stabilnost i održivost poslovanja u ruralnim područjima. Temeljem provedenog istraživanja utvrđeno je kako postoje uvjeti za kvantitativno i kvalitativno povećanje proizvodnje i prerade pšenice u Republici Hrvatskoj.

Ključne riječi: konkurentnost, pšenica, mlinska industrija, DRC, Republika Hrvatska, Europska unija

Datum obrane: 10. srpanj 2015.

Povjerenstvo za obranu:

1. dr. sc. Ružica Lončarić, izvanredna profesorica Poljoprivrednog fakulteta u Osijeku, predsjednica
2. dr. sc. Krunoslav Zmaić, redoviti profesor Poljoprivrednog fakulteta u Osijeku, mentor i član
3. dr. sc. Marko Jukić, izvanredni profesor Prehrambeno-tehnološkog fakulteta u Osijeku, član

Rad je pohranjen u:

Nacionalna i sveučilišna knjižnica u Zagrebu, Sveučilište Josipa Jurja Strossmayera u Osijeku, Sveučilište u Zagrebu, Sveučilište u Rijeci, Sveučilište u Splitu

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek

PhD thesis

Faculty of Agriculture in Osijek

Postgraduate study: Agricultural Sciences

Course: Agroecology

UDK: 631.15:633.11(497.5)EU

Scientific Area: Biotechnical Sciences

Scientific Field: Agriculture

Branch: Agroecology

COMPETITIVENESS OF CROATIAN PRODUCTION AND PROCESSING OF WHEAT ON THE EU MARKET

Davor Balaž, M. Sc.

Thesis performed at Faculty of Agriculture in Osijek, Josip Juraj Strossmayer University of Osijek

Supervisor: Prof. Dr. Krunoslav Zmaić

Short abstract (up to 2000 characters)

Number of pages: 113

Number of figures: 5 graphs, 4 figures

Number of tables: 63

Number of references: 69

Original in: Croatian

Analysis of competitiveness is a demanding process that includes data collection and comparison to the macro and micro economic basis. For the purposes of this study, an analysis of the available data on the production and processing of wheat in the Republic of Croatia and the European Union (desk research), 5th Region of eastern Croatia (130 samples of producers and processors of wheat 18 samples) and research offers wheat flour market Republic Croatia. Based on the collected data, an analysis of the structure of the samples according to different variables in accordance with the performed descriptive statistical analysis for ordinal variables and quantitative (the metering and interval). The data analysis were performed calculations using the cost competitiveness of domestic resources (DRC), and making analytical matrix (PAM). The calculation of separated coefficient (DRC), has not confirmed the competitiveness of Croatian wheat production for the reference year, the parity domestic prices. For the isolated segment of wheat also use of the method was determined neutral status of competitiveness to the DRC coefficient. Identified as possible the necessary adjustments to business standards, foreign trade, foreign trade protection and domestic support under the Common Agricultural Policy (CAP). Today was the evaluation of economic efficiency of the Croatian production and processing of wheat in a simulated conditions of the method of calculating the coefficient of the DRC; (maintenance of production at the current level; DRC production of 1.19 - not competitiveness, DRC processing 1 - neutral status, the level of reduction of 50% for both manufacturing factors; DRC production of 2.39 - not high competitiveness, DRC processing is not changed - neutral 1, minimizing the mill sector while maintaining the production of wheat on the same level; DRC production of 1.19 - not competitiveness, processing DRC 0.45 indicating a competitive business. Performed calculations showed mutual disekonomsku interdependence of production and processing of wheat in the Republic of Croatia, with a positive impact on the stability and sustainability of the business in rural areas. Based on the research it was found that the conditions for the quantitative and qualitative increase in the production and processing of wheat in the Republic of Croatia.

Key words: *competitiveness, wheat, milling industries, DRC, Croatia, European Union*

Date of the thesis defense: July 10th 2015.

Reviewers:

1. **Ph.D. Ružica Lončarić, Associate Professor, Faculty of Agriculture in Osijek, president**
2. **Ph.D. Krunoslav Zmaić, Full Professor, Faculty of Agriculture in Osijek, mentor**
3. **Ph.D. Marko Jukić, Associate Professor, Food Technology Faculty in Osijek, member**

Thesis deposited in: National and University Library, Josip Juraj Strossmayer University of Osijek, University of Zagreb, University of Rijeka, University of Split

KAZALO

1. UVOD	1
1.1. Pregled literature	4
1.2. Cilj istraživanja i hipoteze	11
2. MATERIJAL I METODE RADA	12
2.1. Desk istraživanje	12
2.1.1. Domestic resource cost (DRC) - troškovi domaćih resursa	12
2.1.2. Policy Analysis Matrix (PAM) - politička analiza matrice	14
2.2. Anketno istraživanje	15
2.2.1. Koncept i konstrukcija anketnog upitnika za mjerenje učinkovitosti proizvodnje i prerade pšenice	16
2.2.2. Metode statističke analize podataka primijenjene pri analizi anketnih Upitnika	18
2.3. Scenarij analiza	19
2.4. Statistička obrada podataka	20
3. REZULTATI	21
3.1. Analiza strukture poljoprivredne proizvodnje u Republici Hrvatskoj u odnosu na Europsku uniju	21
3.1.1. Komparacija proizvodnje pšenice u Republici Hrvatskoj i Europskoj uniji	23
3.1.2. Komparacija prerade pšenice u Republici Hrvatskoj i Europskoj Uniji	29
3.1.3. Analiza tržišta pšeničnog brašna u Republici Hrvatskoj	36
3.1.4. Analiza tržišta pšenice u Republici Hrvatskoj i Europskoj uniji	38
3.2. Terensko istraživanje segmenta proizvodnje pšenice	42
3.2.1. Analiza prikupljenih podataka o proizvodnji pšenice (demografska obilježja)	42
3.2.2. Deskriptivni pokazatelji proizvodnje pšenice	45
3.2.2.1. Deskriptivna statistika ordinalnih varijabli tematskih područja stavova o proizvodnji pšenice	45
3.2.2.2. Deskriptivna statistika kvantitativnih varijabli prikupljenih podataka o proizvodnji pšenice	49
3.2.2.3. Analiza glavnih komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice - Makroekonomske Tvrdnje	52
3.2.2.4. Analiza glavnih komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice - Tehničko-tehnološke tvrdnje	53
3.2.2.5. Analiza glavnih komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice – Tržišne tvrdnje	54
3.2.2.6. Analiza glavnih komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice – Konceptijske tvrdnje i međunarodno okruženje	55
3.2.3. Razlike između županija u područjima stavova o proizvodnji pšenice	56
3.2.4. Povezanost između područja stavova o proizvodnji pšenice	58
3.2.5. Razlike između županija u varijablama vezanim uz proizvodnju Pšenice	59

3.2.6. Razlike između OPG-a i obrta u područjima stavova o proizvodnji pšenice	61
3.3. Terensko istraživanje segmenta prerada pšenice	62
3.3.1. Deskriptivni pokazatelji prerade pšenice	63
3.3.1.1. Deskriptivna obilježja za skupine ordinalnih varijabli po pojedinim tematskim područjima stavova o preradi pšenice	63
3.3.1.2. Deskriptivna obilježja za skupinu kvantitativnih varijabli prerade pšenice	69
3.4. Modeli izračuna konkurentnosti	73
3.4.1. Troškovi domaćih resursa – proizvodnja pšenice	73
3.4.2. Troškovi domaćih resursa – prerada pšenice	77
3.4.3. Usporedba različitih scenarija	79
3.4.3.1. Optimistični scenarij	79
3.4.3.2. Pesimistični scenarij	80
3.4.3.3. Analiza scenarija	86
4. RASPRAVA	87
4.1. Zajednička poljoprivredna politika Europske unije, utjecaj na proizvodnju i preradu pšenice u Republici Hrvatskoj	87
4.2. Konkurentnost hrvatske proizvodnje i prerade pšenice u međunarodnim okvirima	90
5. ZAKLJUČCI	93
6. LITERATURA	98
7. SAŽETAK	104
8. SUMMARY	107
9. PRILOG	110
ŽIVOTOPIS	112

1. UVOD

Hrvatska poljoprivreda nalazi se na prekretnici i prilagodbi na složeni sustav Zajedničke poljoprivredne politike (CAP), koji potencira jačanje konkurentnosti poljoprivredne proizvodnje uz osiguranje prehrambene sigurnosti zemalja članica. Naime, CAP ima središnje mjesto u europskoj konstrukciji i njezin se značaj potvrđuje na institucionalnom, pravnom i budžetskom planu. Zahvaljujući racionalnom iskorištavanju proizvodnih potencijala poljoprivrednih gospodarstava i koncentraciji sredstava za proizvodnju, zemlje razvijenog kapitalističkog sustava postale su glavni svjetski proizvođači i izvoznici poljoprivredno-prehrambenih proizvoda. Prilagođavanje CAP-u novim realnostima i izazovima u pogledu promjene potrošačke potražnje i preferencija, međunarodnog trgovinskog rasta, kao i proširenje Europske Unije, označeno je preorijentacijom s cjenovne potpore na potporu baziranu izravnim plaćanjima. Uspostavljanje i zadovoljavanje takvih opredjeljenja podrazumijeva restrukturiranje agrara i stvaranje novoga koncepta, koji se ogleda kroz modalitet proizvodne funkcije koja ima za cilj suočavanje s konkurencijom svjetskog tržišta.

Razvoj poljoprivrede u Europskoj Unije nije određen jednoznačno, s obzirom kako države članice kreiraju strategije razvoja gospodarskog napretka kroz unapređenje proizvodnje, prerade i njihove konkurentnosti kao osnovne odrednice tržišne ekonomije. Povećanje konkurentnosti i prilagodbe na izazove globalnih promjena je dugoročni cilj koji se odražava na europsku i hrvatsku poljoprivrednu proizvodnju i industrijsku preradu. Paradoksi hrvatske poljoprivrede, koji se ogledaju u agrarnoj prezaposlenosti i demografskoj ispražnjenosti, uz brojna, ali usitnjena naturalna i neproizvodna poljoprivredna gospodarstva, znatno su pridonijela povećanju nesrazmjera u odnosu na razvijene zapadno-europske zemlje.

Republika Hrvatska deklarirala se za model otvorenog tržišnog gospodarstva i uključivanje u europske integracijske procese. Na taj način u Republici Hrvatskoj započeti su procesi privatizacije vlasništva, uvođenje tržišnog, pravnog i institucionalnog sustava, zaoštavanje financijske discipline, liberalizacije trgovine i tržišne makro-ekonomske politike. S obzirom na malo unutarnje tržište i gubitak tradicionalnih tržišta zemalja CEFTE, gospodarski se razvoj Republike Hrvatske ogleda u izveznoj orijentaciji u kojoj poljoprivreda preko svojih primarnih i sekundarnih proizvoda ima značajnu ulogu.

Proizvodnja žitarica predstavlja osnovu cjelokupne poljoprivredne djelatnosti, s obzirom na to da neposredno osigurava hranu za stanovništvo, kao i hranu neophodnu za životinjsku proizvodnju. Na taj način opseg i struktura žitarica utječe na opseg i strukturu stočarske proizvodnje. Proizvodnju žitarica karakterizira, s obzirom na vremensku dimenziju, proizvodnja sezonskog karaktera te se ona ubraja u ekstraktivne djelatnosti. Ujedno predstavljaju i komplementarne proizvode i uvjet su propulzivnih djelatnosti te djeluju multiplikacijski na brojne komplementarne proizvodnje. Komplementarnost žitarica ogleda se u potpunijem zadovoljavanju potreba potrošača i povećanja cjelokupnog dohotka, što u krajnjoj liniji djeluje na usklađivanje i operacionalizaciju proizvoda od žitarica na pravcu proizvodnje, prerade, finalizacije, distribucije i potrošnje.

U poljoprivrednom sektoru i sektoru prehrambene industrije, konkurentnost se može mjeriti makroekonomskim pokazateljima uspješnosti nacionalnog gospodarstva s naglaskom na izdvojene sektore. Osnovni makroekonomski indikatori hrvatske poljoprivrede ukazuju na pad bruto dodane vrijednosti za 3,1%, pad ukupnog broja zaposlenih u poljoprivredi za 3,5% te rast uvoza od 2,1% u 2013. godini, u odnosu na 2011. godinu (*Ministarstvo poljoprivrede, 2013.*)

Najveći udio u ukupnoj poljoprivrednoj biljnoj proizvodnji ima proizvodnja žitarica, koje su u razdoblju 2008.–2012. godine bile zastupljene s 559.916 ha, a proizvodilo se prosječno 3.137.702 tone. U strukturi proizvodnje žitarica ima kukuruz s 62,4%, pšenica 27,1%, ječam 7,2%, zob 2,2%, pšeno raž 0,9% te raž i ostale žitarice s 0,1%. U Republici Hrvatskoj je u 2013. godini požnjeveno pšenice na 186.949 ha te je proizvedeno 999.681 t, s prinosom od 5,3 t ha⁻¹ (*Ministarstvo poljoprivrede, 2013.*). Na taj je način kroz promatrano razdoblje proizvodnja pšenice porasla za 28%, te su godišnja potrošnja i potrebe za pšenicom u Republici Hrvatskoj na razini od 550.000 do 600.000 t, što ukazuje na samodostatnost i suficit od 50.000 t.

Relativno nizak prinos pšenice u Republici Hrvatskoj, u odnosu na zemlje Europske unije, leži u nepovoljnoj posjedovnoj strukturi, bilo da je riječ o usporedbi korisnika komercijalnih potpora ili onih koji navedene potpore ne koriste. To ukazuje na još uvijek veliku usitnjenost poljoprivrednih površina, pri čemu je prosjek obradivih površina oko 5,6 ha, uz prisutnu veliku isparceliranost od pet parcela po poljoprivrednom gospodarstvu (*Ministarstvo poljoprivrede, 2013.*). Uz nepovoljnu posjedovnu strukturu, razlozi negativnih trendova proizvodnje i prerade pšenice mogu se sagledati kroz:

- opće makroekonomske probleme povezane s prilagođavanjem gospodarstva novim tržišnim uvjetima,
- nedostatan volumen potražnje i proizvodnja neprilagođena novim zahtjevima potrošača,
- privatizaciju mlinskih industrijskih postrojenja i usvajanje smjernica tržišnog poslovanja,
- nepovoljna socio-ekonomska, demografska i gospodarska kretanja,
- probleme prilagodbe proizvođača i prerađivača novim tržišnim zahtjevima, fokusiranim na visoku kvalitetu konačnih proizvoda.

Uspješnost proizvodnje i prerade pšenice rezultat je istodobnog djelovanja velikog broja činitelja koji u određenom vremenu i na određenom prostoru djeluju s različitim intenzitetom i u različitim međusobnim odnosima. Raspoloživi pokazatelji ukazuju kako je mogućnost hrvatske poljoprivrede po pitanju proizvodnje i prerade pšenice ostvarivanje znatno veće izvozne ekspanzije. Svi navedeni negativni činitelji utječu na pad proizvodnje i smanjenje izvozne ekspanzije i mogu se svesti na zajednički nazivnik, a to je nedovoljna konkurentnost u odnosu na zemlje Europske unije i zemlje u okruženju.

Naime, u registru mlinara, uvoznika i proizvođača brašna, namjenskih smjesa i koncentrata upisano je 193 mlinara, 11 proizvođača namjenskih smjesa i koncentrata, 47 uvoznika brašna, 35 uvoznika namjenskih smjesa i koncentrata te 7 pravnih subjekata koji se bave prepakiranjem brašna. Prema evidencijama Ministarstva poljoprivrede 10 najvećih mlinara proizvede 70% domaćeg brašna. Republika Hrvatska posjeduje mlinsku industriju koja je najvećim dijelom izgrađena korištenjem dostupnih tehnologija u ex Jugoslaviji (*FAO, 2009.*) Mnogobrojna istraživanja pokazala su kako je utjecaj kultivara jedan od bitnih čimbenika kvalitete brašna. Poznato je kako mlinska kvaliteta brašna ovisi 70–80% o kvaliteti kultivara pšenice (*Ugarčić-Hardi Ž., 2002.*)

Mlinsku industriju karakterizira zastarjela tehnologija i nedovoljno korištenje kapaciteta mlinova koji su za 30% veći od stvarnih potreba. Ulaskom u EU, hrvatska mlinska industrija treba odgovoriti na zahtjeve navedenog tržišta eventualnim uvođenjem novih tehnologija za proizvodnju hidro-termički obrađenog brašna, brzo kuhajuće prekrupe, uz poboljšanje kvalitete već postojećih proizvoda, što će uvjetovati daljnje profiliranje određenog broja mlinara koji će uvođenjem novih tehnologija proizvoditi jeftinije brašno s proširenim proizvodnim programom.

1.1. Pregled literature

Temeljem utvrđenog činjeničnog stanja uočeno je kako se problem konkurentnosti u proizvodnji i preradi pšenice nije analizirao s znanstvenog aspekta, a dostupna novija literatura skromno opisuje navedenu problematiku. Podaci o ekonomskim učincima na proizvođače i prerađivače pšenice tranzicijskih zemalja koje su pristupile Europskoj uniji vrlo su šturi, nekompletni, čak i proturječni. Tijekom dosadašnjih istraživanja otvorila su se neka vrlo važna pitanja i nedoumice oko opstanka domaće mlinske prerade i smjera proizvodnje pšenice na tržištu Europske unije.

Franić i Žimbrek (2003.) otkrivaju osnovna ograničenja u postizanju višeg stupnja konkurentnosti hrvatske poljoprivrede: monopolski položaj nabavljača inputa, slab pristup komercijalnim kreditima, isplate u naravi, nerazvijena tržišna i institucijsku infrastrukturu, nedostatak ekonomije opsega u marketingu, malu prosječnu veličinu gospodarstva, teškoće u kupnji i najmu zemljišta, niske prinose, nisku tehnološku razinu i netransparentan subvencijski sustav u kojemu agrarno-političke mjere često prikrivaju tržišne signale.

Bojnec (2003.) istražio je pregled mjera koje se primjenjuju u mjerenju konkurentnosti izdvojene grane poljoprivredne proizvodnje (stočarstvo) u zemljama srednje i istočne Europe. U istraživanju su primijenjena tri koncepta izračuna konkurentnosti: Porterov model dijamanta, analiza dostupnih statističkih podataka i politička analiza matrice (PAM). Rezultati istraživanja ukazuju kako su poboljšanja nužna i primjenjiva na području restrukturiranja, kvalitete, tehnologije, poboljšanja učinkovitost i racionalizacije troškova u stočarstvu srednje i istočne Europe.

Franić i Kumrić (2006.) analizirali su konkurentnost hrvatskog sektora proizvodnje šećera, gdje su utvrdili kako je osnovni problem sektora proizvodnje šećera u Republici Hrvatskoj održavanje niskih troškova proizvodnje i zadržavanje proizvodnje šećerne repe na visokoj razini u odnosu na kvalitetu i ukupne zasijane površine.

Karácsony (2008.) zaključuje kako je u cilju poboljšanja konkurentnosti proizvodnje pšenice u Mađarskoj potrebno kvalitetnije upravljati rizicima, odnosno potporama stvoriti programe kvalitetne proizvodnje pšenice, uz obnovu postojeće zastarjele tehnologije i mehanizacije te time smanjiti ukupne troškove proizvodnje.

Kalanj i Križman-Pavlović (2008.) naveli su kako poduzeće ima konkurentsku prednost ukoliko konačnim kupcima isporučuje veću vrijednost od industrijskih suparnika. Konkurentska prednost postoji ako su ispunjena tri sljedeća uvjeta:

1. kupci opažaju konstantnu razliku u važnim obilježjima između proizvoda/usluge poduzeća i proizvoda/usluge konkurenata;
2. razlika u važnim obilježjima između proizvoda/usluge poduzeća i proizvoda/usluge konkurenata izravna je posljedica nesklada sposobnosti između poduzeća i njegovih suparnika,
3. razlika u važnim obilježjima između proizvoda/usluge poduzeća i proizvoda/usluge konkurenata te sklad sposobnosti između poduzeća i njegovih suparnika mogu se očekivati i u budućnosti.

Atkin (2009.) analizira konkurentnost proizvodnje pšenice u istočnoj Europi. Rezultatima istraživanja usporedio je Rumunjsku i Rusku proizvodnju pšenice s Velikom Britanijom i konstatirao kako je ista visoka s obzirom na povoljne agroekološke uvjete, nisku razinu proizvodne cijene i energije u analiziranim zemljama.

Batalha i sur. (2009.) istražili su konkurentnost najvećih proizvođača pšenice u južnoj Americi (Argentina, Brazil i Urugvaj), gdje su osnovne komponente za analizu konkurentnosti bile troškovi proizvodnje, trgovinske barijere, porezni sustav i institucionalni činitelji. Rezultati istraživanja pokazali su kako Brazil i Urugvaj imaju veće troškove i lošije institucionalne uvjete, što rezultira u konačnici nepovoljnim omjerom između proizvodnje i domaće potrošnje. Argentina ima vrlo niske troškove proizvodnje i višak proizvodnje pšenice, koji se uglavnom izvozi.

Tijanić (2010.) naveo je kako se regionalna konkurentnost pojedine regije ili industrijske grane istražuje primjenom modela višestruke linearne regresije. Rezultati upućuju na pozitivan i značajan utjecaj odabranih determinanti te su prema dobivenom modelu hrvatske regije u konačnici istraživanja rangirane. Najkonkurentnija je hrvatska regija sjeverozapadna Hrvatska, a za njom slijede jadranska Hrvatska pa središnja i istočna (panonska) Hrvatska.

Bezić i sur. (2011.) istaknuli su kako je važan segment u utvrđivanju makroekonomskih čimbenika RH utvrđivanje pozicije i otkrivene konkurentske prednosti hrvatske prerađivačke industrije u vanjskotrgovinskoj razmjeni. Metodologija istraživanja zasniva se na primjeni skupine pokazatelja vanjskotrgovinske otvorenosti i otkrivenih

konkurentskih prednosti, kao i cjelokupnoj analizi strukture prerađivačke industrije Republike Hrvatske. Za potrebe analize izražene konkurentne prednosti prerađivačke industrije Republike Hrvatske koristile su se kvantitativne metode; Indeks izražene komparativne prednosti (RCA), kao metoda otkrivanja komparativnih prednosti u izvozu robe pojedinih zemalja, Indeks izvozne konkurentnosti (XC), kao metoda mjerenja izvozne konkurentnosti promatranih zemalja, Indeks izvozne specijalizacije (ES), kao metoda usporedbe izvozne aktivnosti prerađivačke industrije Republike Hrvatske i Europske unije te Indeks relativne trgovinske prednosti (RTA), koji objedinjuje RCA i RMA indekse.

Tuna i sur (2013.) istražili su konkurentnost proizvodnje duhana u Republici Makedoniji. To je industrijska biljka s preko 70% udjela na ukupnom broju površina pod industrijskim i s prosječnim udjelom od oko 30% u ukupnom izvozu poljoprivrednih proizvoda. Kao zahtjevna biljka, osigurava posao ruralnoj populaciji i daje socijalnu zaštitu ekonomiji i trenutnoj visokoj stopi nezaposlenosti u zemlji. Cilj ovog istraživanja bio je istražiti konkurentnost duhanskog sektora u zemlji analizom konkurentnosti pomoću Porter Diamondovog modela, nadopunjenog Ballasa indeksom komparativnih prednosti. Na temelju prevladavajućih pozitivnih aspekata u modelu konkurentnosti visoke vrijednosti indeksa su u rasponu od sedam do preko devet za razdoblje 2005.-2010., što predstavlja puno više, ako se uspoređi s nekim zemljama u regiji (Grčka, Bugarska, Turska). Navedeno istraživanje je svojim rezultatima istaknulo povoljne uvjete i kompetitivne prednosti za proizvodnju duhana u Republici Makedoniji.

Baban (1994.) analizirao je s gospodarskog stajališta prilagodbu hrvatskog poljodjelstva europskim integracijama, sa stanovišta prilagodbe naših poljodjelskih i prehrambenih proizvoda tržišnim zahtjevima europskih integracija. Prilagodba konkurentnosti očituje se kroz prilagodbu cijenama, formiranje prepoznatljive marke proizvoda, ambalaže, dizajna i drugo. Premijski sustav mora se prilagoditi kako bi se prevladale protekcionističke mjere zemalja uvoznica naših proizvoda, povećanjem standarda kvalitete i označavanja samih proizvoda, uz ocjenu harmonizacije našeg kompletnog sustava, s naglaskom na poreze kako bi se omogućile strane direktne investicije u poljodjelstvo i prehrambenu industriju.

Zmaić (2003.) istaknuo je kako istraživanje opsega i trenda kretanja vanjskotrgovinske razmjene poljoprivrednih proizvoda u RH, zajedno s dostignutom razinom gospodarskog razvitka, ukazuje na postojanje korelacijske veze između stupnja otvorenosti i dinamike gospodarskog rasta.

Petrač i sur. (2005.) konstatirali su kako u Republici Hrvatskoj žitarice čine više od dvije trećine ukupno zasijanih površina. Kukuruz je dominantna žitarica i pokriva 56%, a pšenica 33% od ukupne površine zasijane žitaricama, a proizvodi se uglavnom na obiteljskim poljoprivrednim gospodarstvima. Analize graničnog prinosa žitarica u Republici Hrvatskoj tijekom dužeg vremenskog razdoblja potvrđuju kako promjene u prinosu nisu ujednačene, odnosno osciliraju oko prosječnog prinosa i trenda razvoja. To, kao i činjenica da od žitarica prinosi u Republici Hrvatskoj nisu uvijek zadovoljavajući u usporedbi s rezultatima postignutim u Europskoj uniji, ukazuje na nedovoljnu iskorištenost genetskog potencijala žitarica.

Zmaić i sur (2006.) prikazali su strateške mogućnosti za razvoj hrvatske poljoprivrede u tranzicijskoj ekonomiji, u odnosu na tržišna kretanja u svjetskoj i europskoj trgovini. Istraživanjem su prikazane potencijalne mogućnosti za hrvatsku poljoprivredu, koja za uspješan makroekonomski razvoj mora generirati trgovinski suficit, a da bi se to postiglo poljoprivreda u Hrvatskoj mora prevladati brojne konkurentne nedostatke. Također konstatiraju da će prevladavanjem konkurentne neučinkovitosti Hrvatska biti u mogućnosti postići veći prodor na europsko i svjetsko tržište poljoprivredno-prehrambenih proizvoda.

Blagojević i sur. (2008.) naveli su kako se Republika Hrvatske deklarirala za model otvorenog tržišnog gospodarstva i uključenja u europski integracijski proces koji se odvija kroz privatizaciju vlasništva, uvođenje tržišnog pravnog i institucionalnog sustava, zaoštavanje financijske discipline, liberalizaciju trgovine i tržišnu makroekonomsku politiku. Kvantitativnom analizom i primjenom metode mjerenja indeksa poljoprivredne razmjene između uvoza, izvoza i bruto domaćeg proizvoda utvrđena je uvozna ovisnost, izvozna propulzivnost i stupanj otvorenosti. Analizom je utvrđen pad uvozne ovisnosti sa 4,4% na 3,2%, uz istodoban pad izvozne propulzivnosti i stupnja otvorenosti. Zaustavljanje ovakvih trendova treba tražiti u daljnjoj proizvodnoj strukturi i tehnološkom restrukturiranju uz istodobno zadržavanje visoke kvalitete i prihvatljivih cijena poljoprivrednih proizvoda.

Franić (2009.) navodi kako zbog fiksnog karaktera inputa u poljoprivredi, posebno zemljišta i djelomično rada, kao i zbog obilježja navedene proizvodnje, proizvođači pšenice uglavnom nisu u stanju adekvatno reagirati na promjene cijena poljoprivrednih proizvoda i inputa. Uz navedeno, treba istaknuti i ograničenje koje je vezano za

neelastičnost ponude i neelastičnost potražnje za pšenicom, što uvjetuje visoku fluktuaciju cijena i fluktuaciju poljoprivrednog dohotka.

Bilić (2009.) istaknuo je kako Republika Hrvatska vlastitom proizvodnjom ne podmiruje potrebe i ima skupu hranu - izdaci po stanovniku dvostruko su veći nego u EU. Hrvatska je poljoprivreda prije stotinjak godina bila sličnija zapadnoeuropskoj nego danas, jer je Europa zadnjih 50 godina zajednički rješavala probleme programiranjem i zaštitom proizvodnje, potporom proizvođača i uređenjem tržišta poljoprivrednih proizvoda, a Republika Hrvatska je išla gotovo suprotnim putem. Jaz se ogleda u veličini posjeda, vlasničkoj strukturi, prinosima i konkurentnosti, što se vidi i u sposobnosti rješavanja viška poljoprivrednog stanovništva uz zadržavanje naseljenosti seoskih područja.

Gelo i Gelo (2008.) istražili su otvaranje hrvatskog tržišta hrane s pratećim reformama uz prisutnost rasta proračunskih izdvajanja s ciljem unapređenja poljoprivredne proizvodnje i očuvanja ruralne sredine. Zaključili su kako je konkurentnost hrvatske poljoprivrede ključna za uspješno integriranje u poljoprivredu EU, odnosno dostizanje visine razina potpora zemalja članica iz okruženja.

Obadić (2009.) analizirala je izvozu propulzivnost poljoprivrednih proizvoda. U razdoblju 1966./1968. - 2002./2003. povećane su vrijednosti izvoza za 8, a uvoza za 22 puta, uz prosječne godišnje stope za izvoz 6,5% i uvoz 10,4%. Izvoz i uvoz poljoprivrednih proizvoda RH zaostaje za prosjekom Europske Unije, pri čemu više zaostaje izvoz nego uvoz.

Balaž i sur. (2011.) analizirali su utjecaj različitih elemenata mikro i makro marketing okruženja na razvoj prehrambene industrije u Hrvatskoj. Terenskim istraživanjem, koje je obuhvatilo 58 proizvođača hrane, ukazuju na nedostatke makro marketing okruženja, odnosno političko, pravno, ekonomsko i društveno okruženje koje je ocijenjeno ispod prosjeka, što odgovara zatečenom stanju krize kroz četiri segmenta. Međutim, tehnološko okruženje percipirano je s najmanje nedostataka, jer su tvrtke svjesne da kroz tehnološka poboljšanja mogu podići razinu konkurentskih snaga na međunarodnom i lokalno liberaliziranom tržištu hrane.

Par (2001.) analizira proizvodnju na obiteljskim poljoprivrednim gospodarstvima, s ciljem ustanovljenja metodologija praćenja ekonomske uspješnosti obiteljskih poljoprivrednih gospodarstava u različitim uvjetima proizvodnje povrća, voća i grožđa, primjenom DRC metode.

Ruiz (2003.) analizirala je utjecaj Frankovog autokratskog režima na španjolski industrijski sektor primjenom metode Troškova domaćih resursa - Domestic Resource Cost (DRC), tijekom 1958. godine.

Liebl i Postma (2005.) obavili su istraživanje na području primjene Scenarij analize kao metode za unapređivanje strateškog upravljanja na izdvojenom industrijskom sektoru. Poseban naglasak stavljen je na pronalaženje rješenja za neizvjesnosti prilikom upravljanja i uklanjanju nedostatka konvencionalnih metoda scenarija, ukazivanjem na moguće putove za metodološkim prilagodbama.

Čačić i sur. (2007.) istražili su konkurentnost proizvodnje jagoda komparirajući proizvodnju u Republici Hrvatskoj s proizvodnjom u Njemačkoj s obzirom na vremensko razdoblje proizvodnje. Obavili su izračun troškova domaćih resursa (DRC) formiranjem analitičke matrice (PAM). Dobiveni rezultati ukazuju na konkurentnu proizvodnju izdvojenog segmenta proizvodnje jagoda u RH u razdoblju od dvije godine. Usporedbom s proizvodnjom jagoda u Njemačkoj, koja se obavlja u jednogodišnjem ciklusu, utvrđeno je kako proizvodnja može postati konkurentnija skraćivanjem vremenskog razdoblja za jednu godinu.

Dhebibi i Frija (2009.) istražili su proizvodnju i izvoz maslinovog ulja, naranči i rajčica proizvedenih u Tunisu, primjenom DRC metode. Dobivenim rezultatima utvrđeno je kako je proizvodnja maslinovog ulja u Tunisu konkurentna, iako je rezultat na višegodišnjoj razini promjenjiv, uslijed različitih visina prinosa analizirane kulture. Međutim, iako za izdvojene sektore proizvodnje limuna i rajčice nije utvrđena pozitivna konkurentnost, prisutan je trend povećanja prinosa i primjene suvremenih agrotehničkih mjera, koje bi u budućnosti mogli utjecati na pozitivnu izvoznu konkurentnost navedenih kultura.

Iskili i Yercan (2009.) obavili istraživanja konkurentnosti grane poljoprivredne proizvodnje (hortikulture) na primjeru Turske, prema zemljama u regiji. Obavljena komparacija temeljem izračuna troškova domaćih resursa (DRC) prikazom omjera između oportunitetnih troškova domaće proizvodnje i dobivene dodane vrijednosti, čiji rezultati ukazuju na postojeću konkurentnost Turske proizvodnje hortikultura u odnosu prema zemljama regije.

Koo i sur. (2001.) navode da je analiza troškova uvoza i potražnje za pšenicom u mlinskoj industriji Japana diferencirana po klasama i zemlji podrijetla pšenice. Rezultati pokazuju da se pšenica proizvedena u Sjedinjenim Američkim Državama suočava sa snažnom konkurencijom na japanskom tržištu pšenice, ali da američka pšenica drži primat u tržišnom udjelu s obzirom na visoku kvalitetu i dobre rezultate krajnje uporabe.

Buturac (2008.) istražio je položaj hrvatske prerađivačke industrije u međunarodnoj razmjeni. Primjena pokazatelje disperzije i koncentracije, komparativnih prednosti, specijalizacije u intra-industrijskoj razmjeni, horizontalne i vertikalne specijalizacije i izvozne konkurentnosti. Dobivenim rezultatima zaključio je kako najveći broj sektora prerađivačke industrije u Hrvatskoj nema izražene komparativne prednosti u međunarodnoj razmjeni.

Rašić-Bakarić i Vizek (2010.) obavili su analizu strukturnih obilježja i dinamike proizvodne aktivnosti i proizvodnih činitelja u prerađivačkoj industriji Republike Hrvatske u razdoblju od 1997.-2007. godine. Analizirana je prerađivačka industrija u cjelini, s tehnološkim razinama i pojedinim odjeljcima prerađivačke industrije. Istražili su stanje tehnološke intenzivnosti proizvodnje i povezanost konkurentnog položaja prerađivačke industrije Republike Hrvatske. Rezultati analize ukazali su kako struktura prerađivačke industrije Republike Hrvatske nazaduje i sve više zaostaje, te gubi konkurentnost za europskom prerađivačkom industrijom.

1.2. Cilj istraživanja i hipoteze

U Republici Hrvatskoj po našim saznanjima, nije se detaljnije istraživala konkurentnost hrvatske proizvodnje i prerade pšenice s osvrtom na tržište Europske unije, te su postavljeni opći ciljevi:

- analizirati i ocijeniti međunarodnu konkurentnost hrvatske proizvodnje i prerade pšenice,
- utvrditi mjere prilagodbe standarda poslovanja poljoprivrednih gospodarstava i vanjske trgovine u okviru CAP-a,
- ocijeniti ekonomske učinke i konkurentnost u proizvodnji i preradi pšenice.

Opći cilj koji se odnosi na ocjenu ekonomske učinkovitosti i konkurentnost proizvodnje i prerade pšenice će biti kreirani kroz tri scenarija:

- 1) održavanje proizvodnje na postojećoj razini,
- 2) smanjenje razine proizvodnje i prerade pšenice za 50%,
- 3) minimiziranje prerade, uz održavanje proizvodnje pšenice na jednakoj razini.

Uz postavljene opće ciljeve istraživanja proizlaze i osnovne hipoteze:

1. područje Republike Hrvatske ima prirodne i društvene uvjete za veću proizvodnju pšenice koja je nedovoljno iskorištena, s obzirom da između proizvodnje i prerade postoji tehnološka povezanost, ali je ekonomska povezanost nezadovoljavajuća pa zbog toga nastaje disekonomija, koja se nepovoljno odražava na cjelokupni razvitak sektora,
2. zadržavanje postojeće proizvodnje pšenice osigurava zapošljavanje i gospodarsku stabilnost u ruralnom području,
3. domaća proizvodnja i prerada pšenice je konkurentna i ravnopravna na tržištu Europske Unije,
4. hrvatska proizvodnja i prerada pšenice može kvantitativno i kvalitativno povećati udio u međunarodnoj razmjeni.

2. MATERIJAL I METODE RADA

2.1. Desk istraživanje

U prvom dijelu rada, primjenom desk istraživanja, odnosno prikupljanjem dostupnih sekundarnih podataka, utvrđeno je stvarno stanje, resursi, kapaciteti, tehnološka opremljenost, tržišna kretanja hrvatske pšenice i njenih prerađevina. Podaci su prikupljeni uz korištenje sljedećih izvora: Državni zavod za statistiku, Ministarstvo poljoprivrede, Hrvatska gospodarska komora, Internet i ostali dostupni podaci.

Navedenom metodom prikupljeni su stari i novi podaci o proizvodnji i preradi pšenice, kako bi se jasnije mogli razumjeti trendovi i mogućnosti integralnog prestrukturiranja proizvodnje i prerade pšenice, u cilju dobivanja informacija i davanja smjernica u većem sudjelovanju proizvođača i prerađivača pšenice u međunarodnoj razmjeni.

Temeljem prikupljenih podataka obavljena je analiza s ciljem utvrđivanja neophodnih varijabli za izračun razine konkurentnosti primjenom metoda Domestic Resource Cost (DRC) - troškovi domaćih resursa i Policy Analysis Matrix (PAM) - politička analiza matrice.

2.1.1. Domestic Resource Cost (DRC) - troškovi domaćih resursa

Kako bi se analizirala konkurentnost hrvatske proizvodnje i prerade pšenice, koja daje okvir za vrednovanje profitabilnosti proizvodnje široke potrošnje po različitim cijenama, tečajevima i tehničkim koeficijentima, koristit će se jedna od najčešćih računovodstvenih metoda, a odnosi se na procjenu omjera troškova domaćih resursa (DRC).

Metodologija za izračunavanje DRC-a podrazumijeva brojne pretpostavke, a detaljnu analizu problema i rezultata predstavili su *Davidova i Gorton (2001.)*. DRC metoda mjeri konkurentnost na međunarodnom tržištu uspoređujući troškove domaćih resursa korištenih u proizvodnji dobara s dobivenom dodatnom vrijednosti tih dobara, a dodana vrijednost trebala bi biti veća od troškova korištenih resursa.

Naime, omjer troškova domaćih izvora uspoređuje oportunitetne troškove domaće proizvodnje i nabavne cijene koja se postiže u proizvodnji i preradi pšenice. DRC razlikuje razmjenjive inpute (tradable inputs), odnosno koji se mogu izvoziti ili uvoziti i nerazmjenjive inpute (non-tradable inputs), odnosno one koji nisu predmet međunarodne trgovine.

DRC koeficijentom izračunava se odnos društvenih troškova proizvodnih čimbenika i neto vrijednosti međunarodne razmjene zarađene ili uštedene zbog domaće proizvodnje dobara, to je odnos mogućnosti zarada prema stvarnim zaradama sektora i kao takav može se smatrati pokazateljem komparativnih (poredbenih) prednosti (*Franić (2008.)*).

$$DRC_i = \frac{\sum_{j=k+1}^n a_{ij} P_j^D}{P_i^B - \sum_{j=1}^k a_{ij} P_j^B}$$

Brojnik predstavljaju troškovi korištenja domaćih primarnih resursa (zemljište, radna snaga i kapital) po jedinici outputa čija se cijena određuje graničnim cijenama, odnosno vrijednosti koju mogu dobiti u sljedećoj najboljoj uporabi. Nazivnik predstavlja razliku između nabavne i prodajne cijene po jedinici outputa u graničnim cijenama koje su podešene prema razini poljoprivrednih gospodarstava.

DRC koeficijent kao pokazatelj komparativnih prednosti, prema istraživanju *Khachatryan (2002.)*, može biti:

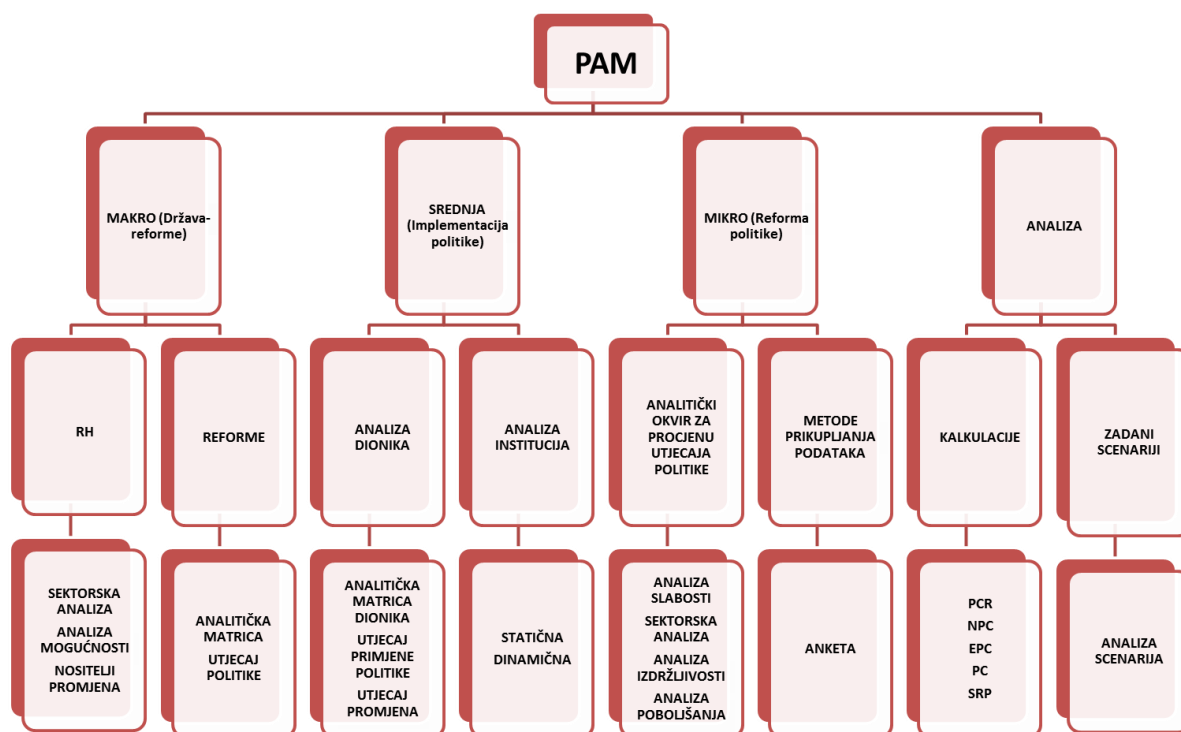
- neutralan, $DRC=1$, što znači da su stvarni troškovi jednaki dodanoj vrijednosti,
- konkurentan, $0 < DRC < 1$, što znači da su stvarni troškovi manji od dodane vrijednosti,
- nekonkurentan, $DRC > 1$, što znači da su stvarni troškovi veći od dodane vrijednosti.

Ujedno, DRC metoda predstavlja osnovnu podlogu za formiranje političke analize matrice (PAM).

2.1.2. Policy Analysis Matrix (PAM) - politička analiza matrice

Uz izračun troškova domaćih resursa, koristit će se i metode PAM (Policy Analysis Matrix), odnosno politika analize matrice, kako bi se ocijenila učinkovitost mjera agrarne politike na profitabilnost njihove proizvodnje u vanjskotrgovinskoj razmjeni, odnosno izostajanju ekonomske učinkovitosti.

PAM je konstruirana za svaki proizvodni sustav, na osnovu čega su utvrđeni troškovi razmjenjivih inputa, troškovi domaćih izvora i prihodi od domaćih i svjetskih cijena. Matrica se sastoji od četiri kolone koje kroz prihode, troškove proizvodnje i profit pokazuju ostvareni dohodak poljoprivrednih gospodarstava, te tri stufaktorske analize koje čine tržišne i svjetske cijene te transferi. Transferi ukazuju na odstupanja koja potječu od tržišnih neuspjeha ili distorzije cijena. Pozitivna vrijednost transfera za prihod znači da je sustav preko implicitnih subvencija platio tržišnu cijenu koja je viša nego njegova svjetska oportunitetna cijena.



Izvor: Monke, Pearson (1989.)

Slika 1. Politička analiza matrice

PAM pristup je sustav dvojnog knjigovodstva. Analitičari koje koriste PAM moraju prikazati kompletno i dosljedno pokrivenost svih utjecaja poljoprivredne politike na pojedinu zemlju ili odabrani sektor, prikazom dobiti i troškova poljoprivredne proizvodnje. Glavni empirijski zadatak je konstruirati računovodstvenu matricu prihoda, troškova i profita (*Monke i Pearson, 1989.*).

Tablica 1. Politička analiza matrice

	Prihodi	Inputi	Resursi	Profit
Stvarne cijene	A	B	C	D
Ekonomске cijene	E	F	G	H
Utjecaj odstupanja učinkovitosti politike	I	J	K	L

Izvor: Assessment of competitiveness of Czech agriculture and food industry in the context of EU accession, *Matthews (1999.)*

Na temelju načinjene računovodstvene matrice ako je vrijednost transfera za prihod negativna tada se radi o implicitnom oporezivanju u sustavu proizvodnje i prerade pšenice. Na osnovi političke analize matrice moguće je utvrditi i političke indikatore kao što su: omjer proizvođačkih troškova (PCR), koeficijent nominalne zaštite (NPC) za outpute i inpute, koeficijent efektivne zaštite (EPC), omjer proizvođačkih troškova, koeficijent profitabilnosti (PC) i koeficijent omjera proizvođačkih subvencija (SRP).

2.2. Anketno istraživanje

Glavno sredstvo za prikupljanje podataka u ovom istraživanju bio je anketni upitnik - najčešće korištena metoda prikupljanja podataka.

Anketni upitnik odlikuje se velikim stupnjem strukturiranosti i prikladan je za statističke analize pa su za potrebe ovog istraživanja izrađena dva upitnika. Prvi anketni upitnik imao je za cilj prikupljanje podataka o proizvodnji pšenice te je proveden na ispitanicima izdvojenim namjernim odabirom iz Upisnika poljoprivrednih gospodarstava, uzimajući u obzir veličinu i strukturu proizvodnje (n=130). Drugi anketni upitnik kreiran je s ciljem prikupljanja podataka o preradi pšenice, odnosno proporcionalne tržišne zastupljenosti s naglaskom na veće prerađivačko-proizvodne kapacitete. Ispitanici su izdvojeni namjernim

odabirom iz registra mlinara, uvoznika i proizvođača brašna, namjenskih smjesa i koncentrata Ministarstva poljoprivrede (n=18).

Na taj način istraženi su uzorci sudionika iz različitih oblika gospodarstava za proizvodnju i preradu pšenice. Prilikom prikupljanja podataka, samo 15% potencijalnih ispitanika odbilo je popuniti upitnik (n=20), od ukupno planiranih 150 upitnika, nasuprot prikupljanju podataka za djelokrug prerade pšenice, gdje odbijanja popunjavanja upitnika nije bilo (n=0).

Istraživanje je provedeno u razdoblju 2012./2013. godina. U navedenom razdoblju određen je redoslijed provedbe pojedinih koraka u postupku prikupljanja podataka.

2.2.1. Koncept i konstrukcija anketnog upitnika za mjerenje učinkovitosti proizvodnje i prerade pšenice

Za provođenje empirijskog istraživanja mjerenja učinkovitosti proizvodnje pšenice primijenjen je anketni upitnik od 43 pitanja, a za utvrđivanje mišljenja ispitanika o temeljnoj strukturi i učinkovitosti prerade pšenice korišten je upitnik od 66 pitanja. Operacionalizirana su četiri koncepta, koja su oblikovana u tvrdnje-skale na nekoliko razina:

- makroekonomske tvrdnje, koje se odnose na nositelje poljoprivredne politike i indikatore poljoprivredne proizvodnje,
- tehničko-tehnološke tvrdnje, kojima se utvrdila primjena tehničkih postupaka i tehnoloških razina proizvodnje i prerade pšenice,
- tržišne tvrdnje, za utvrđivanje činitelja ponude i potražnje za pšenicom i proizvodima od pšenice,
- međunarodno okruženje, kako bi se utvrdili ekonomski učinci poslovanja poslovnih subjekata na međunarodnom tržištu

Na osnovu provedene ankete i zadanih parametara utvrdili su se stavovi, struktura i povezanosti između pojedinih komponenti koje su bile uvjetovane specifičnim uvjetima proizvodnje i prerade pšenice i to:

1. Stavove o proizvodnji i preradi pšenice te varijable vezane uz proizvodnju i preradu pšenice,
2. Strukturu područja stavova o proizvodnji pšenice, pri čemu se analizira struktura stavova koje će se grupirati uz pojedine tematske cjeline u jedinstvene komponente. Osnova za ovu pretpostavku je činjenica kako su koncepti tematski grupirani,
3. Povezanost između latentnih dimenzija, odnosno područja stavova o proizvodnji pšenice bit će pozitivnog predznaka i statistički značajne. Naime, pretpostavlja se kako će grupirana četiri koncepta prema proizvodnji pšenice imati stabilan trend kod svakog pojedinca, odnosno, stavovi prema jednom području bit će u određenoj mjeri u skladu s stavovima prema drugom području. Drugim riječima, proizvođači ili prerađivači koji imaju pozitivne stavove prema određenim grupiranim tematskim konceptima, vjerojatno će imati relativno pozitivne stavove i prema drugim područjima koja su predmet ovog istraživanja,
4. Utvrditi razlike između županija u područjima stavova o proizvodnji pšenice te u varijablama vezanim uz proizvodnju pšenice. Može se pretpostaviti kako će postojati određene razlike između županija u područjima stavova o proizvodnji pšenice te u varijablama vezanim uz proizvodnju pšenice. Razlike će biti uvjetovane specifičnim uvjetima proizvodnje u određenoj županiji, ali i mnogim drugim čimbenicima,
5. Utvrditi razlike između obiteljskih poljoprivrednih gospodarstva i obrta u područjima stavova o proizvodnji pšenice, uz pretpostavku da postoji određena razlika u stavovima s obzirom na proces proizvodnje pšenice. Razlike su uvjetovane specifičnim uvjetima proizvodnje pšenice u odnosu na način poslovanja, odnosno mjerama izravnih i neizravnih potpora od nositelja poljoprivredne politike, kao i troškova koje nose određeni oblik poslovanja.

Najjednostavnije ljestvice samoprocjene svedene su na jednu varijablu dok je kod složenih instrumenata tog tipa informiranost dobivena na temelju rezultata nekoliko varijabli. Takvi testovi mogu imati različite izvedbene forme, ovisno o tome kako se formuliraju njihova pitanja. Konceptijski su korištene dvije vrste pitanja koje se razlikuju po načinu na koji ispitanici odgovaraju na postavljena pitanja.

1. Pitanje s otvorenim, slobodnim odgovorima. Prednosti te vrste pitanja su ne uvjetovani odgovori i ne mogućnost slučajnog odabira točnog odgovora.
2. Pitanje s više ponuđenih odgovora, od kojih je samo jedan točan. Prednost toga formata pitanja su ekonomičnost i objektivno kategoriziranje odgovora.

Finalna forma instrumenata sadržavala je 26 tvrdnji za mjerenje učinkovitosti proizvodnje pšenice, te 50 tvrdnji mišljenja ispitanika o temeljnoj strukturi i učinkovitosti prerade pšenice. Ovim su tvrdnjama pridodane ordinalne skale slaganja od 5 stupnjeva (1 = uopće se ne slažem, 5 = u potpunosti se slažem), pa se tako dobilo pet stavovskih kompozita ordinalnog tipa. Dobiveni podaci iz provedenih anketa o ekonomskoj učinkovitosti proizvodnje, strukturi i preradi pšenice podvrgnuti su odgovarajući deskriptivnim procedurama, nakon čega je izvršena faktorska analiza pod komponentnim modelima u svrhu provjeravanja četiri prethodno postavljena koncepta.

Socio-demografski profili i pojedini stavovi strukture izdvojenih tvrdnji dobiveni su multiplom regresijskom analizom, uz socio-demografske varijable kao zavisne i konceptijske tvrdnje kao nezavisne varijable.

2.2.2. Metode statističke analize podataka primijenjene pri analizi anketnih upitnika

Za analizu podataka korišten je statistički paket SPSS 20.0. U istraživanju su korištene deskriptivne statističke metode, primijenjene za izdvojene tvrdnje te za ukupne rezultate anketnih upitnika popunjenih od strane proizvođača pšenice ($n = 130$) i prerađivača pšenice ($n=18$). Zatim je provedena faktorska analiza koja obuhvaća distribucije frekvencija odgovora, aritmetičke sredine, standardna raspršenja i testiranje normaliteta distribucija.

Za distribucije koje statistički značajno odstupaju od Gaussove krivulje, odnosno za podatke ordinalnog tipa koje čine pojedinačne tvrdnje sa skalama procjene Likertova tipa, središnje vrijednosti određene su izračunavanjem medijana, dok su apsolutne frekvencije i relativne frekvencije izražene u postocima.

Faktorska analiza, odnosno analiza glavnih komponenti provedena je na odgovorima ispitanika na prvi dio upitnika, prema makroekonomskim područjima proizvodnje pšenice.

Cilj primjene metode faktorske analize bio je utvrditi latentne varijable (tj. zbirne rezultate za pojedina tematska područja stavova) koje leže u osnovi međusobne povezanosti manifestnih varijabli (tj. pojedinačnih stavova).

Logika komponentne analize, odnosno metode glavnih komponenti faktorske analize, svodi se na izračunavanje varijance glavnih komponenata te njihovih parcijalnih i kumulativnih doprinosa u odnosu na ukupni varijabilitet analiziranog prostora. U inicijalnoj analizi glavnih komponenata određen je Guttman-Kaisserovim kriterijem utvrđivanja broja glavnih komponenti primjenom kriterija ekstrakcije, onih kojima je karakteristični korijen veći od 1, sa zadanim saturacijama komponenti od minimalno 0,30 korelacije pojedinih varijabli s glavnim komponentama.

Potom je izračunata matrica korelacija za varijable skupova sa značajnim glavnim osovina, te su određeni komunaliteti za pojedine skupine varijabli. Kao metoda ekstrakcije faktora primijenjena je metoda glavnih komponenti, a potom Varimax rotacija na normalizirana faktorska opterećenja, maksimizirajući varijance kvadriranih normaliziranih faktorskih opterećenja za sve varijable koje definiraju jednu komponentu.

S obzirom na činjenicu kako u principu svi podupitnici hipotetski mjere samo jedno usko područje vezano uz proizvodnju pšenice, korištena je strategija apriornog određivanja broja faktora, koja se u pravilu fiksirala na jednu glavnu komponentu (osim u slučaju prve faktorske analize, odnosno makroekonomskih tvrdnji, gdje se dvokomponentna solucija pokazala pogodnijom).


Drugim riječima, utvrđene su čestice svakog subupitnika koje zadovoljavajuće saturiraju tu jedinu glavnu komponentu (bez faktorske rotacije), s vrijednošću korelacije od minimalno 0,30. Nakon toga provjerena je pouzdanost pojedinih dimenzija (glavnih komponenti) koje su dobivene faktorskom analizom, metodom izračuna pouzdanosti tipa interne konzistencije (Cronbach's alpha koeficijent).

Za utvrđivanje povezanosti između pojedinih varijabli korišteni su Spearmanovi koeficijenti korelacije, a za testiranje značajnosti razlika korištena je ANOVA ili Kruskal-Wallisov test za usporedbu više nezavisnih uzoraka, ovisno o broju ispitanika i vrstama varijabli. Testiranje značajnosti razlika između dva uzorka obavljeno je primjenom t-testa za nezavisne uzorke.

2.3. Scenarij analiza

Scenarij analiza je metoda predviđanja najvažnijih trendova i tokova koji bi direktno i indirektno mogli utjecati na buduće poslovanje promatranog izdvojenog sektora ili sustava. Scenarij analiza primjenjuje se prilikom razvoja dugoročnih strategija, a obuhvaća strateška razmišljanja, nekonvencionalne perspektive (outside of box”) i „što-ako” pitanja.

Primjenom scenarij analize dobivaju se smjernice za situacije koje bi se mogle dogoditi, s ciljem kreiranja odgovora na iste.



Izvor: Gospodarenje prirodnim resursima Singer (2007.)

Slika 2. Algoritam izrade scenarija

Kreiranjem scenarij analize izrađuju se više mogućih scenarija i pripadajućih strategija, primjenom identifikacije alternativnih scenarija, razvojem scenarij strategije, procjenom vjerojatnosti scenarija i analizom “žaljenja” (Buble, 1997.) Za istraživanje je primijenjen princip „što-ako“ pitanja, kojim su ocijenjeni ekonomski učinci kroz tri zadana scenarija: održavanje proizvodnje na postojećoj razini, smanjenje razine proizvodnje i prerade pšenice za 50%, minimiziranje prerade, uz održavanje proizvodnje pšenice na jednakoj razini.

2.4. Statistička obrada podataka

Statistička analiza rezultata provedena je pomoću programskog statističkog paketa SPSS 20.0 for Windows 11.0.

3. REZULTATI

3.1. Analiza strukture poljoprivredne proizvodnje u Republici Hrvatskoj u odnosu na Europsku uniju

Osnovni podaci o proizvodnji i preradi pšenice u okviru provedenih istraživanja prikupljeni su s ciljem dobivanja uvida u trenutno stanje u Republici Hrvatskoj i mogućnosti kompariranja s drugim odabranim članicama Europske unije.

Europska unija, gledano sveukupno za 27 zemalja članica, u 2012. godini u odnosu na prethodnu 2011. godinu bilježi pad bruto domaćeg proizvoda (BDP) od 0,3%. Najveći rast BDP-a bilježe baltičke zemlje Latvija (5,6%), Litva (3,7%) i Estonija (3,2%) te Slovačka (2%) i Poljska (1,9%), a najveći pad BDP-a bilježe Grčka (6,4%), Portugal (3,2%), Cipar (2,4%), Italija (2,4%) i Slovenija (2,3%). Bruto dodana vrijednost poljoprivrede, šumarstva i ribarstva u 2012. godini u iznosu od 14 milijardi kuna činila je 5% bruto dodane vrijednosti hrvatskog gospodarstva. U odnosu na prethodnu 2011. godinu, bruto dodana vrijednost poljoprivrede, šumarstva i ribarstva u 2012. godini smanjena je za 6,2%. Vrijednost poljoprivredne proizvodnje Republike Hrvatske u 2012. godini procjenjuje se na 20,6 milijarda kuna. Promatrano po proizvodnim sektorima, u vrijednosti poljoprivredne proizvodnje najveći udio ima biljna proizvodnja (*Ministarstvo poljoprivrede, 2013.*).

Republika Hrvatska ima povoljne agro-klimatološke uvjete koji omogućuju raznovrsnu poljoprivrednu proizvodnju. U ukupnoj strukturi proizvodnje u Hrvatskoj, proizvodnja žitarica zauzima najznačajnije mjesto, odnosno proizvodnja žitarica predstavlja osnovu cjelokupne poljoprivredne djelatnosti, s obzirom da neposredno osigurava hranu za stanovništvo, kao i hranu neophodnu za životinjsku proizvodnju. Žitarice u Republici Hrvatskoj participiraju s više od dvije trećine svih zasijanih površina, pri čemu dominira kukuruz s udjelom od 56% i pšenica s 33%. Važnost proizvodnje žitarica u Republici Hrvatskoj vidljiva je kroz analizu razdoblja od stotinu i deset godina (tablica 2.).

Tablica 2. Proizvodnja žitarica u RH (1900.–2013.)

Razdoblja	Godišnja proizvodnja (u tisućama t)			Po stanovniku (kg)
	Ukupno	*Krušne žitarice	**Stočne žitarice	
1900.-1904.	993	421	575	308,5
1910.-1914.	1179	459	720	334,8
1935.-1939.	1613	548	1083	404,7
1945.-1949.	1272	427	845	340,9
1965.-1969.	2856	1032	1824	660,3
1985.-1989.	3826	1259	2567	818,5
1995.-1999.	2932	811	2121	641,3
2000.-2003.	3035	905	2130	683,1
2004.-2013.	2997	799	2198	672,3

Izvor: Stipetić (1991.); Statistički ljetopis Republike Hrvatske (za razdoblje 1990.-2003.), za razdoblje 2004.-2013. izračunao autor; *(pšenica, raž, pir, proso, heljda i napolica); **(kukuruz, ječam i zob)

U navedenom razdoblju uočen je pozitivan trend rasta proizvodnje od početka stoljeća, izuzev razdoblja oko II. svjetskog rata, nakon toga proizvodnja konstantno raste, a kulminacija opsega proizvodnje žitarica u Republici Hrvatskoj je krajem osamdesetih godina. Prelaskom na tržišni sustav gospodarenja dolazi do stagnacije i pada proizvodnje žitarica, a rezultati dostignuti u spomenutom razdoblju krajem osamdesetih godina prošlog stoljeća nisu dostignuti zaključno s 2013. godinom.

Sukladno obavljenim popisima stanovništva i pripadajućim izdvojenim ekonomskim i demografski pokazateljima za navedene godine, može se uočiti značaj poljoprivrede kao djelatnosti za Republiku Hrvatsku (tablica 3.).

Tablica 3. Demografski i ekonomski pokazatelji udjela poljoprivrede u ukupnom gospodarstvu Republike Hrvatske (1953.-2011.)

Godina	Poljoprivrednici u ukupnom stanovništvu (%)	Aktivni poljoprivrednici (kao % ukupnog aktivnog stanovništva)	BDP iz poljoprivrede (kao % ukupnog)	Poljoprivredni proizvodi u ukupnom izvozu (%)	Poljoprivredni proizvodi u ukupnom uvozu (%)
1953.	56,4	64,8	23,5	/	/
1961.	43,9	50,2	16,8	19,4*	12,0*
1971.	29,1	35,5	15,4	18,3	9,1
1981.	15,2	20,9	10,1	11,4	9,5
1991.	9,1	12,6	9,6	9,0	11,6
2001.	5,5	8,5	7,1	11,7	9,1
**2011.	4,9	3,6	5,1	11,7	8,1

Izvor: Grahovac (2005.); *Podatak od 1966. Godine; **2011. dodani podaci sukladno naknadno obavljenom popisu stanovništva

Poratnom industrijalizacijom smanjivao se i značaj poljoprivrede kroz analizirano razdoblje, što je rezultiralo brzim smanjivanju udjela poljoprivrednog u ukupnom stanovništvu (više od 50%).

Udjel poljoprivrednika u ukupnom broju aktivnog stanovništva znatno se brže smanjivao nego doprinos poljoprivrede u formiranju BDP-a, s obzirom na to da je produktivnost rada u poljoprivredi imala veći porast nego u ostalim ekonomskim djelatnostima. U analiziranom razdoblju najmanje oscilacije imaju vrijednosti udjela poljoprivrednih proizvoda u ukupnom uvozu odnosno izvozu.

3.1.1. Komparacija proizvodnje pšenice u Republici Hrvatskoj i Europskoj uniji

Zbog velike prilagodljivosti različitim klimatskim i pedološkim uvjetima proizvodnje, pšenica se uzgaja na cijelom području Republike Hrvatske. Posebno se izdvajaju istočni i sjeverozapadni krajevi Republike Hrvatske, bogati humusnim zemljištem i pod utjecajem kontinentalne klime, koji se ubrajaju u svjetsku zonu proizvodnje pšenice. To se odnosi naročito na područje istočne Hrvatske.

S obzirom kako je pšenica naša osnovna krušarica, ima status strateškog proizvoda, što znači da su nositelji agrarne politike oduvijek subvencionirali njenu proizvodnju i regulirali tržište i cijene pšenice (*Horak i sur., 2006.*).

U godini provođenja istraživanja (2013.) proizvodnju pšenice obilježili su i imali na istu znakovit utjecaj: ulazak Republike Hrvatske u Europsku uniju, povoljni agro-klimatski uvjeti za proizvodnju poljoprivrednih kultura, nedostatak sredstava domaćih otkupljivača pšenice, duboka recesija, uspješna, ali ne i rekordna žetva pšenice, dugi rokovi naplate isporučenih roba i usluga te negativan utjecaj sive ekonomije.

Temeljem prikupljenih podataka o proizvodnji pšenice u Republici Hrvatskoj za dvanaestogodišnje razdoblje (2002.-2013.) i izdvojenju 1990. godinu, prikazane su vrijednosti indeksa rasta proizvodnje (tablica 4.)

Kako bi se utvrdilo pozicioniranje proizvodnje Republike Hrvatske u segmentu proizvodnje pšenice, obavljeno je kompariranje s referentnom godinom 1990., kada su dostignuti maksimalni kvalitativni i kvantitativni proizvodni rezultati. Dobivene negativne vrijednosti indeksa rasta proizvodnje za razdoblje 2002.–2013. ukazuju zaostajanje proizvodnih rezultata za onima postignutim u referentnoj godini.

Tablica 4. Požnjevene površine i proizvodnja pšenice u Republici Hrvatskoj (2002. - 2013.)

Godina	Požnjevena površina (ha)	Prinos (t ha ⁻¹)	Proizvodnja (1000 t)	Indeks rasta proizvodnje (%)
1990.	319.000	5	1602,0	NA
2002.	234.000	3,5	822,7	-48,6
2003.	206.000	2,5	506,2	-68,4
2004.	162,600	4,9	801,4	-50,0
2005.	146.000	4,1	601,7	-62,4
2006.	176.000	4,6	804,6	-49,8
2007.	175.000	4,6	812,3	-49,3
2008.	156.536	5,5	858,3	-46,4
2009.	180.376	5,2	936,1	-41,6
2010.	168.507	4,0	681,0	-57,5
2011.	149.797	5,2	782,5	-51,2
2012.	186.949	5,4	918,0	-42,7
2013.	188.520	5,2	999,7	-37,6
* χ	163.987	4,6	856,0	

Izvor: Statistički ljetopis Republike Hrvatske (2005.-2013.); *Prosječne vrijednosti se odnose na razdoblje 2002.-2013.

Najniža vrijednost indeksa rasta proizvodnje zabilježena je 2003. godine, -68,4%, a najviša 2013. godine, -37,6%, što predstavlja razliku od ukupno 30,8%.

Analizom prosječnih vrijednosti za navedeno razdoblje 2002.-2013. godina, utvrđeno je kako je požnjeveno 163.987 ha pšenice (podatak uključuje i 2013. godinu), uz prinos od 4,6 t ha⁻¹, i proizvodnju od 856.000 t pšenice.

Analizom najviših i najnižih vrijednosti požnjevenih površina, ukupne proizvodnje i prosječnog prinosa za izdvojeno razdoblje 2002.-2013. godina, utvrđeno je slijedeće:

- najviše pšenice požnjeveno je 2002. godine (234.000 ha), a najmanje 2005. (146.000 ha), što predstavlja razliku od 37,6%,
- najviše pšenice proizvedeno je 2013. godine (997.000 t), a najmanje 2005. godine (601.700 t), što je razlika od 39,7%,
- najveći prosječni prinos zabilježen je 2008. godine (5,8 t ha⁻¹), a najmanji 2003. godine (2,5 t ha⁻¹), što predstavlja razliku od 56,9%.

Ako navedene prosječne rezultate usporedimo s 1990. godinom, utvrđeno je kako se u razdoblju 2002.-2013. godina požnjelo 51% manje pšenice, odnosno, prinos za razdoblje 2002.-2013. godina bio manji za 10%, odnosno u navedenom razdoblju se proizvodilo 51,2 % pšenice manje u odnosu na referentnu 1990. godinu.

Analizom prikupljenih podataka o proizvodnji pšenice u zemljama Europske Unije, za razdoblje 2002.-2013. godina, utvrđeno je kako se podaci o proizvodnji za cjelokupnu Europsku uniju povećavaju razmjerno s godinama proširenja. Tako su se 2004. godine podaci povećali s ulaskom sljedećih zemalja: Cipar, Češka Republika, Estonija, Latvija, Litva, Mađarska, Malta, Poljska, Slovačka, Slovenija, 2007. godine u EU su pristupile Bugarska i Rumunjska, a 01. srpnja 2013. godine članica EU postaje i Republika Hrvatska.

Zemlje najveći proizvođači pšenice u Europskoj Uniji su Francuska s prosječnom proizvodnjom od 36.849.600 t (27%), Njemačka s 23.149.200 t (17%), Velika Britanija s 14.846.000 t (11%) i Poljska s prosječnom proizvodnjom od 8.931.000 t (7%). Republika Hrvatska se ulaskom na tržište Europske Unije nalazi na 22. mjestu (0,57%), s prosječnom proizvodnjom u razdoblju 2002.-2013. godine od 776.500 t.

S obzirom na to da je Republika Hrvatska u 80-tim godinama prošlog stoljeća proizvodila prosječno 1.550.000 t pšenice, prostora za bolju alokaciju resursa ima kroz poboljšanja i povećanja proizvodnje. S navedenom prosječnom proizvodnjom Republika Hrvatska bila je na 16. mjestu po prosječnoj proizvodnji pšenice u Europskoj uniji.

Zemlje članice koje prosječno proizvode najmanje pšenice su: Slovenija 149.000 t (0,11%), Luksemburg 79.700 t (0,06%), Cipar 15.600 t (0,01%) i Malta na začelju bez proizvodnje (tablice 5. i 6.).

Tablica 5. Proizvodnja pšenice u Europskoj uniji izraženo u 1.000 t (2002.-2007.)

Članica/Godina	2002.	2003.	2004.	2005.	2006.	2007.
EU	104133	90638	137283	124351	117732	120075
Belgija	1675	1693	1913	1799	1720	1645
Bugarska	4123	2004	3.961	3.478	3302	2391
Češka	3867	2638	5043	4145	3506	3939
Danska	4056	4701	4759	4887	4802	4519
Njemačka	20818	19260	25.427	23693	22428	20828
Estonija	148	145	197	263	220	346
Irska	867	794	1019	803	801	713
Grčka	1783	1632	1774	1761	1576	1384
Španjolska	6822	6019	7097	4.027	5522	6436
Francuska	38933	30481	39692	36886	35364	32770
Hrvatska	823	506	801	602	805	812
Italija	7548	6230	8639	7717	7182	7170
Cipar	13	14	10	9	8	11
Letonija	520	468	500	677	598	807
Litva	1218	1204	1430	1379	810	1391
Luksemburg	72	69	80	72	76	71
Mađarska	3910	2941	6007	5088	4376	3987
Malta	0	0	0	0	0	0
Nizozemska	1057	1130	1224	1175	1185	1018
Austrija	1434	1191	1719	1453	1396	1399
Poljska	9304	7858	9.893	8771	7060	8317
Portugal	413	150	293	82	250	102
Rumunjska	4421	2479	7812	7341	5526	3045
Slovenija	175	123	147	141	134	133
Slovačka	1554	930	1765	1608	1343	1380
Finska	569	679	782	801	684	797
Švedska	2113	2283	2412	2247	1967	2256
Velika Britanija	15973	14327	15473	14877	14735	13221

Izvor: Eurostat (2013.)

Tablica 6. Proizvodnja pšenice u Europskoj Uniji (u 1.000 t) 2008.-2013.

Članica/Godina	2008.	2009.	2010.	2011.	2012.	2013.	* χ
EU	150618	138363	136634	138270	133200	0	126481,6
Belgija	1944	1978,1	1913	1655	1835	0	1797,3
Bugarska	4632	3977	4095	4459	4455	5097	3831
Češka	4691	4358	4162	4913	3519	4726	4125,5
Danska	5019	5940	5060	5060	4525	4139	4788,9
Njemačka	25989	25190	24040	22783	22409	24927	23149,2
Estonija	343	343	328	353	485	406	298
Irska	993	690	669	929	708	534	793,4
Grčka	1939	1830	1663	1702	1569	0	1692,2
Španjolska	6832	4773	5941	6900	5190	7598	6096,4
Francuska	39002	38325	38195	36013	37921	38614	36849,6
Hrvatska	858	936	616	782	1000	0	776,5
Italija	8859	6341	6777	6622	7654	7010	7312,4
Cipar	25	15	19	25	23	17	15,6
Letonija	990	1036	973	940	1539,8	1435	873,6
Litva	1723	2100	1710	1869	2999	2862	1724,6
Luksemburg	97	91	84	77	79	91	79,7
Mađarska	5631	4419	3764	4130	4011	5096	4446,6
Malta	0	0	0	0	0	0	0
Nizozemska	1366	1402	1442	1186	1302	1331	1234,8
Austrija	1689	1523	1518	1782	1276	1598	1498,3
Poljska	9275	9790	9488	9339	8607	9470	8931
Portugal	203	124	83	59	59	0	165,1
Rumunjska	7181	52023	5588	7192	5114	7463	5697,1
Slovenija	160	137	152	154	188	139	149
Slovačka	1820	1538	1228	1639	1275	0	1461,8
Finska	788	887	723	981	909	888	790,6
Švedska	2202	2278	2143	2253	2289	1867	2192,5
Velika Britanija	17227	14076	14878	15257	13261	0	14846

Izvor: Eurostat (2013.); *srednja vrijednost za razdoblje 2002.-2013.

Analizom ukupno zasijanih površina pod pšenicom na području Europske unije utvrđeno je da se najveće površine zasiju na oranicama Francuske 5.338.500 ha (20%), Njemačke 3.130.500 ha (12%), Poljske 2.253.500 ha (9%) i Rumunjske, gdje je pšenicom zasijano ukupno 2.094.300 ha (8%) oranica.

Rumunjska se po zasijanim površinama pod pšenicom nalazi na 4. mjestu, međutim po prosječnoj ukupnoj proizvodnji je na 7. mjestu, što je rezultat primjene lošije agrotehnike, odnosno zastarjele mehanizacije.

Republika Hrvatska se nalazi na 20. mjestu po prosječnim zasijanim površinama pšenicom s 168.800 ha (0,64 %). Zemlje članice koje zasijavaju najmanje površina pod pšenicom su: Slovenija 33.000 ha (0,13%), Luksemburg 13.100 ha (0,05%), Cipar 7.000 ha (0,03%) te Malta na začelju bez proizvodnje (tablice 7. i 8.).

Tablica 7. Proizvodnja pšenice u Europskoj Uniji na zasijanim površinama (u 1.000 ha) 2002.-2007.

Članica/Godina	2002.	2003.	2004.	2005.	2006.	2007.
EU	18015	17163	23306	22892	21871	24806
Belgija	203	199	212	214	210	210
Bugarska	1348	818	1018	1084	0	1082
Češka	849	648	863	820	782	811
Danska	577	664	666	676	686	689
Njemačka	3015	2964	3112	3174	3115	2992
Estonija	65	67	78	85	91	100
Irska	103	96	103	95	88	84
Grčka	890	851	839	846	685	623
Španjolska	2407	2221	2175	2274	1920	1803
Francuska	5230	4877	5237	5278	5246	5239
Hrvatska	179	157	163	146	176	175
Italija	2415	2266	2354	2123	1926	2100
Cipar	6	7	8	5	5	5
Letonija	154	168	170	188	215	225
Litva	335	337	355	370	344	355
Luksemburg	12	11	12	12	13	13
Mađarska	1111	1114	1174	1131	1075	1111
Malta	0	0	0	0	0	0
Nizozemska	135	129	137	136	140	141
Austrija	289	272	290	289	285	293
Poljska	2414	2308	2311	2218	2.176	2.112
Portugal	231	175	187	123	105	55
Rumunjska	2296	1735	2296	2476	2013	1975
Slovenija	36	36	32	30	32	32
Slovačka	406	308	369	376	351	361
Finska	174	192	236	215	192	204
Švedska	339	411	403	354	360	360,5
Velika Britanija	1996	1836	1990	1867	1836	1831

Izvor: Eurostat (2013.)

Tablica 8. Proizvodnja pšenice u Europskoj Uniji na zasijanim površinama (u 1.000 ha) 2008.-2013.

Članica/Godina	2008.	2009.	2010.	2011.	2012.	2013.	* χ
EU	26513	25565	25876	26146	26091	0	23476,8
Belgija	224	212	213	203	217	0	210,6
Bugarska	1112	1185	1138	1138	1185	1200	1118,7
Češka	802	831	834	863	815	829	1025,5
Danska	638	739	764	747	614	568	669
Njemačka	3214	3226	3327	3248	3057	3125	3130,5
Estonija	108	114	119	129	124	125	100,4
Irska	111	85	78	94	98	60	91
Grčka	657	698	510	544	563	0	700,6
Španjolska	2058	1773	1948	1993	2188	2122	2073,4
Francuska	5493	5147	5426	5827	5740	5323	5338,5
Hrvatska	157	180	169	149	187	189	168,8
Italija	2289	1796	1830	1726	1854	1889	2047,2
Cipar	5	6	8	11	9	9	7
Letonija	257	286	297	307	352	369	248,8
Litva	404	500	517,6	551	627	665	446,6
Luksemburg	15	14	14	14	14	14	13,1
Mađarska	1130	1147	1011	981	1070	1102	1096,3
Malta	0	0	0	0	0	0	0
Nizozemska	157	151	153	151	152	153	145
Austrija	297	309	303	304	308	297	294,7
Poljska	2278	2346	2406	2259	2077	2138	2253,5
Portugal	88	73	58	43	55	0	108,3
Rumunjska	2110	2149	1994	1980	1959	2147	2094,3
Slovenija	35	34	32	30	35	32	33
Slovačka	374	380	350	363	388	356	365,2
Finska	220	218	212	255	231	229	214,7
Švedska	361	374	397	419	366	323	372,3
Velika Britanija	2080	1775	1939	1969	1992	1615	1893,8

Izvor: Eurostat (2013.); * srednja vrijednost za razdoblje (2002.-2013.)

3.1.2. Komparacija prerade pšenice u Republici Hrvatskoj i Europskoj uniji

U godini provođenja istraživanja (2013.) na strukturu industrijske prerade pšenice u Republici Hrvatskoj utjecali su različiti socio-ekonomski i globalno-politički faktori: ulazak Republike Hrvatske u Europsku uniju, uvođenje PDV-a po stopi od 5% na sve vrste kruha, težak gospodarski položaj i kod većine stagnacija proizvodnih aktivnosti, smanjena

aktivnost u mlinskoj industriji u odnosu na prethodnu godinu, priliv jeftinijih roba iz susjednih zemalja, nepovoljan položaj proizvođača u odnosu s trgovinom, pogotovo s velikim trgovačkim lancima, prisutnost na tržištu sive ekonomija, kao i uvoz poljoprivredno prehrambenih proizvoda na štetu domaće proizvodnje (HGK, 2013.).

U registre mlinara, uvoznika i proizvođača brašna, namjenskih smjesa i koncentrata upisano je 193 mlinara, 11 proizvođača namjenskih smjesa i koncentrata, 47 uvoznika brašna, 35 uvoznika namjenskih smjesa i koncentrata, te 7 pravnih subjekata koji se bave prepakiranjem brašna.

Prema evidencijama Ministarstva poljoprivrede moguće je uočiti neravnomjernu distribuciju u kojoj 10 najvećih mlinara proizvede 70% domaćeg brašna, odnosno oko 400.000 t, a pet najvećih uvoznika uvoze 73% brašna, odnosno 2.200 t. Kapaciteti mlinova za meljavu pšenice u Republici Hrvatskoj premašuju 1.300.000 t, što je dostatno za 250 radnih dana, kapaciteti za meljavu kukuruza su oko 100-110.000 t i raži oko 7.000 t. Ukupna potrošnja brašna u Republici Hrvatskoj kreće se oko 460.000 t (HGK, 2013.).

U Republici Hrvatskoj od ukupne samljevene količine pšenice 75% otpada na pšenično brašno, 20% na stočnu hranu, a 5% na posije.

Analizom ukupne proizvodnje brašna za razdoblje 2002.-2012. godine utvrđeno je da se od ukupne prosječne proizvodnje mlinskih proizvoda u navedenom razdoblju 486.180 t pšeničnog brašna proizvodilo u prosjeku 460.302 t (tablica 9.).

Tablica 9. Proizvodnja mlinskih proizvoda (t) u Republici Hrvatskoj 2002.-2012.

Godina	Mlinski proizvodi	Pšenično brašno
2002.	465.574	434.203
2003.	468.755	440.148
2004.	470.572	446.524
2005.	491.673	456.440
2006.	492.440	464.762
2007.	492.613	470.827
2008.	522.313	491.409
2009.	492.019	471.139
2010.	496.750	472.804
2011.	477.223	456.958
2012.	478.045	458.112
χ	486.180	460.302

Izvor: Hrvatska Gospodarska Komora (2013.)

Najniža razina proizvodnje u analiziranom razdoblju zabilježena je 2002. godine, kada je ukupno proizvedeno 434.203 t, nasuprot 2008. godini, kada je proizvedeno 491.408 t pšeničnog brašna, što predstavlja razliku od 11,7%.

Sagledavanjem ukupnih potreba stanovništva Republike Hrvatske za jednom od osnovnih životnih namirnica – brašnom, za razdoblje 2002.-2012. godina, utvrđeno je kako je u prosjeku bilo potrebno osigurati 379.500 t brašna.

Oscilacije potrebe za pšeničnim brašnom se u navedenom razdoblju kreću od najniže vrijednosti od 338.440 t zabilježene 2002. godine do 409.822 t brašna u 2005. godini, odnosno razlika između navedenih vrijednosti je 17,4% (tablica 10.).

Za izdvojeno razdoblje 2002.-2012. godina obavljena je analiza uvožno-izvozne bilance (tablica 10.), gdje je utvrđeno da je ista pozitivna i iznosi 76.215 t. Negativni trendovi su zabilježeni 2002., 2004., 2005. i 2006. godine, a najniži negativni omjer uvoza prema izvozu zabilježen je 2005. godine (3.528 t).

U preostalim godinama analiziranog razdoblja zabilježeni su pozitivni trendovi uvožno-izvozne bilance, a 2012. godine evidentiran je najveći izvozni rezultat u količini od 17.583 tone. Prosječno se u Republiku Hrvatsku uvezilo 2.908 t, a izvezilo 9.836 t brašna.

Tablica 10. Izvoz-uvoz brašna, potrebe u Republici Hrvatskoj (t) 2002. - 2012.

Godina	Uvoz brašna	Izvoz brašna	Potrebne količine	Uvožno-izvozna bilanca
2002.	1.985	1.564	338.440	- 421
2003.	1.500	1.852	406.634	352
2004.	4.397	2.609	399.448	-1.788
2005.	5.852	2.324	409.822	-3.528
2006.	5.010	1.762	379.558	-3.248
2007.	3.368	14.921	376.077	11.553
2008.	2.911	19.737	359.568	16.826
2009.	2.528	10.703	370.978	8.175
2010.	2.672	17.590	377.338	14.918
2011.	1.196	16.989	377.013	15.793
2012.	565	18.148	380.000	17.583
Ukupno	31.984	108.199	4.174.876	76.215
\bar{x}	2.908	9.836	379.534	

Izvor: Hrvatska Gospodarska Komora (2013.)

Analizom proizvodnje brašna po tipovima za razdoblje 2002.-2012. godine (tablica 11.), utvrđeno je kako se od ukupne prosječne proizvodnje brašna od 306.303 tone, najviše proizvelo pšeničnog bijelog brašna TIP 550, u prosjeku 250.000 t (53,1%), zatim pšeničnog polubijelog brašna TIP 850 (15,9%), prosječno 75.000 t, a najmanja prosječna proizvodnja zabilježena je kod brašna TIP 1600, od 500 t ili 0,1%. U analiziranom razdoblju prosječno se proizvodilo 100.00 t stočne hrane, odnosno 25.000 t posija.

S obzirom kako se u procesu mljevenja pšenice zrno usitnjava razdvajanjem anatomskih dijelova i na taj način se proizvodi brašno i krupica za ljudsku prehranu, stočna brašna i posije, koji se koriste kao stočna hrana, i u maloj količini izdvaja se klica. Učinkovitost razdvajanja ovisi od meljivosti pšenice i načina vođenja tehnološkog procesa pripreme i mljevenja.

Tablica 11. Proizvodnja brašna u Republici Hrvatskoj po tipovima, proizvodni udjeli za razdoblje 2002.-2012.

Tipovi brašna	Pojedinačni proizvodni udjeli (%)	Proizvodnja (t)
T-400	3,9	15.000
T-550	53,1	250.000
T-850	15,9	75.000
T-700	0,2	1.500
T-1100	0,2	5.000
T-1600	0,1	500
Integralno	0,4	1.500
Posije	5,1	25.000
Stočna hrana	21,1	100.000

Izvor: Hrvatska gospodarska komora (2013.)

S ciljem prikupljanja podataka o preradi pšenice, obrađeni su podaci dostupni od europske krovne udruge mlinske industrije - The European Flour Millers. Republika Hrvatska se datumom ulaska u Europsku Uniju (01.07.2013.) priključila članstvu navedene udruge.

Temeljem dostupnih podataka za 22. zemlje članice, izuzev Bugarske, Grčke, Irske, Italije i Malte, utvrđeno je da je u razdoblju 2004.-2007. godine prisutna disproporcija u mlinskom sektoru analiziranih zemalja članica Europske unije, odnosno veliki broj mlinova ne znači i automatski najveću proizvodnju pšeničnog brašna.

Analizom prikupljenih podataka o broju mlinova po zemljama članicama utvrđen je trend pada broja mlinova ili stagnacije u manjem broju zemalja prema izdvojenom vremenskom razdoblju od 2004.- 2007. (tablica 12.).

Tablica 12. Broj mlinova po zemljama članicama za razdoblje 2004.-2007.

Zemlja članica/Godina	2004.	2005.	2006.	2007.
Austrija	205	196	193	185
Belgija	53	44	44	44
Cipar	5	4	4	4
Češka	52	50	48	47
Danska	8	7	7	7
Estonija	11	10	10	10
Finska	6	6	6	6
Francuska	511	495	470	468
Njemačka	336	333	318	317
Mađarska	93	72	68	62
Latvija	45	21	22	21
Litva	22	19	20	21
Luksemburg	2	2	2	2
Nizozemska	15	15	15	15
Poljska	650	630	620	580
Portugal	24	24	23	22
Rumunjska	1000	1000	1000	1000
Slovenija	8	9	7	7
Slovačka	34	33	31	30
Španjolska	196	186	178	162
Švedska	10	10	10	10
Velika Britanija	63	60	59	60

Izvor: The European Flour Millers, QUESTIONNAIRE (2012.)

Stavljanjem u omjer vrijednosti prosječne godišnje proizvodnje prema zemlji članici, odnosno broju mlinova, utvrđeno je da najmanju vrijednost po objektu – mlinu, ima Rumunjska 1.600 t. Rumunjsku mlinsku proizvodnju karakterizira veliki broj mlinova (1000), od kojih više od polovice su mali mlinovi, malog kapaciteta i zastarjele tehnologije.

Najveći kapaciteti prerade zabilježeni su u Nizozemskoj, gdje se po mlinu prosječno godišnje proizvodi 78.667 t pšeničnog brašna, odnosno od ukupno proizvedene količine od 1.180.000 t godišnje 50% se proizvede od domaće proizvodnje pšenice, a preostalih 50% se uvozi. Zemlje s visokim vrijednostima prosječne proizvodnje po proizvodnoj

jedinici su Velika Britanija (73.798 t), Švedska (64.600 t) i Danska (57.143 t), a izdvojene zemlje članice s niskim vrijednostima prosječne proizvodnje su Latvija (1.852 t) i Austrija 2.939 t (austrijski mlinski sektor karakterizira veliki broj mlinova malog kapaciteta: 135 mlinova proizvodi manje od 2.000 t/godišnje, a koji se, osim za proizvodne namjene, koriste i u turističke svrhe).

Republika Hrvatska se s prosječnom godišnjom proizvodnjom pšeničnog brašna od 460.302 tone nalazi na 14. mjestu od ukupno 23 izdvojene zemlje članice. Analizom razine prosječne proizvodnje po proizvodnoj jedinici - mlinu za izdvojene zemlje članice, Republika Hrvatska s vrijednosti od 2.423 tone na 20. je mjestu, odnosno s iskorištenosti proizvodnih kapaciteta od 40% na začelju je zajedno s Rumunjskom (tablica 13.).

Tablica 13. Prikaz ukupne godišnje proizvodnje brašna i korištenja postojećih mlinskih kapaciteta u izdvojenim zemljama članicama

Zemlja članica	Proizvodnja (t/god)	Iskorištenost proizvodnih kapaciteta (%)	Broj mlinova- višegodišnji prosjek	Prosječna proizvodnja proizvodne jedinice
Austrija	573.000	80	195	2.939
Belgija	1.195.266	70	46	25.984
Cipar	65.000	65	4	16.250
Češka	920.000	65	49	18.776
Danska	400.000	58	7	57.143
Estonija	48.000	68	10	4.800
Finska	200.000	70	6	33.333
Francuska	4.513.287	65	486	9.287
Hrvatska	460.302	45	190	2.423
Njemačka	5.299.436	80	326	16.041
Mađarska	907.000	56	73	12.425
Latvija	50.000	80	27	1.852
Litva	229.456	66	21	10.927
Luksemburg	4.000	75	2	2.000
Nizozemska	1.180.000	85	15	78.667
Poljska	3.200.000	65	620	5.161
Portugal	680.000	70	23	29.565
Rumunjska	1.600.000	45	1000	1.600
Slovenija	114.695	60	8	14.337
Slovačka	410.000	74	32	12.813
Španjolska	2.700.000	50	181	14.917
Švedska	646.000	70	10	64.600
Velika Britanija	4.501.669	80	61	73.798

Izvor: The European Flour Millers, QUESTIONNAIRE (2012.)

Iskorištenost proizvodnih kapaciteta ostalih zemlja članica je visoka. Najveća vrijednost od 85% evidentirana je u Nizozemskoj, Austrija, Njemačka i Velika Britanija imaju 80% iskorištenosti, dok preostale zemlje članice koriste svoje prerađivačke kapacitete u mlinskom sektoru u rasponu od 60-80%, izuzev Španjolske, koja ima 50% iskorištenosti kapaciteta proizvodnje.

Analizom podataka o korištenju sirovine - pšenice u proizvodnji mlinskih proizvoda u izdvojenim zemljama članicama utvrđeno je da je najzastupljenija pšenica iz vlastite proizvodnje, izuzev Portugala i Cipra, koji koriste u proizvodnji pšenicu iz uvoza, s obzirom na to da im je vlastita proizvodnja niska ili ne zadovoljava kvalitetom (tablica 14.).

Tablica 14. Ukupna godišnja proizvodnja brašna, prikazom postotnog udjela utrošene sirovine-pšenice

Zemlja članica	Vlastita proizvodnja	Uvoz - EU	Uvoz - treće zemlje
Austrija	80	20	-
Belgija	10	80	10
Cipar	5	80	15
Češka	93,9	6,1	-
Danska	50	50	-
Estonija	50	50	-
Finska	83	9	8
Francuska	97	2	1
Hrvatska	99,5	0,5	-
Njemačka	94,4	5,4	0,2
Mađarska	100	-	-
Latvija	100	-	-
Litva	85,4	14,6	-
Luksemburg	-	100	-
Nizozemska	50	40	10
Poljska	93	7	-
Portugal	10	90	-
Rumunjska	85	15	-
Slovenija	44,8	55,2	-
Slovačka	95	5	-
Španjolska	50	40	10
Švedska	30	60	10
Velika Britanija	84	8	8

Izvor: The European Flour Millers, QUESTIONNAIRE (2012.)

Zemlje koje uvoze sirovinu – pšenicu, najvećim dijelom obavljaju uvoz iz zemalja članica Europske unije, a manji dio pšenice (u prosjeku 10%) uvozi se iz trećih zemalja (Kanada i Sjedinjene Američke Države).

Republika Hrvatska koristi u preradi pšenicu iz vlastite proizvodnje (99,5%), a uvozi minimalne količine (0,5%), i to iz zemlja Europske unije.

3.1.3. Analiza tržišta pšeničnog brašna u Republici Hrvatskoj

Kako bi se utvrdilo stanje i trendovi na tržištu pšeničnog brašna u Republici Hrvatskoj, obavljeno je terensko istraživanje utvrđivanja ponude izdvojenog proizvoda u robnim maloprodajnim lancima aktivnim na području istočne Hrvatske u 2013. godini.

Utvrđivanjem ponude pšeničnog brašna u maloprodaji kod devet maloprodajnih trgovačkih lanaca, od kojih su tri u hrvatskom vlasništvu, a preostalih sedam imaju većinske vlasničke udjele u zemljama članicama Europske unije. Terenskim istraživanjem i analiziranim stanjem utvrđeni su tipovi i podrijetlo brašna zastupljenih u maloprodaji. Analizirani proizvodi imaju navedenu zemlju podrijetla Republika Hrvatska kod ukupno trinaest registriranih proizvođača, a nisu zatečeni proizvodi proizvedeni izvan Republike Hrvatske.


U tablici 15. navedeni su podaci o zemlji podrijetla trgovačkog lanca i zastupljenosti brašna prema tipovima i namjeni u izdvojenim analiziranim objektima maloprodaje. Analizom zastupljenosti (Z) prema pojedinačnom proizvodu utvrđeno je kako su najzastupljeniji proizvodi pšenično bijelo brašno (T-550) glatko (Z=38; 22,2%), zatim pšenično bijelo brašno (T-550) oštro (Z=23; 13,5%) i pšenično polubijelo brašno T-850, (Z=21; 12,2%). Preostali tipovi brašna zastupljeni su u približno proporcionalnim vrijednostima intervala (Z=8-13; 4,7-7,6%). Ukupno je utvrđena visina zastupljenosti pšeničnog brašna po tipovima ($\sum Z=171$).

Tablica 15. Zastupljenost pšeničnog brašna u Republici Hrvatskoj po tipovima - maloprodaja u 2013. godini

Trg. lanac*	A 1	HR 1	D 1	A 2	D 2	HR 2	HR 3	SLO	D 3	Z	%
Tip brašna**											
T-400 (O)	1	2	1	2	1	0	0	1	1	9	5,3
T-400 (G)	1	1	0	0	3	2	0	2	2	11	6,3
T-400 (kolač)	2	0	0	1	4	3	0	1	1	12	7
T-400	1	0	0	0	4	0	0	2	2	9	5,3
T-550 (G)	4	6	1	5	7	5	1	4	5	38	22,2
T-550 (O)	1	1	0	1	7	4	1	3	5	23	13,5
T-550 (pizza)	1	1	0	1	1	2	0	0	2	8	4,7
T-550 (dizana tj.)	1	1	0	1	2	1	0	1	2	9	5,3
T-850	3	3	1	2	2	3	1	2	4	21	12,2
Krupica	4	2	0	1	0	0	0	0	2	9	5,3
Integralno	4	1	0	1	4	0	0	2	1	13	7,6
T-1600	0	1	1	1	0	2	2	1	1	9	5,3
									Σ	171	100

*A1, A2 (Austrija), D1, D2, D3 (Njemačka), HR1, HR2 (Hrvatska), SLO (Slovenija), navedene oznake su u skladu s većinskim vlasničkim udjelima pojedinog trgovačkog lanca u odnosu na zemlju podrijetla; ** O (oštro), G (glatko), (kolač, dizana tjesta i pizza - namjenska brašna)

Temeljem dostupnih podataka ažuriranih od strane Ministarstva poljoprivrede, prikazano je kretanje cijena pšeničnog bijelog brašna T-550 (glatko) u razdoblju od tri godine, sukladno prosječnoj cijeni po mjesecima (grafikon 1.).



Izvor: Ministarstvo poljoprivrede RH (2013.)

Grafikon 1. Kretanje cijena (kn), pšeničnog bijelog brašna T-550 (glatko) u razdoblju (2010. – 2012.)

Analizom za navedene tri godine za izdvojeni proizvod pšenično bijelo brašno (T-550) glatko, utvrđeno je kako su trendovi kretanja cijena početkom godine različiti, od najnižih 1,5 kn 2010. godine, do najviše vrijedosti 2,75 kn u 2011. godini.

Prijelomna točka je razdoblje završetka žetve, odnosno mjesec srpanj, kada se cijene sukladno tržišnoj asimilaciji ujednačavaju i trendovsku stabilnost zadržavaju do konca godine pojedinačno.

3.1.4. Analiza tržišta pšenice u Republici Hrvatskoj i Europskoj uniji

Tržišna cijena pšenice u Europskoj uniji formira se na dvije glavne burze - MATIF (francuska burza pšenice) i BSA burza u Budimpešti, uz utjecaj kretanja cijena robe na najvećoj svjetskoj burzi u Chicagu (Sjedinjene Američke Države).

Europska komisija u svom sastavu ima posebno tijelo tj. istraživački centar Joint Research Centre (JRC), gdje se obavljaju istraživanja najnovijim metodologijama, odnosno pomoću satelitskih daljinskih istraživanja i matematičkih modela simulira se rast usjeva, uz kalkulaciju klimatskih i vremenskih uvjeta.

Dobiveni rezultati pokazali su se u praksi kao vrlo prihvatljivi i precizni, a na temelju istih te praćenja kretanja cijene pšenice na svjetskim burzama, Europska komisija predviđa cijene strateških poljoprivrednih proizvoda, uključujući i pšenicu.

Analizom cijena pšenice za jedanaestogodišnje razdoblje 2002.-2012. godine (izraženih u kn/kg pšenice), uočeno je da je najniža prosječna cijena zabilježena u 2005. godini (0,77 kn), a najviša 2013. godine (1,99 kn). Prosjek otkupne cijene pšenice na tržištu Europske unije u navedenom razdoblju je 1,17 kn (0,16 €), (tablica 16.)


Najniža prosječna otkupna cijena pšenice u Republici Hrvatskoj od 0,85 kn zabilježena je 2009., a najviša vrijednost od 2,3 kn evidentirana je 2007. godine. Prosječna vrijednost otkupne cijene pšenice u Republici Hrvatskoj za razdoblje 2002.-2013. godine je 1,42 kn, a u Europskoj Uniji 1,17 kn (0,16 €), odnosno navedena vrijednost je za 18% bila veća u Republici Hrvatskoj u odnosu na zemlje Europske unije.

Tablica 16. Otkupna cijena pšenice u Republici Hrvatskoj i Europskoj uniji izražena u kunama/kg i €/kg (2002.-2013.)

Godina	RH (kn/kg)	EU (kn/kg)	EU (€/kg)
2002.	1,23	0,84	0,11
2003.	0,95	0,92	0,12
2004.	1,61	0,91	0,12
2005.	1,29	0,77	0,10
2006.	0,99	0,92	0,12
2007.	2,30	1,38	0,18
2008.	1,89	1,3	0,18
2009.	0,85	0,92	0,12
2010.	1,27	1,15	0,15
2011.	1,4	1,45	0,2
2012.	1,39	1,53	0,21
2013.	1,85	1,98	0,26
χ	1,42	1,17	0,16

Izvor: Ministarstvo poljoprivrede RH (2013.), Eurostat (2013.)

Usporedbom kretanja cijena pšenice u Republici Hrvatskoj s onima u Europskoj Uniji, uočeno je da u razdoblju 2002.-2008. godine otkupne cijene u Republici Hrvatskoj značajno odstupaju od tržišnih cijena u Europskoj uniji, izuzev 2003. i 2006. godine kada su odstupanja bila minimalna (grafikon 2.).



Izvor: Ministarstvo poljoprivrede Republike Hrvatske (2013.); Eurostat (2013.)

Grafikon 2. Prikaz kretanja otkupnih cijena pšenice u Republici Hrvatskoj i Europskoj uniji izraženih u kunama (2002. - 2013.)


Nakon početka pregovora s Europskom Unijom 2005., zamjetne su manje oscilacije u formiranju otkupnih cijena pšenice, izuzev 2007. godine, kada je razlika bila najveća (RH 2,3 kn, EU 1,4 kn). U razdoblju od 2009. sve do 2013. godine, sukladno približavanju ulasku Republike Hrvatske u punopravno članstvo, razlika prosječne otkupne cijene pšenice između Republike Hrvatske i Europske unije bila je minimalna.

Tablica 17. Prodajne cijene pšenice na tržištu Europske Unije 2002.-2012. (EUR/100 kg pšenice)

Članica/Godina	2002.	2003.	2004.	2005.	2006.	2007.	2008.	2009.	2010.	2011.	2012.
Belgija	9,9	11,2	10,9	9	11,9	17,7	16,5	11,1	15,6	19,8	22,3
Bugarska	8,2	10,7	11,8	7,9	8,7	15,3	16	10,8	12,5	16,7	20,7
Češka	11,1	10,6	12,2	9,2	10,9	16,5	20,5	10,9	13,4	20,5	20,1
Danska	10,5	10,8	12,7	10,1	11	16,6	20,4	12	13,2	19,3	20,7
Njemačka	10,4	11,1	11,8	9,4	11,2	17,6	18,6	11,3	14,9	20,7	:
Estonija	10,3	11,4	11,2	9,8	11,2	18,3	15,6	10,4	15,6	18,7	21
Irska	9,7	12	10,8	10,5	12,2	20,1	13,7	10,5	:	:	:
Grčka	14	14,2	14,2	14,1	14,1	23,5	22,6	13,5	16,	22,5	23,2
Španjolska	13	13,5	14	13,8	14	20,9	19	14,	17,3	21,2	23,9
Francuska	9,7	11,5	9,0	9,4	12,2	18,9	14,9	11,11	16,1	21,3	:
Italija	14,3	14,8	16	12,6	14,5	20,8	22,3	15,4	18,2	24,9	24,6
Letonija	10,3	9,9	10,2	8,9	11,2	18,9	15,5	11,3	16,3	19,7	21,3
Litva	11,7	11,6	10,5	9,5	12,8	18,7	16,2	11,5	16,2	20,6	21,2
Luksemburg	12,6	13,4	11,8	11,5	12,6	20,3	14	10	15,9	18,2	23,1
Mađarska	9,3	11,9	9,3	8,2	10	17,4	15,9	10,6	14,2	18,3	20,9
Nizozemska	9,8	11,8	11,1	9,7	10,2	19	16,1	11,1	16,1	19,4	22,4
Austrija	9,8	10,8	8,8	8,2	10,5	18,9	13,6	8	18,4	15,7	18,4
Poljska	11,3	10,3	10,4	9,1	11,5	19	18,3	11,2	15	19,9	21,38
Portugal	12,3	13	13,9	12,3	11,6	17,7	20,3	13,6	14,9	20	22,1
Rumunjska	12,2	17,6	13,6	10	9,6	18	18	11,1	14	20,8	20,4
Slovenija	13,6	14	11,9	10,6	10,9	17,1	17,	11,9	13,6	19,3	19,6
Slovačka	9,1	9,7	9,6	8,3	9,9	16,3	14,1	10,3	13,6	17,9	19,2
Finska	13,2	12,6	12	10,6	11,1	16	18,9	13,2	14,7	19,7	20,
Švedska	10,6	11,2	10,7	9,8	11,2	18,7	18,6	10,7	17	19,9	21,8
Velika Britanija	11,1	12,1	12,7	10,6	11,9	18,8	19,1	12,3	15,3	21,	23,8
χ	11,11	12	11,7	10,1	11,5	18,4	17,5	11,5	15,4	19,8	20,1

Izvor: Eurostat (2013.); *: nema podataka

Analizirajući veleprodajne cijene pšenice u Republici Hrvatskoj za razdoblje 2009. – 2013. godine, uočeno je kako nema značajnih oscilacija, izuzev 2011. godine, kada je prodajna cijena pšenice sa stabilne vrijednosti od oko 2 kn u prvih šest mjeseci, u razdoblju žetve, odnosno srpnju, pala na vrijednost od 0,66 kn (grafikon 3.).



Izvor: Ministarstvo poljoprivrede Republike Hrvatske (2013.)

Grafikon 3. Prikaz kretanja veleprodajnih cijena u Republici Hrvatskoj po mjesecima u razdoblju 2009.–2013.

U daljnjem razdoblju kolovoz–prosinac, izdvojene 2011. godine, cijena pšenice bila je stabilna, s vrijednošću cca 1,4 kn. Kretanja cijena u ostalim godinama trendovski su stabilna, bez značajnih odstupanja.

3.2. Terensko istraživanje segmenta proizvodnje pšenice

Osnovni podaci u istraživanju dobiveni su analizom upitnika, kojim su obuhvaćeni podaci o proizvodnji pšenice, gdje je statistički obrađeno 130 upitnika popunjenih od pojedinaca uposlenih u različitim tipovima i oblicima poslovanja u proizvodnji pšenice, na području pet županija istočne Hrvatske (slika 3.).



Izvor: https://commons.wikimedia.org/wiki/File:Croatia_location_map.svg (2014.)

Slika 3. Prikaz broja prikupljenih upitnika Proizvodnja pšenice, po županijama

3.2.1. Analiza prikupljenih podataka o proizvodnji pšenice (demografska obilježja)

Najveći broj ispitanika bio je iz Osječko-baranjske županije (67, odnosno 51,5%), a najmanji broj ispitanika iz Virovitičko-podravske županije (10 ili 14,9%), na području

Požesko-slavonske županije prikupljeno je i obrađeno 15 upitnika (11,5%), a broj popunjenih upitnika za Brodsko-posavsku i Vukovarsko-srijemsku županiju bio je identičan (19%, odnosno 14,6%).

Analizom kumulativnog postotka izraženog sukladno najvećem broju ispitanika (Osječko-baranjska županija (67 ili 100%), utvrđeno je kako je vrijednost kumulativa identična za Brodsko-posavsku i Vukovarsko srijemsku županiju i iznosi 28,4%, dok je najniža vrijednost kumulativa (14,9 %) utvrđena za Virovitičko-podravsku županiju (tablica 18.).

Tablica 18. Zastupljenost ispitanika po županijama

Županija	Broj ispitanika	%	Kumulativ
Brodsko-posavska	19	14,6	28,4
Osječko-baranjska	67	51,5	100,0
Požeško-slavonska	15	11,5	22,4
Virovitičko-podravska	10	7,7	14,9
Vukovarsko-srijemska	19	14,6	28,4

Obradom prikupljenih upitnika utvrđena je zastupljenost ispitanika prema mjestu obavljanja poslovanja. Od ukupnog broja ispitanika 28 ili 21,5% obavlja poslovanje vezano za proizvodnju pšenice na području grada, dok 102 ispitanika (78,5%) obavlja poslovanje na području sela.

Izraženo u kumulativnom postotku, za područje grada on iznosi 27,5%, što je i razumljivo jer je riječ o segmentu proizvodnje pšenice koji se najvećim dijelom obavlja u ruralnim područjima (kumulativ selo 100%) (tablica 19.).

Tablica 19. Zastupljenost ispitanika prema mjestu obavljanja poslovanja

Struktura mjesta poslovanja	Broj ispitanika	%	Kumulativ
Grad	28	21,5	27,5
Selo	102	78,5	100,0

Anketnim upitnikom utvrđena je i zastupljenost ispitanika prema obliku poslovanja, gdje je utvrđeno da najveći broj ispitanika (97 odnosno 74,6%) proizvodi pšenicu na obiteljskim poljoprivrednim gospodarstvima, dok najmanji broj ispitanika posluje u obliku dioničkog društva (samo 1 ili 0,8%). Od preostalih oblika poslovanja zastupljeni su u ispitanom

uzorku obrt s 23 ispitanika (17,7%), društvo s ograničenom odgovornošću sa 7 ispitanika (5,4%) i zadruga s 2 ispitanika (1,5%) (tablica 20.).

Tablica 20. Zastupljenost ispitanika prema obliku poslovanja

Oblik poslovanja subjekta	Broj ispitanika	%
OPG	97	74,6
ZADRUGA	2	1,5
D.O.O.	7	5,4
D.D.	1	0,8
OBRT	23	17,7

Prikupljenim podacima o zastupljenosti ispitanika po broju članova gospodarstva-poduzeća koji se bave proizvodnjom pšenice (ovisno o obliku poslovanja), utvrđeno je da najveći broj ispitanika 115 (88,5%), ovisno o obliku poslovanja, ima broj članova od 1-5, dok je najmanji broj ispitanika s većim brojem od 49 zaposlenih samo 1 (0,8%). Od 6 do 9 članova ima 7 ispitanika (5,4 %), 10-19 članova ima 3 ispitanika (2,3%), a 20-49 članova ima ukupno 4 ispitanika (3%). Obavljen je izračun broja ispitanika prema broju članova gospodarstva (poduzeća) (tablica 21.).

Tablica 21. Zastupljenost ispitanika po broju članova gospodarstva-poduzeća

Broj članova gospodarstva (poduzeća)	Broj ispitanika	%
1-5	115	88,5
6-9	7	5,4
10-19	3	2,3
20-49	4	3,0
> 49	1	0,8

Utvrđeno je kako najveći broj gospodarstava ima 1 do 5 članova (89 %), zatim 6 do 9 članova 5 %, 10 do 19 članova 2,3 %, 20 do 49 članova 3 % i više od 49 članova samo 0,8%.

3.2.2. Deskriptivni pokazatelji proizvodnje pšenice

U pripadajućim tablicama prikazani su rezultati deskriptivne statističke analize prema izdvojenim analiziranim područjima istraživanja.

3.2.2.1. Deskriptivna statistika ordinalnih varijabli tematskih područja stavova o proizvodnji pšenice

Rezultati provedenog istraživanja za prvih 26. pitanja upitnika stavova o proizvodnji pšenice podijeljeni su u četiri koncepta s pripadajućim tvrdnjama:

- makroekonomske tvrdnje,
- tehničko-tehnološke tvrdnje,
- tržišne tvrdnje,
- tvrdnje o koncepciji proizvodnje i međunarodnom okruženju.

Provedenom deskriptivnom statističkom analizom utvrđeno je slijedeće:

U tematskom području stavova o proizvodnji pšenice, odnosno izdvojenim makroekonomskim tvrdnjama, uočljivo je da najvišu vrijednost medijana (4) ima najbolje procijenjeni Potencijal poljoprivredne proizvodnje u RH.

Najniži ukupni raspon ima varijabla Utjecaj RH na produktivnost poljoprivredne proizvodnje, dok preostale varijable pokrivaju cijeli ukupni raspon procjena.

Najniže vrijednosti medijana (2) imaju varijable: Utjecaj RH na produktivnost poljoprivredne proizvodnje, Pozitivan utjecaj RH na razvoj poljoprivrede, Važeći propisi (Zakoni i Pravilnici) su primjenjivi za uspješno obavljanje proizvodnje pšenice te Utjecaj države pri reguliranju otkupa pšenice. Preostale varijable imaju vrijednost medijana 3. (tablica 22.).

Tablica 22. Deskriptivna statistika za ordinalne varijable tematskog područja stavova o proizvodnji pšenice - Makroekonomske tvrdnje

Varijabla	Medijan	Minimum	Maksimum	Raspon
Makroekonomske tvrdnje				
Utjecaj RH na produktivnost poljoprivredne proizvodnje	2	1	4	3
Pozitivan utjecaj RH na razvoj poljoprivrede	2	1	5	4
Važeći propisi (Zakoni i Pravilnici) primjenjivi su za uspješno obavljanje proizvodnje pšenice	2	1	5	4
Utjecaj države pri reguliranju otkupa pšenice	2	1	5	4
Utjecaj tržišta pri reguliranju otkupa pšenice	3	1	5	4
Utjecaj visine potpore na razinu proizvodnje pšenice	3	1	5	4
Potencijal poljoprivredne proizvodnje u RH	4	1	5	4
Pozitivnog sam mišljenja po pitanju razvoja hrvatske poljoprivrede u budućnosti	3	1	5	4

U tematskom području stavova o proizvodnji pšenice prema izdvojenim tehničko-tehnološkim tvrdnjama, razvidno je da najvišu vrijednost medijana (4) ima najbolje procijenjeni Agrotehnika proizvodnje pšenice na Vašem gospodarstvu.

Vrijednosti dobivene za ukupni raspon su identične (4) za sve tri navedene varijable: Tehnološka razinu strojeva koju primjenjujete u proizvodnji, Agrotehnika proizvodnje pšenice na Vašem gospodarstvu i Razina iskorištenja kapaciteta proizvodnje u Vašem gospodarstvu. Najniže vrijednost medijana (3) imaju varijable: Tehnološka razinu strojeva koju primjenjujete u proizvodnji i Razina iskorištenja kapaciteta proizvodnje u Vašem gospodarstvu (tablica 23.).

Tablica 23. Deskriptivna statistika za ordinalne varijable tematskog područja stavova o proizvodnji pšenice - Tehničko-tehnološke tvrdnje

Varijabla	Medijan	Minimum	Maksimum	Raspon
Tehničko-tehnološke tvrdnje				
Agrotehniku proizvodnje pšenice na Vašem gospodarstvu	4	1	5	4
Tehnološku razinu strojeva koju primjenjujete u proizvodnji	3	1	5	4
Razina iskorištenja kapaciteta proizvodnje u Vašem gospodarstvu	3	1	5	4

U tematskom području stavova o proizvodnji pšenice, obavljenom analizom tržišnih tvrdnji, uočljivo je kako najvišu vrijednost medijana (4) ima najbolje procijenjenu razinu kvalitete proizvedene pšenice u protekloj godini. Ukupni raspon je identičan (4) za sve četiri navedene varijable Razina kvalitete proizvedene pšenice u protekloj godini.

Razina poslovne suradnje s otkupljivačima pšenice, Ovisnost proizvodnje pšenice o utjecaju države i Prilagodljivost Vaše proizvodnje tržištu. Najniže vrijednosti medijana (3) imaju varijable: Razina poslovne suradnje s otkupljivačima pšenice, Ovisnost proizvodnje pšenice o utjecaju države i Prilagodljivost vaše proizvodnje tržištu (tablica 24.)

Tablica 24. Deskriptivna statistika za ordinalne varijable tematskog područja stavova o proizvodnji pšenice - Tržišne tvrdnje

Varijabla	Medijan	Minimum	Maksimum	Raspon
Tržišne tvrdnje				
Razina poslovne suradnje s otkupljivačima pšenice	3	1	5	4
Razina kvalitete proizvedene pšenice u protekloj godini	4	1	5	4
Ovisnost proizvodnje pšenice o utjecaju države	3	1	5	4
Prilagodljivost Vaše proizvodnje tržištu	3	1	5	4

U tematskom području stavova o proizvodnji pšenice, obavljenom analitikom tvrdnji o koncepciji proizvodnje i međunarodnom okruženju, uočljivo je da najvišu vrijednost medijana (4) ima najbolje procijenjeni upit Proizvodnja pšenice na Vašem gospodarstvu u protekloj godini.

Ukupni raspon je identičan (4) za sve navedene varijable:

Proizvodnja pšenice na Vašem gospodarstvu u protekloj godini, Razina prihoda od prodaje osnovnog proizvoda-pšenice, Razina otkupne cijene pšenice u protekloj godini, Razina povrata na ulaganja u proizvodnju pšenice u protekloj godini, Razina zadovoljavanja proizvodnih ciljeva u protekloj godini, Ukupni poslovni rezultat Vašeg gospodarstva u protekloj godini, Pozitivan utjecaj ulaska RH u EU na proizvodnju, Razina potpora i uvjeta za proizvodnju pšenice koji vladaju u EU, Spremnost Vašeg gospodarstva za ulazak u EU, Mogućnost prilagodbe Vašeg gospodarstva uvjetima koji vladaju u EU i Utjecaj ulaska u EU na budući razvoj Vašeg gospodarstva (tablica 25.).

Tablica 25. Deskriptivna statistika za ordinalne varijable tematskog područja stavova o proizvodnji pšenice - Konceptija proizvodnje i međunarodno okruženje

Varijabla	Medijan	Minimum	Maksimum	Raspon
Konceptija proizvodnje i međunarodno okruženje				
Proizvodnja pšenice na Vašem gospodarstvu u protekloj godini	4	1	5	4
Razina prihoda od prodaje osnovnog proizvoda-pšenice	3	1	5	4
Razina otkupne cijene pšenice u protekloj godini	3	1	5	4
Razina povrata na ulaganja u proizvodnju pšenice u protekloj godini	3	1	5	4
Razina zadovoljavanja proizvodnih ciljeva u protekloj godini	3	1	5	4
Ukupni poslovni rezultat Vašeg gospodarstva u protekloj godini	3	1	5	4
Pozitivan utjecaj ulaska RH u EU na proizvodnju	3	1	5	4
Razina potpora i uvjeta za proizvodnju pšenice koji vladaju u EU	3	1	5	4
Spremnost Vašeg gospodarstva za ulazak u EU	3	1	5	4
Mogućnost prilagodbe Vašeg gospodarstva uvjetima koji vladaju u EU	3	1	5	4
Utjecaj ulaska u EU na budući razvoj Vašeg gospodarstva	3	1	5	4

Najniže vrijednost medijana (3) imaju varijable: Razina prihoda od prodaje osnovnog proizvoda-pšenice, Razina otkupne cijene pšenice u protekloj godini, Razina povrata na ulaganja u proizvodnju pšenice u protekloj godini, Razina zadovoljavanja proizvodnih ciljeva u protekloj godini, Ukupni poslovni rezultat Vašeg gospodarstva u protekloj godini, Pozitivan utjecaj ulaska RH u EU na proizvodnju, Razina potpora i uvjeta za proizvodnju pšenice koji vladaju u EU, Spremnost Vašeg gospodarstva za ulazak u EU, Možnost prilagodbe Vašeg gospodarstva uvjetima koji vladaju u EU i varijabla Utjecaj ulaska u EU na budući razvoj Vašeg gospodarstva.

3.2.2.2. *Deskriptivna statistika kvantitativnih varijabli prikupljenih podataka o proizvodnji pšenice*

Uz varijable stavova o proizvodnji pšenice, izdvojene su socio-deomografske i konceptijske tvrdnje, odnosno 26 varijabli kod kojih je bilo moguće primijeniti parametrijske statističke metode.

Analizom varijabli o dobi članova subjekta poslovanja, dominira starosna dob od 41-60 godina, dok je najmanji broj ispitanika u dobi preko 80 godina života (tablica 26.).

Tablica 26. Broj članova subjekta poslovanja

Anketna pitanja	Frekvencija	Postotak
Starosna dob <20	6	5,82%
Starosna dob 21-40	13	12,61%
Starosna dob 41-60	75	72,75%
Starosna dob 61-80	2	2,06%
Starosna dob >80	1	0,97%
Ukupno	97	100%

Rezultati analize konceptijskih tvrdnji za izdvojenu varijablu koja opisuje vlasničku strukturu pokazuju kako je znatno veći udio zemljišta u privatnom vlasništvu u odnosu na zemljište za koje se plaća najam.

Analizom varijabli iznosa troškova uočljivo je da se najveći iznos sredstava troši za pribavljanje mineralnih gnojiva, zatim slijede troškovi održavanja vlastite mehanizacije, troškovi pribavljanja sjemenskog materijala, ostali troškovi (osiguranje, prijem, najam, manipulacija), troškovi pribavljanja sredstava za zaštitu bilja i da najmanje troškova iziskuje eventualni najam mehanizacije, a za potrebe proizvodnje pšenice u ispitanom uzorku (tablica 27.)

Tablica 27. Deskriptivna statistika za kvantitativne varijable vezane uz proizvodnju pšenice – Konceptijske tvrdnje


Anketna pitanja	Min.	Max.	Aritm. sredina	Std. Devijacija	Kolmogorov-Smirnov Z	Znač. (p)**
Broj hektara koje obrađuje Vaše gospodarstvo	5	19000	238,85	1678,134	5,205	,000
Iznos sredstava u kunama koje je Vaše gospodarstvo ostvarilo prijavom za projekte financirane od strane EU i Ministarstva poljoprivrede	0	5000000	64684,62	476820,6	5,551	,000
S obzirom na glavnu djelatnost koju obavljate, a to je poljoprivreda, koliki je godišnji %ni udio proizvodnje pšenice u vašem gospodarstvu	2	70	32	12,607	2,473	,000
Vlasničku strukturu nad zemljištem koje obrađujete – vlasništvo	0	100	59,2	32,256	1,487	,024
Vlasničku strukturu nad zemljištem koje obrađujete – najam	0	100	<i>41,13</i>	32,177	1,440	,032
Upišite broj konjskih snaga (KS), kojima raspolaže mehanizacija na Vašem gospodarstvu	0	2500	297,34	376,953	2,699	,000
Prosječan prinos pšenice izražen u tma/ha u protekloj godini	3	41398	653,19	5173,949	4,242	,000
Iznos troškova za sjeme pšenice u kunama/ha	0	7000	884,03	659,448	2,462	,000
Iznos troškova mineralnih gnojiva u kunama/ha za proizvodnju pšenice	0	6000	2057,2	1015,475	1,133	,153
Iznos troškova sredstava zaštite bilja u kunama/ha za proizvodnju pšenice	100	6000	731,12	580,113	2,438	,000
Iznos ostalih troškova (osiguranje, prijem, najam, manipulacija) pri proizvodnji pšenice	0	8000	738,77	871,604	2,779	,000
Iznos troškova vlastite mehanizacije u kunama/ha za proizvodnju pšenice	0	2500	917,85	557,852	1,437	,032
Iznos troškova najma mehanizacije u kunama/ha za proizvodnju pšenice	0	5000	305,47	654,82	3,888	,000

Legenda: *Italic – varijable s najvećim aritmetičkim sredinama među komparabilnim varijablama i varijable koje ne odstupaju značajno od Gaussove krivulje

Na kraju, prikazan je pregled deskriptivne statistike za varijable vezane uz tematska područja stavova proizvođača pšenice prema izdvojenim tvrdnjama, na temelju prosječnih vrijednosti za sve tvrdnje koje opisuju tematska područja stavova proizvođača pšenice (tablica 28. i grafikon 4.).

Tablica 28. Deskriptivna statistika za izvedene kvantitativne varijable vezane uz tematska područja stavova proizvođača pšenice

Anketna pitanja	Min.	Max.	Aritm. sredina	Std. devijacija	Kolmogorov-Smirnov Z	Znač. (p)**
Tehničko-tehnološke tvrdnje	1,00	5,00	3,3615	0,79948	1,150	0,142
Makroekonomske tvrdnje	1,00	5,00	2,4750	0,68684	1,439	0,032
Koncepcijske tvrdnje	1,00	5,00	2,9186	0,82997	0,814	0,521
Tržišne tvrdnje	1,00	5,00	3,0827	0,74928	1,209	0,108
Međunarodno okruženje	1,00	5,00	2,7600	0,83282	0,460	0,984



Grafikon 4. Prosječne vrijednosti (aritmetičke sredine i standardna raspršenja) za sve tvrdnje koje opisuju tematska područja stavova proizvođača pšenice

U grafikonu 4. prikazane su prosječne vrijednosti (aritmetičke sredine i standardna raspršenja) za sve tvrdnje koje opisuju pojedina tematska područja stavova proizvođača pšenice, definirane kao prosječni zbrojevi (ukupan zbroj procjena za tvrdnje unutar tablica

22.-25., podijeljen brojem tvrdnji koje opisuju pojedina područja stavova). U njima su još jasnije uočljivi prethodno opisani trendovi.

3.2.2.3. Analiza glavnih komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice - Makroekonomske tvrdnje

Sukladno zadanom postupku, provedena je analiza četiri koncepta tvrdnji za skupine varijabli tematskih područja stavova proizvođača pšenice: makroekonomske tvrdnje, tehničko-tehnološke tvrdnje, tržišne tvrdnje i međunarodno okruženje, kako bi se utvrdili ekonomski učinci poslovanja poslovnih subjekata na međunarodnom tržištu.

Vrijednosti KMO mjera adekvatnosti uzorka te Bartlettova testa sfericiteta (χ^2 značajan uz $p < 0,01$) pokazuju kako je matrica skupine varijabli pod nazivom Makroekonomske tvrdnje pogodna za faktorizaciju (tablica 29.).

Primjena analize glavnih komponenti (faktorske analize), uz primjenu Guttman-Kaiserova kriterija te Scree Plota, pokazala je da je za ovu skupinu varijabli najpogodnija dvokomponentna solucija pa su nakon varimax rotacije dobivene dvije glavne komponente, koje zajedno tumače 53,8% ukupne varijance.

Prvu glavnu komponentu definira šest varijabli, koje uglavnom govore o utjecaju države na razvoj poljoprivrede: nazvana je stoga Utjecaj države i pokazala je relativno visoku pouzdanost (Cronbachov alfa = 0,78). Drugu glavnu komponentu definira pet varijabli, koje uglavnom govore o potencijalima proizvodnje i regulativi: nazvana je stoga Potencijali proizvodnje i regulativa: ova komponenta pokazala je vrlo nisku, ali zadovoljavajuću pouzdanost (alfa = 0,51) (tablica 29.).

Tablica 29. Analiza komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice - Makroekonomske tvrdnje

Makroekonomske tvrdnje	Utjecaj države	Potencijali proizvodnje i regulativa	Komunalitet / Communalities
Ocijenite pozitivan utjecaj RH na razvoj poljoprivrede	0,898		0,815
Ocijenite utjecaj RH na produktivnost poljoprivredne proizvodnje	0,859		0,755
Ocijenite utjecaj države pri reguliranju otkupa pšenice	0,672		0,499
Ocijenite potencijal poljoprivredne proizvodnje u RH		0,817	0,706
Pozitivnog sam mišljenja po pitanju razvoja hrvatske poljoprivrede u budućnosti		0,688	0,509
Ocijenite utjecaj visine potpore na razinu proizvodnje pšenice	0,428	0,547	0,482
Ocijenite utjecaj tržišta pri reguliranju otkupa pšenice	0,320	0,469	0,323
Važeći propisi (Zakoni i Pravilnici), su primjenjivi za uspješno obavljanje proizvodnje pšenice		0,432	0,215
Objašnjena varijanca (%)	29,817	23,393	
Karakteristični korijen	2,385	1,919	
Pouzdanost (Cronbachov alfa koeficijent)/	0,782	0,508	
KMO mjera adekvatnosti uzorka	0,739		
Bartlettov test sfericiteta (χ^2)	259,126**		

3.2.2.4. Analiza glavnih komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice - Tehničko-tehnološke tvrdnje

Matrica skupine varijabli koje se odnose na analizirane tehničko-tehnološke tvrdnje je pokazala pogodnost za faktorizaciju, na temelju dobivene vrijednosti KMO mjere adekvatnosti uzorka te Bartlettova testa sfericiteta (χ^2 značajan uz $p < 0,01$).

Primjena analize glavnih komponenti (faktorske analize) uz primjenu Guttman-Kaiserova kriterija te Scree Plota pokazala se kao najpogodnija solucija za navedenu skupinu varijabli jednokomponentna, koja tumači 72,8% od ukupne varijance.

Izdvojena glavna komponenta definirana je kroz tri varijable koje pojašnjavaju razinu primijenjene agrotehnike, upotrijebljene mehanizacije i kapacitete proizvodnje na anketiranim gospodarstvima. Dobivena pouzdanost je relativno visoka i iznosi 0,81. (tablica 30.)

Tablica 30. Analiza komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice - Tehničko-tehnološke tvrdnje

Tehničko-tehnološke tvrdnje	Tehnologija proizvodnje	Komunalitet /Communalities
Agrotehniku proizvodnje pšenice na Vašem gospodarstvu	0,874	0,765
Tehnološku razinu strojeva koju primjenjujete u proizvodnji	0,890	0,792
Razina iskorištenja kapaciteta proizvodnje u Vašem gospodarstvu	0,791	0,626
Objašnjena varijanca (%)	72,752	
Karakteristični korijen	2,183	
Pouzdanost (Cronbachov alfa koeficijent)/	0,812	
KMO mjera adekvatnosti uzorka	0,684	
Bartlettov test sfericiteta (χ^2)	139,454**	

3.2.2.5. Analiza glavnih komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice – Tržišne tvrdnje

Matrica skupine varijabli tematskog područja stavova proizvođača pšenice, odnosno tržišnih tvrdnji, pokazale su se pogodnim za faktorizaciju. Dobivenom vrijednosti KMO mjera adekvatnosti uzorka te Bartlettova testa sfericiteta (χ^2 je značajan uz $p < 0,01$). Primjena analize glavnih komponenti (faktorske analize), uz primjenu Guttman-Kaiserova kriterija te Scree Plota, pokazala je kako je najpogodnija solucija za navedenu skupinu varijabli jednokomponentna, odnosno kako izdvojena komponenta tumači 50,9% od ukupne varijance. Izdvojena glavna komponenta definirana je kroz četiri varijable koje objedinjuju podatke o otkupljivačima, kvaliteti, utjecaju države i tržišta na anketiranim gospodarstvima. Dobiveni koeficijent za pouzdanost pokazuje da je isti relativno nizak, ali zadovoljavajuć i iznosi 0,67 (tablica 31.).

Tablica 31. Analiza komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice – Tržišne tvrdnje

Tržišne tvrdnje	Koeficijent (1)	Komunalitet/ Communalities
Razina poslovne suradnje s otkupljivačima pšenice	0,756	0,571
Razina kvalitete proizvedene pšenice u protekloj godini	0,644	0,415
Ovisnost proizvodnje pšenice o utjecaju države	0,725	0,525
Prilagodljivost Vaše proizvodnje tržištu	0,725	0,526
Objašnjena varijanca (%)	50,920	
Karakteristični korijen	2,037	
Pouzdanost (Cronbachov alfa koeficijent)/	0,678	
KMO mjera adekvatnosti uzorka	0,722	
Bartlettov test sfericiteta (χ^2)	74,396**	

3.2.2.6. Analiza glavnih komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice – Konceptijske tvrdnje i međunarodno okruženje

Vrijednosti KMO mjera adekvatnosti uzorka te Bartlettova testa sfericiteta (χ^2 značajan uz $p < 0,01$) pokazuju kako je matrica skupine varijabli tematskog područja stavova proizvođača pšenice pod nazivom Konceptijske tvrdnje i međunarodno okruženje (tablica 32.).

Primjena analize glavnih komponenti (faktorske analize), uz primjenu Guttman-Kaiserova kriterija te Scree Plota, pokazala je da je najpogodnija solucija za ovu skupinu varijabli dvokomponentna pa su nakon varimax rotacije dobivene dvije glavne komponente, koje zajedno tumače 61,6% ukupne varijance.

Prvu glavnu komponentu definira pet varijabli, konceptijskih tvrdnji, koje uglavnom govore o prihodima koje gospodarstvo-tvrtka ostvaruje proizvodnjom pšenice i pokazala je visoku pouzdanost (alfa = 0,86).

Drugu glavnu komponentu definira pet varijabli, kojima su prikazana razina očekivanja gospodarstva koja se bave proizvodnjom pšenice, a vezano na uvjete koje vladaju na tržištu

Europske Unije, odnosno utjecaj međunarodnog okruženja. Ova komponenta je pokazala također visoku pouzdanost (alfa= 0,84).

Tablica 32. Analiza glavnih komponenti za skupinu varijabli tematskog područja stavova proizvođača pšenice - Konceptijske tvrdnje i međunarodno okruženje

Konceptijske tvrdnje i međunarodno okruženje	Prihod od pšenice	Utjecaj i uvjeti u EU	Komunalitet / Communalities
Proizvodnja pšenice na Vašem gospodarstvu u protekloj godini	0,573		0,385
Razina prihoda od prodaje osnovnog proizvoda-pšenice	0,848		0,757
Razina otkupne cijene pšenice u protekloj godini	0,623		0,392
Razina povrata na ulaganja u proizvodnju pšenice u protekloj godini	0,844		0,761
Razina zadovoljavanja proizvodnih ciljeva u protekloj godini	0,784	0,343	0,732
Ukupni poslovni rezultat Vašeg gospodarstva u protekloj godini	0,715	0,364	0,644
Pozitivan utjecaj ulaska RH u EU, na proizvodnju	0,319	0,596	0,457
Razina potpora i uvjeta za proizvodnju pšenice koji vladaju u EU		0,683	0,516
Spremnost Vašeg gospodarstva za ulazak u EU	0,314	0,792	0,727
Mogućnost prilagodbe Vašeg gospodarstva uvjetima koji vladaju u EU		0,816	0,717
Utjecaj ulaska u EU na budući razvoj Vašeg gospodarstva		0,825	0,686
Objašnjena varijanca (%)	32,541	29,040	
Karakteristični korijen	3,579	3,194	
Pouzdanost (Cronbachov alfa koeficijent)/	0,858	0,841	
KMO mjera adekvatnosti uzorka	0,851		
Bartlettov test sfericiteta (χ^2)	743,632**		

3.2.3. Razlike između županija u područjima stavova o proizvodnji pšenice

Pronađene su tri statistički značajne razlike među županijama u odnosu na ponuđene tvrdnje područja stavova o proizvodnji pšenice:

- Tehnologija proizvodnje-gospodarstvo (najveći prosječni rezultat za Osječko-baranjsku županiju, a najniži za Brodsko-posavsku),

- Utjecaj države na proizvodnju i otkup pšenice (najveći prosječni rezultat za Brodsko-posavsku županiju, a najniži za Vukovarsko-srijemsku),
- Prihod od pšenice (najveći prosječni rezultat za Osječko-baranjsku županiju, a najniži za Virovitičko-podravsku) (Tablica 33.).

Tablica 33. Analiza razlika između županija u područjima stavova o proizvodnji pšenice

Varijable	Županija	N	Aritm. Sredina	Std. devijacija	Kruskal-Wallis test (p)
Tehnologija proizvodnje-gospodarstvo	Os-bar	67	3,5113	0,59565	0,042*
	Vu-sri	19	3,4511	0,67323	
	Br-pos	19	2,9298	0,95309	
	Pž-sla	15	3,4667	0,76428	
	Vt-pod	10	3,3333	0,64788	
Utjecaj države na proizvodnju i otkup	Os-bar	67	3,3615	0,79948	0,001**
	Vu-sri	19	2,5690	0,57706	
	Br-pos	19	2,2237	0,74370	
	Pž-sla	15	2,6974	0,78541	
	Vt-pod	10	2,2917	0,98046	
Potencijali proizvodnje i regulativa	Os-bar	67	2,1750	0,15811	0,344
	Vu-sri	19	2,4750	0,68684	
	Br-pos	19	3,1754	0,74368	
	Pž-sla	15	2,6974	0,88811	
	Vt-pod	10	3,3421	0,73697	
Otkup pšenice	Os-bar	67	3,0333	0,59662	0,052
	Vu-sri	19	2,7750	0,38097	
	Br-pos	19	3,0827	0,74928	
	Pž-sla	15	3,0995	0,68661	
	Vt-pod	10	2,6228	1,13017	
Prihod od pšenice	Os-bar	67	3,1667	0,79623	0,017*
	Vu-sri	19	2,5778	0,89723	
	Br-pos	18	2,3333	0,45812	
	Pž-sla	15	2,9186	0,82997	
	Vt-pod	10	2,8388	0,69652	
Utjecaj i uvjeti u EU	Os-bar	67	2,2947	0,88786	0,060
	Vu-sri	19	3,2211	1,03041	
	Br-pos	18	2,6400	0,91402	
	Pž-sla	15	2,4200	0,52873	
	Vt-pod	10	2,7600	0,83282	

Legenda: *razlika statistički značajna uz $p < 0,05$; **razlika statistički značajna uz $p < 0,01$;

3.2.4. Povezanost između područja stavova o proizvodnji pšenice

Provedenom analizom utvrđeno je da postoji relativno niska pozitivna povezanost između različitih izdvojenih područja stavova o proizvodnji pšenice (tablica 34.).

Tablica 34. Analiza povezanosti između područja stavova o proizvodnji pšenice

Varijable	Tehnologija proizvodnje-gospodarstvo	Utjecaj države na proizvodnju i otkup	Potencijali proizvodnje i regulativa	Otkup pšenice	Prihod od pšenice	Utjecaj i uvjeti u EU
Tehnologija proizvodnje-gospodarstvo	1,000	0,037	0,211*	0,449**	0,378**	0,329**
Utjecaj države na proizvodnju i otkup		1,000	-,010	0,270**	0,402**	0,232**
Potencijali proizvodnje i regulativa			1,000	0,354**	0,188*	0,410**
Otkup pšenice				1,000	0,577**	0,435**
Prihod od pšenice					1,000	0,045
Utjecaj i uvjeti u EU						1,000

Legenda: *korelacija statistički značajna uz $p < 0,05$; **korelacija statistički značajna uz $p < 0,01$, (Spearmanovi koeficijenti korelacije)

Najviše vrijednosti korelacija pronađene su između varijabli stavova Prihoda od pšenice i Otkupa pšenice, Otkupa pšenice i Tehnologije proizvodnje-gospodarstvo, kao i Otkupa pšenice i Utjecaja i uvjeta u EU.

Najniže vrijednosti korelacije pronađene su između varijabli Tehnologije proizvodnje-gospodarstvo i Utjecaja države na proizvodnju i otkup pšenice te Utjecaja i uvjeta u EU i Prihoda od pšenice.

3.2.5. Razlike između županija u varijablama vezanim uz proizvodnju pšenice

Među odabranim varijablama vezanim uz proizvodnju pšenice, vezane na izdvojene tržišne (tablica 35.) i konceptijske tvrdnje (tablica 36.), statistički značajne razlike u odnosu na županiju pronađene su samo kod četiri varijable.

Tablica 35. Analiza razlika između županija u varijablama vezanim uz proizvodnju pšenice (Tržišne tvrdnje)

Varijable	Županija	N	Aritm. sredina	Std. devijacija	ANOVA (p)
Iznos troškova za sjeme pšenice u kunama/ha	Os-bar	67	879,46	798,990	0,142
	Vu-sri	19	844,74	147,097	
	Br-pos	19	652,63	367,602	
	Pž-sla	15	1243,33	707,830	
	Vt-pod	10	890,00	356,526	
Iznos troškova mineralnih gnojiva u kunama/ha za proizvodnju pšenice	Os-bar	67	1788,45	949,243	0,000**
	Vu-sri	19	2826,32	640,175	
	Br-pos	19	1521,05	859,314	
	Pž-sla	15	2954,00	1127,524	
	Vt-pod	10	2070,00	405,654	
Iznos troškova sredstava zaštite bilja u kunama/ha za proizvodnju pšenice	Os-bar	67	695,91	716,089	0,284
	Vu-sri	19	813,16	248,239	
	Br-pos	19	642,11	219,661	
	Pž-sla	15	1001,33	634,394	
	Vt-pod	10	575,00	168,737	
Iznos ostalih troškova (osiguranje, prijem, najam, manipulacija) pri proizvodnji pšenice	Os-bar	67	816,27	1050,019	0,449
	Vu-sri	19	534,21	230,972	
	Br-pos	19	560,53	590,334	
	Pž-sla	15	973,33	1022,753	
	Vt-pod	10	595,00	240,890	
Iznos troškova vlastite mehanizacije u kunama/ha za proizvodnju pšenice	Os-bar	67	975,37	584,223	0,207
	Vu-sri	19	938,42	599,113	
	Br-pos	19	712,63	334,794	
	Pž-sla	15	1050,00	661,438	
	Vt-pod	10	685,00	362,131	
Iznos troškova najma mehanizacije u kunama/ha za proizvodnju pšenice (eventualno)	Os-bar	67	347,01	628,845	0,046
	Vu-sri	19	131,58	276,993	
	Br-pos	17	20,59	84,887	
	Pž-sla	15	673,33	1254,402	
	Vt-pod	10	290,00	284,605	

Tablica 36. Analiza razlika između županija u varijablama vezanim uz proizvodnju pšenice (Konceptijske tvrdnje)

Varijable	Županija	N	Aritm. sredina	Std. devijacija	ANOVA (p)
Broj hektara koje obrađuje Vaše gospodarstvo	Os-bar	67	416,37	2331,101	0,822
	Vu-sri	19	71,21	107,303	
	Br-pos	19	53,32	44,203	
	Pž-sla	15	24,53	27,813	
	Vt-pod	10	42,00	26,055	
Iznos sredstava u kunama koje je Vaše gospodarstvo ostvarilo prijavom za projekte financirane od strane EU i Ministarstva poljoprivrede	Os-bar	67	125388,06	660803,527	0,698
	Vu-sri	19	0,00	0,000	
	Br-pos	19	0,00	0,000	
	Pž-sla	15	533,33	2065,591	
	Vt-pod	10	0,00	,000	
Obzirom na glavnu djelatnost koju obavljate a to je poljoprivreda, koliki je godišnji %ni udio proizvodnje pšenice u vašem gospodarstvu	Os-bar	67	32,36	12,049	0,566
	Vu-sri	19	33,16	13,865	
	Br-pos	19	28,26	17,694	
	Pž-sla	15	35,00	9,449	
	Vt-pod	10	30,00	3,333	
Vlasničku strukturu nad zemljištem koje obrađujete – vlasništvo	Os-bar	65	61,31	31,713	0,026*
	Vu-sri	19	57,26	36,751	
	Br-pos	19	51,79	33,753	
	Pž-sla	15	77,00	27,111	
	Vt-pod	10	36,50	12,259	
Vlasničku strukturu nad zemljištem koje obrađujete – najam	Os-bar	64	39,30	31,584	0,027*
	Vu-sri	19	42,74	36,751	
	Br-pos	19	48,21	33,753	
	Pž-sla	15	23,00	27,111	
	Vt-pod	10	63,50	12,259	
Upišite broj konjskih snaga (KS), kojima raspolaže mehanizacija na Vašem gospodarstvu	Os-bar	67	338,09	398,884	0,363
	Vu-sri	18	340,00	578,741	
	Br-pos	19	287,63	252,473	
	Pž-sla	15	134,67	88,791	
	Vt-pod	10	210,00	113,554	
Prosječan prinos pšenice izražen u tma/ha u protekloj godini	Os-bar	35	5,73	1,291	0,477
	Vu-sri	5	6,20	0,837	
	Br-pos	14	2965,46	11061,653	
	Pž-sla	5	6,20	1,789	
	Vt-pod	5	5,00	1,225	

Legenda: *razlika statistički značajna uz $p < 0,05$

Varijable s statistički značajnim razlikama u odnosu na izdvojene županije:

- iznos troškova mineralnih gnojiva u kn/ha za proizvodnju pšenice (najveći prosječni rezultat za Požeško-slavonsku županiju, a najniži za Brodsko-posavsku županiju), (tablica 35.),
- iznos troškova najma mehanizacije u kn/ha za proizvodnju pšenice (eventualno) (najveći prosječni rezultat za Požeško-slavonsku županiju, a najniži za Brodsko-posavsku županiju). (tablica 35.),
- vlasničku strukturu nad zemljištem koje obrađujete – vlasništvo (najveći prosječni rezultat za Požeško-slavonsku županiju, a najniži za Virovitičko-podravsku), vlasničku strukturu nad zemljištem koje obrađujete – najam (najveći prosječni rezultat za Virovitičko-podravsku, a najniži za Osječko-baranjsku županiju), (tablica 36.).

3.2.6. Razlike između OPG-a i obrta u područjima stavova o proizvodnji pšenice

Provedenom analizom je utvrđeno da niti jedna vrijednost t-testa nije statistički značajna pa se može utvrditi kako nema statistički značajnih razlika u područjima stavova o proizvodnji pšenice između OPG-a i obrta (tablica 37.).


Tablica 37. Analiza razlika OPG-a i obrta u područjima stavova o proizvodnji pšenice

Varijable	Oblik poslovanja	N	Aritm. sredina	Std. devijacija	t-test
Tehnologija proizvodnje-gospodarstvo	OPG	97	3,3402	0,71359	0,856
	Obrt	23	3,1449	1,01417	
Utjecaj države na proizvodnju i otkup	OPG	97	2,5013	0,69374	1,236
	Obrt	23	2,2609	0,68040	
Potencijali proizvodnje i regulativa	OPG	97	3,1289	0,62823	,476
	Obrt	23	2,7826	1,07213	
Otkup pšenice	OPG	97	2,9601	0,76117	1,488
	Obrt	23	2,6232	1,04110	
Prihod od pšenice	OPG	96	2,9214	0,77068	1,539
	Obrt	23	2,2412	1,03218	
Utjecaj i uvjeti u EU	OPG	96	2,7814	0,71068	0,990
	Obrt	23	2,4609	1,24818	

3.3. Terensko istraživanje segmenta prerada pšenice

Osnovni podaci koji su prikupljeni u istraživanju dobiveni su analizom upitnika konstruiranim s ciljem prikupljanja podataka o preradi pšenice na izdvojenom području istočne Hrvatske (4 županije: Brodsko-posavska, Osječko-baranjska, Požeško-slavonska i Virovitičko-podravska županija) (slika 4.).

Upitnikom su prikupljeni i statistički obrađeni podaci koji su stručne osobe, uposlenici mlinova različitih preradbenih kapaciteta, priložili popunjavanjem upitnika. Ukupno je prikupljeno i statistički obrađeno 18 upitnika koji se odnose na isto toliko mlinova različitih prerađivačkih kapaciteta s naglaskom na veće.



Izvor: https://commons.wikimedia.org/wiki/File:Croatia_location_map.svg (2014.)

Slika 4. Prikaz mjesta prikupljanja podataka za upitnik Prerada pšenice, po županijama

Cilj izdvojenog dijela istraživanja je bio anketom prikupiti podatke o činjeničnom stanju, uvjetima proizvodnje i prodaje, a zbog sagledavanja konkurentne pozicije izdvojenog sektora na tržištu Republike Hrvatske i jedinstvenom tržištu Europske Unije

3.3.1. Deskriptivni pokazatelji prerade pšenice

U pripadajućim tablicama prikazani su dobiveni rezultati deskriptivnih obilježja ordinalnih (tvrdnje o preradi pšenice) varijabli, prikupljenih podataka o preradi pšenice: makroekonomske, tehničko-tehnološke, tržišne, koncepcijske i tvrdnje o međunarodnom okruženju.

3.3.1.1. Deskriptivna obilježja za skupine ordinalnih varijabli po pojedinim tematskim područjima stavova o preradi pšenice

U tematskom području stavova o preradi pšenice Makroekonomske tvrdnje, uočljivo je kako najvišu vrijednost medijana (5) ima RH ima preveliku birokraciju, a najniže vrijednost medijana (2) imaju varijable: Ocijenite utjecaj RH na produktivnost poslovanja poduzetnika i Ocijenite razinu uporabe obnovljivih izvora energije u Vašem poduzeću. Najniži ukupni raspon (2) imaju varijable Ocijenite utjecaj RH na produktivnost poslovanja poduzetnika i Ocijenite pozitivan utjecaj RH na razvoj prehrambene industrije, dok je najveći ukupni raspon (4) uočen pri varijabli RH ima preveliku birokraciju (tablica 38.).

U tematskom području stavova o preradi pšenice Tehničko-tehnološke tvrdnje, razvidno je kako najvišu vrijednost medijana (4) imaju varijable Ocijenite razinu iskorištenja kapaciteta proizvodnje u Vašem poduzeću i varijabla Ocijenite potrebu uvođenja novih tehnologija u Vašem poduzeću. Najniže vrijednost medijana (3) imaju preostalih sedam varijabli.

Tablica 38. Deskriptivna statistika za ordinalne varijable tematskih područja stavova o preradi pšenice - Makroekonomske tvrdnje

Varijabla	Medijan	Min.	Max.	Raspon
Makroekonomske tvrdnje				
Ocijenite utjecaj RH na produktivnost poslovanja poduzetnika	2	2	4	2
Ocijenite pozitivan utjecaj RH na razvoj prehrambene industrije	2,5	2	4	2
Važeći propisi (Zakoni i Pravilnici), su primjenjivi za uspješno obavljanje poslovanja	3	1	5	4
RH ima preveliku birokraciju	5	1	5	4
Potrošači u RH radije kupuju robu domaćih proizvođača	3,5	2	5	3
Ocijenite utjecaj države pri reguliranju sektora prerade pšenice	3	1	5	4
Ocijenite utjecaj tržišta pri reguliranju sektora prerade pšenice	3	2	5	3
Ocijenite utjecaj korupcije na razvoj sektora prerade pšenice	3	1	5	4
Ocijenite razinu uporabe obnovljivih izvora energije u Vašem poduzeću	2	1	4	3

Najniže vrijednosti ukupnog raspona (3) imaju varijable Ocijenite mogućnost poboljšanja tehnološke razine proizvodnje u narednom razdoblju (cca 5 godina) i varijabla Pozitivnog sam mišljenja po pitanju razvoja domaće mlinske industrije u budućnosti, preostale vrijednosti za ukupni raspon su identične (4) (tablica 39.).

Tablica 39. Deskriptivna statistika za ordinalne varijable u tematskom području stavova o preradi pšenice - Tehničko-tehnološke tvrdnje

Varijabla	Medijan	Min.	Max.	Raspon
Tehničko-tehnološke tvrdnje				
Ocijenite tržišnu konkurentnost domaće mlinske industrije	3	1	5	4
Ocijenite tehnološku razinu strojeva koju primjenjujete u proizvodnji	3	1	5	4
Ocijenite razinu iskorištenja kapaciteta proizvodnje u Vašem poduzeću	4	1	5	4
Ocijenite potrebu uvođenja novih tehnologija u Vašem poduzeću	4	1	5	4
Ocijenite mogućnost poboljšanja tehnološke razine proizvodnje u narednom razdoblju (cca 5. godina)	3	2	5	3
Ocijenite potencijal mlinske industrije u RH	3	1	5	4
Pozitivnog sam mišljenja po pitanju razvoja domaće mlinske industrije u budućnosti	3	2	5	3
Ocijenite kapacitete prerade pšenice u RH u odnosu na susjedne države	3	1	5	4
Ocijenite utjecaj domaćih makroekonomskih trendova na razvoj sektora prerade pšenice	3	1	5	4

U tematskom području stavova o preradi pšenice izdvojenog naziva Tržišne tvrdnje, uočeno je da najvišu vrijednost medijana (4) imaju varijable s većim brojem proizvođača pšenice surađujemo dugi niz god. i Ocijenite brojnost konkurenata na tržištu, najniže vrijednosti medijana (2) imaju varijable Ocijenite razinu suradnje s trgovačkim mrežama-lancima i Ocijenite mogućnost ulaska gotovih proizvoda u trgovačke lance.

Analizom dobivenih vrijednosti za ukupni raspon vidljivo je kako je najniža vrijednost (3) utvrđena kod pet varijabli, a najviša (4) kod osam varijabli (tablica 40.).

Tablica 40. Deskriptivna statistika za ordinalne varijable u tematskom području stavova o preradi pšenice - Tržišne tvrdnje

Varijabla	Medijan	Min.	Max.	Raspon
Tržišne tvrdnje				
S većim brojem proizvođača pšenice surađujemo dugi niz god.	4	2	5	3
Ocijenite razinu poslovne suradnje (proizvođači-prerađivači) pšenice	3,5	2	5	3
Ocijenite prosječnu razinu kvalitete pšenice (sirovine) koji se koristi u proizvodnji	3	1	5	4
Ocijenite prodajne rezultate Vaših finalnih proizvoda	3,5	1	5	4
Ocijenite razinurazinu suradnje s trgovačkim mrežama-lancima	2	1	5	4
Ocijenite mogućnost ulaska gotovih proizvoda u trgovačke lance	2	1	4	3
Ocijenite ovisnost proizvodnje o utjecaju trgovačkih mreža	3	1	5	4
Ocijenite uvjetovane prodajne zahtjeve trgovačkih mreža	3	1	5	4
Ocijenite prilagodljivost Vaše proizvodnje tržištu	3,5	1	4	3
Ocijenite brojnost konkurenata na tržištu	4	1	5	4
Ocijenite poslovne odnose s konkurencijom	3	1	5	4
Ocijenite poslovnu korektnost konkurentskih poduzeća	3	1	5	4
Ocijenite analitičko praćenje slabosti i snage konkurencije	3	1	4	3

U tematskom području stavova o preradi pšenice naziva Konceptijske tvrdnje, uočeno je kako najvišu vrijednost medijana (4) imaju varijable Ocijenite razinu zadržavanja postojećih poslovnih partnera (proizvođača pšenice, trgovačkih mreža), Ocijenite razinu

kvalitete Vaših proizvoda u odnosu na konkurenciju i varijabla Ocijenite vjernost krajnjih potrošača Vašim finalnim proizvodima, najnižu vrijednost medijana (1,5) ima varijabla Ocijenite razinu sudjelovanja Vašeg poduzeća na međunarodnim tematskim sajmovima izvan RH. Najnižu vrijednost ukupnog raspona (2) ima varijabla Ocijenite razinu sudjelovanja Vašeg poduzeća na međunarodnim tematskim sajmovima izvan RH, najviša uočena vrijednost za raspon je (4), istu imaju jedanaest varijabli (tablica 41.).

Tablica 41. Deskriptivna statistika za ordinalne varijable u tematskom području stavova o preradi pšenice - Konceptijske tvrdnje

Varijabla	Medijan	Min.	Max.	Raspon
Koncepcijske tvrdnje				
Ocijenite povećanje tržišnog udjela Vašeg poduzeća u protekloj godini	3	1	5	4
Ocijenite razinu prodaje u protekloj godini	3	1	5	4
Ocijenite razinu povrata na ulaganja u protekloj godini	3	1	5	4
Ocijenite razinu zadovoljavanja prodajnih ciljeva vašeg poduzeća u protekloj godini	3	1	4	3
Ocijenite financijsko poslovanje u protekloj godini	3	1	5	4
Ocijenite ukupni poslovni rezultat u protekloj godini	3	1	5	4
Ocijenite razinu zadržavanja postojećih poslovnih partnera (proizvođača pšenice, trgovačkih mreža)	4	1	5	4
Ocijenite razinu kvalitete Vaših proizvoda u odnosu na konkurenciju	4	1	5	4
Ocijenite vjernost krajnjih potrošača Vašim finalnim proizvodima	4	1	5	4
Ocijenite razvoj novih proizvoda u odnosu na konkurenciju	3	1	4	3
Ocijenite razinu fluktuacije zaposlenika u vašem poduzeću	3	1	5	4
Ocijenite neto profitnu stopu Vašeg poduzeća u odnosu na konkurenciju	3	1	5	4

U tematskom području stavova o preradi pšenice naziva Međunarodno okruženje, utvrđeno je kako najveću vrijednost medijana (3) imaju varijable Ocijenite pozitivan utjecaj ulaska RH u EU, na sektor prerade pšenice, Ocijenite razinu poznavanja tržišta brašna i uvjeta koji vladaju na tržištu EU, Ocijenite spremnost Vašeg poduzeća za ulazak na tržište EU, Ocijenite mogućnost prilagodbe Vašeg poduzeća uvjetima koji vladaju na EU tržištu i Ocijenite utjecaj ulaska u EU na budući razvoj Vašeg poduzeća. Najnižu vrijednost medijana (1,5), ima varijabla Ocijenite razinu sudjelovanja Vašeg poduzeća na međunarodnim tematskim sajmovima izvan Republike Hrvatske, navedena varijabla ima i najnižu uočenu vrijednost ukupnog raspona (2).

Najvišu vrijednost za ukupni raspon (4), ima varijabla Ocijenite razinu sudjelovanja Vašeg poduzeća na međunarodnim tematskim sajmovima u Republici Hrvatskoj (tablica 42.).

Tablica 42. Deskriptivna statistika za ordinalne varijable u tematskom području stavova o preradi pšenice Međunarodno okruženje

Varijabla	Medijan	Min.	Max.	Raspon
Međunarodno okruženje				
Ocijenite razinu sudjelovanja Vašeg poduzeća na međunarodnim tematskim sajmovima izvan RH	1,5	1	3	2
Ocijenite razinu sudjelovanja Vašeg poduzeća na međunarodnim tematskim sajmovima u RH	2	1	5	4
Ocijenite pozitivan utjecaj ulaska RH u EU, na sektor prerade pšenice	3	1	4	3
Ocijenite razinu poznavanja tržišta brašna i uvjeta koji vladaju na tržištu EU	3	1	4	3
Ocijenite spremnost Vašeg poduzeća za ulazak na tržište EU	3	1	4	3
Ocijenite mogućnost prilagodbe Vašeg poduzeća uvjetima koji vladaju na EU tržištu	3	1	4	3
Ocijenite utjecaj ulaska u EU na budući razvoj Vašeg poduzeća	3	1	4	3

Legenda: M=medijan; SD= standardna devijacija; osjenčane su čestice s najvećim vrijednostima medijana

3.3.1.2. Deskriptivna obilježja za skupinu kvantitativnih varijabli prerade pšenice

U segmentu prerade pšenice, posebno su analizirane 22 varijable kod kojih je bilo moguće primijeniti parametrijske statističke metode.

Primjenom Kolmogorov-Smirnov Z-testa (testiranjem značajnosti odstupanja od Gaussove krivulje), utvrđeno je kako distribucija rezultata za većinu varijabli statistički značajno odstupa od Gaussove krivulje pa su se u analizi podataka koristile neparametrijske statističke metode.

Uočljivo je kako se analizom varijabli o podrijetlu mlinskih proizvoda u istraženom uzorku utvrđeno kako su najzastupljeniji proizvodi od pšenice (u usporedbi s kukuruzom i heljdom) (tablica 43.).

Tablica 43. Deskriptivna statistika za kvantitativne varijable vezane uz preradu pšenice – Sirovina

Anketna pitanja	Min.	Max.	Aritm. sredina	Std. devijacija	Kolmogorov-Smirnov Z	Znač. (p)**
Mlinski proizvodi od pšenice	99	100	99,87	,352	1,992	,000
Mlinski proizvodi od kukuruza	0	1	,13	,352	1,992	,000
Mlinski proizvodi od heljde	0	3	,18	,728	2,214	,000

Nadalje, varijabla koja opisuje tipove brašna temeljem tržišnog udjela, ukazuje kako se najviše proizvodi Bijelo brašno (tip 400 i tip 550), zatim polubijelo brašno (tip 700 i tip 850), dok najmanji udjel u proizvodnji ima brašno iz cijelog zrna (integralno). Proizvodnja brašna i krupice iz durum pšenice nije zabilježena u ispitanom uzorku (tablica 44.).

Tablica 44. Deskriptivna statistika za kvantitativne varijable vezane uz preradu pšenice – Tržišni udio i tipovi brašna

Anketna pitanja	Min.	Max.	Aritm. sredina	Std. devijacija	Kolmogorov-Smirnov Z	Znač. (p)**
Tržišni udio	0	20	6,88	7,586	0,630	0,823
<i>Krupica (tip 400)</i>	0	50	3,93	13,275	1,820	0,003
<i>Bijelo brašno (tip 400 i tip 550)</i>	0	89	57,76	20,101	0,957	0,320
<i>Polubijelo brašno (tip 700 i tip 850)</i>	0	65	24,18	15,629	0,556	0,917
<i>Crno brašno (tip 1100 i tip 1600)</i>	0	20	3,27	6,442	1,655	0,008
<i>Prekrupa</i>	0	22	1,47	5,340	2,024	0,001
<i>Brašno iz cijelog zrna (integralno)</i>	0	22	2,56	5,887	1,673	0,007
<i>Prekrupa iz cijelog zrna (integralna)</i>	0	4	,29	1,069	1,998	0,001
<i>Krupica iz durum pšenice</i>	0	0	,00	,000	-	-
<i>Brašno iz durum pšenice</i>	0	0	,00	,000	-	-

Ukupni iznos troškova po jedinici finalnog proizvoda (brašno) u 2012. godini iznosio je prosječno 1,80 kn, nesrazmjer između jedne i dvije kn. Ukupni iznos troškova materijala proizvodnje brašna u 2012. godini (osnovni i pomoćni materijali, energija, ambalaža, inventar i sl.) iznosio je prosječno 6.446.920,24 kn, uz (relativno veliki) nesrazmjer između 80.000 i 28.900.000 kn. Ukupni iznos troškova sredstava za rad u 2012. godini (amortizacija, troškovi održavanja imovine, premije osiguranja, kamate na kredite, troškovi čuvanja objekta i opreme) iznosio je prosječno 631.439,41 kn, uz veliki nesrazmjer između 37.500 i 3.199.000 kn. Ukupni iznos troškova radne snage u 2012. godini iznosio je prosječno 746.926,25 kn, uz (opet relativno veliki) nesrazmjer između 14.000 i 4.504.830 kn (tablica 46.).

Ukupan iznos proizvedenih sporednih proizvoda u 2012. godini u kilogramima iznosio je prosječno 1.777.781,33 kg, uz nesrazmjer od 0 do 5.600.000 kg.

Ukupan iznos vrijednosti proizvedenih sporednih proizvoda u 2012. godini iznosio je 2.074.992,12 kn, uz također veliki nesrazmjer između 0 i 8.400.000 kn.


Unesite ukupan iznos proizvedenog brašna u 2012. godini u kilogramima iznosio je prosječno 8.268.912,56 kg, uz (opet relativno veliki) nesrazmjer između 42.000 i 45.000.000 kn.

Unesite ukupan iznos proizvedenog brašna u 2012. godini u kn iznosio je prosječno 10.975.422,59 kn, uz također veliki nesrazmjer između 21.500 i 49.500.000 kn.

Tablica 45. Deskriptivna statistika za kvantitativne varijable vezane uz preradu pšenice – Troškovi i proizvodni rezultati

Anketna pitanja	Min.	Max.	Aritm. sredina	Std. devijacija	Kolmogorov-Smirnov Z	Znač. (p)**
Ukupni iznos troškova po jed. finalnog proizvoda (brašno) u 2012. god. u kn	1	2	1,80	0,473	0,927	,357
Unesite ukupni iznos troškova materijala proizvodnje brašna u 2012. godini u kn	80000	28900000	6446920,24	10356235,109	1,476	0,026
Ukupni iznos troškova sredstava za rad u 2012. godini u kunama (amortizacija, troškovi održavanja imovine, premije, kamate na kredite, troškovi čuvanja objekta i opreme)	37500	3199000	631439,41	859166,349	1,009	0,261
Ukupni iznos troškova radne snage u 2012. god. u kn	14000	4504830	746926,25	1126954,077	1,145	0,145
Ukupan iznos proizvedenih sporednih proizvoda u 2012. godini u kg	0	5600000	1777781,33	2256522,550	1,381	0,044
Ukupan iznos vrijednosti proizvedenih sporednih proizvoda u 2012. godini u kn	0	8400000	2074992,12	2934804,312	1,4	0,040
Unesite ukupni iznos proizvedenog brašna u 2012. godini u kg	42000	45000000	8268912,56	12057806,202	1,266	0,081
Unesite ukupni iznos proizvedenog brašna u 2012. godini u kn	21500	49500000	10975422,59	16179386,680	1,3	0,068

U grafikonu 5. prikazane su prosječne vrijednosti (aritmetičke sredine i standardna raspršenja) za sve tvrdnje koje opisuju pojedina tematska područja stavova prerađivača pšenice.



Grafikon 5. Prosječne vrijednosti (aritmetičke sredine i standardna raspršenja) za sve tvrdnje koje opisuju tematska područja stavova prerađivača pšenice

Stavovi u pojedinim tematskim područjima definirani kao prosječni zbrojevi (ukupan zbroj procjena za tvrdnje unutar tablica 35.-39., podijeljen brojem tvrdnji koje opisuju pojedina područja stavova).

U njima su uočljivi trendovi kako su najpozitivniji stavovi prerađivača prikazani u tematskom području stavova o preradi pšenice Tehničko-tehnološke tvrdnje, a najnegativniji u tematskom području Makroekonomske tvrdnje.

3.4. Modeli izračuna konkurentnosti

Modeli izračuna konkurentnosti zasnivaju se na korelacijama i zavisnosti između metode Troškova domaćih resursa i Političke analize matrice za izdvojene segmente proizvodnje i prerade pšenice u Republici Hrvatskoj. Podjela ispitnog uzoraka na dvije grupe neznatno je povećala koeficijent korelacije, ali je potvrdila međusobnu ekonomsku zavisnost između navedenih segmenata.

3.4.1. Troškovi domaćih resursa – proizvodnja pšenice

Za izračun metode Troškovi domaćih resursa (engl. DRC), korištene su vrijednosti aritmetičke sredine izdvojenih varijabli, dobiveni iz primarnih i sekundarnih izvora. Primarni podaci dobiveni su prikupljanjem i obradom 130 upitnika, prikupljenih na 5 županija istočne Hrvatske, preostale potrebite varijable, odnosno njihove srednje vrijednosti korištene su iz sekundarnih izvora, odnosno dostupnih podataka iz sličnih studija, Statističkog ljetopisa Republike Hrvatske, godišnjih izvješća Hrvatske gospodarske komore, Državnog zavoda za statistiku i podataka dostupnih od strane Ministarstva poljoprivrede Republike Hrvatske.

DRC se izračunavao po etapama, sukladno odabranoj proizvodnoj aktivnosti-proizvodnja pšenice. U prvom koraku je izdvojena ukupna vrijednost proizvodnje, odnosno obavljen je izračun proizvodnih troškova jednogodišnjeg ciklusa proizvodnje pšenice.

U sljedećem koraku, sve ulazne i izlazne varijable razvrstane su u čimbenike-inpute kojima se može i ne može trgovati. Inputi kojima se može trgovati su robe ili usluge kojima se može obaviti razmjena ili uvozom ili izvozom, a to su gnojivo, sjeme, zaštitna sredstva, mehanizacija i gorivo. Gnojivo i sjeme su inputi koji su proizvedeni u Republici Hrvatskoj i svejedno se smatraju inputima kojima se može obavljati trgovina.

Izdvojeni čimbenici kojima se ne može trgovati su: rad, zemlja, kapital i voda. Najam mehanizacije može se svrstati u inpute kojima se može, ali i ne može trgovati, u konačnici se klasificira u inpute kojima se može trgovati.

DRC koeficijentom izmjerila se učinkovitost, odnosno komparativna prednost ili nedostatak izdvojenog sektora proizvodnje pšenice.

Za 2013. godinu korišteni su podaci prikupljeni terenskim istraživanjem, odnosno iz uzorka od 130 ispitanika, izuzev podataka o prosječnom prinosu, cijeni, visini potpore, gdje su korišteni dostupni podaci Ministarstva poljoprivrede, za prosječne vrijednosti izražene u kunama na hektar. Za izračun DRC koeficijenta u 2011. i 2012. godini korišteni su dostupni podaci prikupljeni od Ministarstva poljoprivrede i Hrvatske gospodarske komore (tablica 46.).

Tablica 46. Varijable izračuna koeficijenta troškovi domaćih resursa za sektor proizvodnja pšenice po godinama (2011., 2012. i 2013.)

Varijable/godina	2011.	2012.	2013.
Prinos/ha	5,2	5,4	5,2
Cijena u RH, kn/t	1450	1530	1670
Potpore, kn/ha	1950	1460	1600
Vrijednost proizvodnje/domaće cijene	9490	9722	10284
Inputi kojima se može trgovati			
Sjeme	760	800	884
Gnojivo	1600	1800	2057
Zaštitna sredstva	700	700	731
Razne usluge-najam	280	300	306
Mehanizacija	700	800	918
Ukupni troškovi tržišnih inputa	4040	4400	4896
Indirektni troškovi	650	690	739
Bruto marža	590	620	650
Dodana vrijednost/domaće cijene	-60	-70	-89
Vrijednost rada	750	756	768
Kapitalni troškovi	240	245	250
Koeficijent troškova domaće proizvodnje	990	1001	1018

Izvor: Hrvatska gospodarska komora, Ministarstvo poljoprivrede RH (2013.)

Temeljem prikupljenih podataka izdvojene su varijable ukupni prihodi i rashodi, odnosno na osnovu istih utvrđena je visina dobiti za svaku izdvojenu godinu (tablica 47.).

Tablica 47. Prihodi, rashodi i dobit (kn/ha) za godine 2011., 2012. i 2013.

Varijable/godina	2011.	2012.	2013.
Prihodi	9490	9722	10284
Rashodi	6210	6641	7214
Dobit	3280	3081	3070

Izdvojenim vrijednostima po godinama pristupilo se formiranju analitičke matrice kojom su uspoređeni podaci proračuna sustava po stvarnim i ekonomskim cijenama kako bi se ustanovilo u kojoj mjeri učinci agrarne politike i tržišni poremećaji utječu na materijalne inpute, domaće resurse i outpute, za izdvojene godine (2011., 2012. i 2013.)

Nakon formiranja matrice (tablice 48., 49. i 50.) obavljen je izračun pripadajućih koeficijenata s izdvojenim predmetnim koeficijentom - Troškovi domaćih resursa (DRC).

Tablica 48. Analitička matrica - proizvodnja pšenice, 2011. godina

Varijable/troškovi	Prihodi	Inputi	Resursi	Profit
Stvarne cijene	9490	4250	1960	3280
Ekonomske cijene	5500	3790	1899	189
Utjecaj odstupanja učinkovitosti politike	3990	460	61	3469

Troškovi domaćih resursa (DRC=1,11), omjer proizvođačkih troškova (PCR=0,2), koeficijent nominalne zaštite za outpute (NPCO=1,72) i inpute (NPCI=1,12), koeficijent efektivne zaštite (EPC=3,06), koeficijent profitabilnosti (PC=17,4) i koeficijent omjera proizvođačkih subvencija (SRP=0,63).

Tablica 49. Analitička matrica- proizvodnja pšenice, 2012. godina

Varijable/troškovi	Prihodi	Inputi	Resursi	Profit
Stvarne cijene	9722	4400	2241	3081
Ekonomske cijene	5890	3990	2090	190
Utjecaj odstupanja učinkovitosti politike	3832	410	151	3271

Troškovi domaćih resursa (DRC=1,1), omjer proizvođačkih troškova (PCR=0,42), koeficijent nominalne zaštite za outpute (NPCO=1,65) i inpute (NPCI=1,1), koeficijent efektivne zaštite (EPC=2,8), koeficijent profitabilnosti (PC=16,2) i koeficijent omjera proizvođačkih subvencija (SRP=0,56).

Tablica 50. Analitička matrica - proizvodnja pšenice, 2013. godina

Varijable/troškovi	Prihodi	Inputi	Resursi	Profit
Stvarne cijene	10284	4896	2318	3070
Ekonomske cijene	6303	4500	2150	347
Utjecaj odstupanja učinkovitosti politike	3981	396	168	3417

Troškovi domaćih resursa (DRC=1,19), omjer proizvođačkih troškova (PCR=0,43), koeficijent nominalne zaštite za outpute (NPCO=1,63) i inpute (NPCI=1,09), koeficijent efektivne zaštite (EPC=2,99), koeficijent profitabilnosti (PC=8,87) i koeficijent omjera proizvođačkih subvencija (SRP=0,54).

Dobiveni rezultati za izdvojene godine 2011., DRC=1,11, 2012., DRC=1,1 i 2013. DRC=1,19 ukazuju na zaključak da proizvodnja pšenice u Republici Hrvatskoj nije u granicama konkurentnosti.

3.4.2. Troškovi domaćih resursa – prerada pšenice

Kako bi se obavio izračun metode Troškovi domaćih resursa (engl. DRC) za izdvojeni segment prerade pšenice, također su korištene vrijednosti izdvojenih varijabli, odnosno njihovih aritmetičkih sredina, dobiveni iz primarnih i sekundarnih izvora.

Podaci o prihodima, vrijednosti proizvodnje i troškova za 2012. godinu dobiveni su dijelom prikupljanjem i obradom 18 upitnika prerađivača pšenice, prikupljenih na 4 županije istočne Hrvatske, preostale potrebite varijable, odnosno njihove srednje vrijednosti korištene su iz sekundarnih izvora, odnosno dostupnih podataka iz sličnih studija, Statističkog ljetopisa Republike Hrvatske, godišnjih izvješća Hrvatske gospodarske komore, Državnog zavoda za statistiku i podataka dostupnih od strane Ministarstva poljoprivrede Republike Hrvatske.

Korištenjem godišnjih financijskih izvješća za izdvojeni sektor prerade pšenice, a koje objedinjuju spomenute institucije, sastavljena je temeljem računa dobiti i gubitka tablica s pripadajućim vrijednostima prihoda, troškova i vrijednosti proizvodnje i rada, dobivenim istraživanjem (tablica 51.), ukupnih prihoda, rashoda i dobiti (tablica 52.), a navedene tablice su bila ishodište izrade analitičke matrice za istraživanjem obuhvaćene godine 2011. i 2012. (tablica 53. i 54.)

Tablica 51. Podaci o prihodima, vrijednosti proizvodnje i troškova za 2011. i 2012. godinu

Varijable/godina	2011.	2012.
Prihodi od prodaje	1.435.447.000	1.500.775.000
Ostali prihodi	62.952.000	46.790.000
Vrijednost proizvodnje/domaće cijene	1.498.399.000	1.547.565.000
Troškovi sirovine	551.916.000	530.101.000
Vrijednost rada	143.139.000	144.714.000
Ostali troškovi	761.382.000	839.168.000
Ukupni troškovi tržišnih inputa	1.456.437.000	1.513.983.000

Izvor: Hrvatska gospodarska komora, Ministarstvo poljoprivrede RH (2013.)

Tablica 52. Ukupni prihodi, rashodi i dobit sektora prerade pšenice (kn) u Republici Hrvatskoj za godine 2011. i 2012.

Varijable/godina	2011.	2012.
Ukupni prihodi	1.498.399.000	1.547.565.000
Rashodi	1.456.437.000	1.513.983.000
Dobit	41.962.000	33.582.000

Tablica 53. Analitička matrica – prerada pšenice, 2011. godina

Varijable/troškovi	Prihodi	Inputi	Resursi	Profit
Stvarne cijene	1.498.399.000	761.382.000	695.055.000	41.962.000
Ekonomske cijene	1.155.755.000	600.586.000	552.579.000	2.590.000
Utjecaj odstupanja učinkovitosti politike	342.644.000	160.796.000	142.476.000	39.372.000

Troškovi domaćih resursa (DRC=0,99), omjer proizvođačkih troškova (PCR=0,09), koeficijent nominalne zaštite za outpute (NPCO=1,3) i inpute (NPCI=1,27), koeficijent efektivne zaštite (EPC=1,32), koeficijent profitabilnosti (PC=16,2) i koeficijent omjera proizvođačkih subvencija (SRP=0,034).

Tablica 54. Analitička matrica – prerada pšenice, 2012. godina

Varijable/troškovi	Prihodi	Inputi	Resursi	Profit
Stvarne cijene	1.547.565.000	839.168.000	674.815.000	33.582.000
Ekonomske cijene	1.290.201.000	760.520.000	527.071.000	2.610.000
Utjecaj odstupanja učinkovitosti politike	257.364.000	78.648.000	147.744.000	30.972.000

Troškovi domaćih resursa ($DRC=1$), omjer proizvođačkih troškova ($PCR=0,95$), koeficijent nominalne zaštite za outpute ($NPCO=1,2$) i inpute ($NPCI=1,1$), koeficijent efektivne zaštite ($EPC=1,34$), koeficijent profitabilnosti ($PC=12,9$) i koeficijent omjera proizvođačkih subvencija ($SRP=0,024$).

Dobivena vrijednost troškova domaćih resursa za preradu pšenice RH u 2011. i 2012. godini ukazuje kako je promatrani izdvojeni segment neutralan u odnosu na parametre izračuna konkurentnosti.

3.4.3. Usporedba različitih scenarija

Za potrebe utvrđivanja razine konkurentnosti proizvodnje i prerade pšenice u RH, u okviru scenarij analize, obavljena je identifikacija alternativnih scenarija:

Optimistični scenarij:

- održavanje proizvodnje na postojećoj razini;

Pesimistični scenarij:

- smanjenje razine proizvodnje i prerade pšenice za 50%,
- minimiziranje prerade, uz održavanje proizvodnje pšenice na jednakoj razini.

3.4.3.1. Optimistični scenarij

Obavljenim istraživanjem utvrđena je postojeća razina proizvodnje i prerade pšenice u RH, za izdvojeno vremensko razdoblje, odnosno u godini provođenja istraživanja (2013.) za proizvodnju pšenice u RH, utvrđeno je kako su požnjevene površine iznosile 188.520 ha, prosječan prinos iznosio je $5,2 \text{ t ha}^{-1}$, a proizvedeno je ukupno 999.700 t pšenice.

Uvidom u registar mlinara, uvoznika i proizvođača brašna, namjenskih smjesa i koncentrata – utvrđeno je kako u 2013. godini upisano 193 mlinara, 11 proizvođača namjenskih smjesa i koncentrata, 47 uvoznika brašna, 35 uvoznika namjenskih smjesa i koncentrata, te 7 pravnih subjekata koji se bave prepakiranjem brašna. Zadnji dostupni podaci o proizvodnji brašna iz 2012. godine govore kako je ukupno proizvedeno 478.045 t mlinskih proizvoda, od navedene količine 458.112 t je iznosila proizvodnja pšeničnog brašna, odnosno 95,8%.

U navedenoj godini (2012.), prema dostupnim podacima, utvrđena je razina uvoza pšeničnog brašna od 565 t, ukupnog izvoza od 18.148 t, odnosno uvozno-izvozna bilanca bila je pozitivna u količini od 17.583 t pšeničnog brašna. Utvrđeni kapaciteti mlinova za meljavu pšenice u Hrvatskoj (za 250 radnih dana) veći su od 1.300.000 t, ukupna potrošnja brašna u RH kreće se oko 460.000 t, a minimalne potrebe za preživljavanje stanovništva su 380.000 t.

Temeljem prikupljenih podataka obavljen je izračun koeficijenta Troškova domaćih resursa (DRC), s ciljem utvrđivanja razine konkurentnosti u izdvojenim sektorima proizvodnje i prerade pšenice. Dobiveni rezultati za izdvojene godine 2011., DRC=1,11, 2012., DRC=1,1 i 2013. DRC=1,19 ukazuju kako proizvodnja pšenice u Republici Hrvatskoj nije konkurentna. Paralelno je obavljen i izračun troškova domaćih resursa (DRC), za izdvojeni sektor prerade pšenice RH u 2011. i 2012. godini, dobiveni rezultati ukazali su neutralan status hrvatskog mlinskog sektora u odnosu na parametre izračune konkurentnosti. Primjenom eventualne agresivne strategije investiranja u tržište pšenice i pratećih mlinskih proizvoda, postojeća razina proizvodnje i prerade pšenice mogla bi se održati, uz očuvanje postojećih radnih mjesta, a s obzirom na to da kapaciteti za proizvodnju i preradu nisu iskorišteni u potpunosti, prostora za povećanje proizvodnje, odnosno povećanje zaposlenosti u oba izdvojena sektora ima.

3.4.3.2. *Pesimistični scenarij*

Identifikacijom alternativnog pesimističnog scenarija, uz predviđanje kako ulazak RH u Europsku uniju, nije donio očekivana poboljšanja za proizvođače i prerađivače pšenice, povoljni agroklimatski uvjeta za proizvodnju pšenice narušavani konstantnim vremenskim nepogodama, nedostatak sredstava na tržištu, odnosno predugim rokovima isplate domaćih otkupljivača pšenice, nastavak recesije, smanjivanje proizvodnje i prerade pšenice uz daljnji gubitak radnih mjesta.

Sukladno navedenim negativnim kretanjima i predviđenom scenariju o smanjenju proizvodnje i prerade pšenice za 50%, obavljen je izračun Koeficijenta domaćih resursa (DRC), na navedene okolnosti, korištenjem podataka za 2013. godinu za izdvojeni segment proizvodnja pšenice. Smanjena je vrijednost prinosa, i inputa, a vrijednost dostupnih resursa ostala je nepromijenjena (tablica 55.).

Tablica 55. Varijable izračuna koeficijenta troškovi domaćih resursa za sektor proizvodnja pšenice za godinu (2013.), smanjenje prinosa 50%

Varijable/godina	2013. (-50%)
Prinos/ha	5,2
Cijena u RH, KN/t	1450
Potpore, KN/ha	1950
Vrijednost proizvodnje/domaće cijene	5720
<i>Inputi kojima se može trgovati</i>	
Sjeme	884
Gnojivo	2057
Zaštitna sredstva	731
Razne usluge-najam	306
Mehanizacija	918
Ukupni troškovi tržišnih inputa	4896 (-50%)
Indirektni troškovi	739
Bruto marža	650
Dodana vrijednost/domaće cijene	-89
Vrijednost rada	768
Kapitalni troškovi	250
Koeficijent troškova domaće proizvodnje	1018

Sukladno zadanom scenariju, o smanjenju proizvodnje za 50%, smanjen je podatak o visini prinosa po hektaru i podatak o ukupnim troškovima tržišnih inputa. Formiranjem tablice s podacima o prihodima, rashodima, utvrđeno je znatno smanjenje dobiti (tablica 56.).

Tablica 56. Prihodi, rashodi i dobit (kn/ha) za godinu 2013., smanjenje 50%

Varijable/godina	2013.
Prihodi	5720
Rashodi	4766
Dobit	954

Formiranjem analitičke matrice s smanjenim vrijednostima prihoda i inputa, obavljen je izračun Troškova domaćih resursa (DRC). Dobivena vrijednost koeficijenta DRC od **2,39**, ukazuje na visoku nekonkurentnost proizvodnje pšenice u uvjetima pesimističnog scenarija smanjenja prihoda (prinosa) i inputa za 50% (tablica 57.).

Tablica 57. Analitička matrica - proizvodnja pšenice, 2013. godina (smanjenje 50%)

Varijable/troškovi	Prihodi (-50%)	Inputi (-50%)	Resursi	Profit
Stvarne cijene	5720	2448	2318	954
Ekonomске cijene	3152	2250	2150	1248
Utjecaj odstupanja učinkovitosti politike	2568	198	168	2202

Sukladno zadanom scenariju o smanjenju prerade pšenice za 50%, korišteni su dostupni podaci iz 2012. godine. Dostupne vrijednost prihoda od prodaje, ostalih prihoda, troškova sirovine, ostalih troškova i vrijednost troškova rada je smanjena za 50% (tablica 58.).

Tablica 58. Varijable izračuna koeficijenta troškovi domaćih resursa za sektor prerada pšenice za godinu (2012.), smanjenje 50%

Varijable/godina	2012.
Prihodi od prodaje	1.500.775.000
Ostali prihodi	46.790.000
Vrijednost proizvodnje/domaće cijene	1.547.565.000 (-50%)
Troškovi sirovine	530.101.000
Vrijednost rada	144.714.000
Ostali troškovi	839.168.000
Ukupni troškovi tržišnih inputa	1.513.983.000 (-50%)

Temeljem podataka o prihodima i rashodima formirana je tablica sa smanjenim vrijednostima istih, uz smanjenje konačne dobiti (tablica 59.).

Tablica 59. Ukupni prihodi, rashodi i dobit sektora prerade pšenice Republike Hrvatske za godinu 2012. (kn), smanjenje 50%

Varijable/godina	2012.
Ukupni prihodi	773.782.500
Rashodi	756.991.500
Dobit	16.791.000

Formiranjem analitičke matrice (tablica 60.), odnosno stavljanjem u omjere varijabli prihoda i rashoda uz pripadajuće smanjenje ekonomskih cijena, pristupilo se izračunu Koeficijenta domaćih resursa (DRC). Dobivena vrijednost od 0,996 odnosno koeficijenta **1**, ukazuje kako navedene promjene ne dovode do promjene razine konkurentnosti, uslijed smanjenja parametara za 50%, odnosno konkurentnost segmenta prerade pšenice ostaje nepromijenjena tj. neutralna.

Tablica 60. Analitička matrica – prerada pšenice, 2012. godina, smanjenje 50%

Varijable/troškovi	Prihodi (-50%)	Inputi (-50%)	Resursi (-50%)	Profit
Stvarne cijene	773.782.500	419.584.000	337.407.500	16.791.000
Ekonomske cijene	645.100.500	380.260.000	263.535.500	1.305.000
Utjecaj odstupanja učinkovitosti politike	128.682.000	39.324.000	73.720.000	15.486.000

Treći zadani scenarij predviđa minimiziranje mlinskog sektora u Republici Hrvatskoj, uz održavanje proizvodnje pšenice na jednakoj razini. Kako bi se izračunala razina konkurentnosti također je obavljen izračun DRC koeficijenta uz formiranje prateće matrice (PAM). S obzirom kako se razina proizvodnje pšenice ne mijenja u ovom scenariju, podaci- rezultati konkurentnosti ostaju nepromijenjeni sukladno dobivenim rezultatima za 2013. godinu, vrijednost koeficijenta DRC=**1,19**, odnosno proizvodnja pšenice u Republici Hrvatskoj za 2013., sukladno provedenom istraživanju je u negativnoj razini konkurentnosti.

Kako bi se proveo scenarij o minimiziranju sektora prerade pšenice, postojeći podaci iz 2012. godine mijenjaju se s pretpostavkom kako razina prihoda ostaje ista, ali se znatno smanjuju troškovi vrijednosti rada i ostali troškovi, s obzirom kako je scenarijem predviđeno smanjenje broja mlinova za 60%, odnosno brojka od 193 mlina smanjena je na 77, uz povećanje iskorištenosti kapaciteta od 75%. Odnosno, smanjena je vrijednost rada i ostalih troškova za 60%, uz pretpostavku kako 77 mlinova obavlja kompletnu preradu pšenice s ciljem zadovoljavanja potreba za pšeničnim brašnom u Republici Hrvatskoj, a vrijednost troškova sirovine ostaje nepromijenjena (tablica 61.).

Tablica 61. Varijable izračuna koeficijenta troškovi domaćih resursa za sektor prerada pšenice za godinu (2012.), scenarij minimiziranja

Varijable/godina	2012.
Prihodi od prodaje	1.500.775.000
Ostali prihodi	46.790.000
Vrijednost proizvodnje/domaće cijene	1.547.565.000
Troškovi sirovine	530.101.000
Vrijednost rada	57.885.600 (-60%)
Ostali troškovi	335.667.200 (-60%)
Ukupni troškovi tržišnih inputa	923.653.800

S obzirom na navedena smanjenja troškova, formirana je tablica ukupnih prihoda i rashoda sa značajnim povećanjem dobiti, sukladno navedenom smanjenju (tablica 62.).

Tablica 62. Ukupni prihodi, rashodi i dobit sektora prerade pšenice (kn) RH za godinu 2012. , scenarij minimiziranja

Varijable/godina	2012.
Ukupni prihodi	1.547.565.000
Rashodi	923.653.800
Dobit	623.911.200

Minimiziranjem mlinskog sektora za 60%, sukladno scenariju formirana je analitička matrica s ciljem izračuna Koeficijenta domaćih resursa u takovim uvjetima znatno je porastao profit, a i ukupna konkurentnost koja je izračunom DRC koeficijenta iznosi **0,45** što ukazuje na visoku konkurentnost u insceniranim uvjetima (tablica 63.).

Navedeni scenarij je svrstan u kategoriju pesimističnih, s obzirom kako se predviđenim smanjivanjem broja mlinova od 60% gube radna mjesta u navedenom postotku.

Tablica 63. Analitička matrica – prerada pšenice, 2012. godina, scenarij minimiziranja

Varijable/troškovi	Prihodi	Inputi (-60%)	Resursi (-60%)	Profit
Stvarne cijene	1.547.565.000	520.520.400	403.133.400	623.911.200
Ekonomске cijene	774.120.600	304.208.000	210.828.400	259.084.200
Utjecaj odstupanja učinkovitosti politike	773.444.400	216.312.400	192.305.000	364.827.000

3.4.3.3. Analiza scenarija

Scenarij analiza provedena je kroz izračun koeficijenta Troškova domaćih resursa (DRC), za svaki zadani scenarij. Optimističnim scenarijem predviđeno je održavanje proizvodnje na postojećoj razini, analizom dostupnih podataka za 2012. godinu za preradu i za 2013. godinu za proizvodnju pšenice utvrđeno je kako DRC za proizvodnju pšenice iznosi **1,19**, što ukazuje na ne konkurentnost. Koeficijent DRC za preradu pšenice iznosi **1**, što ukazuje na neutralni status konkurentnosti u izdvojenom segmentu.

Pesimističnim scenarijem predviđeno je smanjenje proizvodnje i prerade pšenice za 50%. Izračunom koeficijenta Troškova domaćih resursa za proizvodnju pšenice, sukladno navedenom smanjenju, utvrđena je visina koeficijenta DRC od **2,39** ukazuje na visoku nekonkurentnost. Vrijednost koeficijenta DRC za preradu pšenice ostaje nepromijenjena-neutralna (**1**), s obzirom na to da se scenarijem smanjila vrijednost prihoda i rashoda.

Scenarij kojim je predviđeno minimiziranje sektora prerade pšenice uz zadržavanje postojeće proizvodnje pšenice, utvrđeno je kako koeficijent DRC za proizvodnju pšenice ostaje ne promijenjen **1,19**, što ukazuje na ne konkurentnost. Nasuprot, uz predviđeno smanjenje broja mlinova odnosno troškova onih koji ostanu obavljati djelatnost, tj. prihodi ostaju isti ali se troškovi znatno smanjuju, a vrijednost dobivenog koeficijenta DRC iznosi **0,45**, što ukazuje na konkurentno poslovanje sektora prerade pšenice u takvim insceniranim uvjetima.

4. RASPRAVA

4.1. Zajednička poljoprivredna politika Europske Unije, utjecaj na proizvodnju i preradu pšenice u Republici Hrvatskoj

Analizom prikupljenih podataka u ovom radu je utvrđeno činjenično stanje hrvatske proizvodnje i prerade pšenice, uočene su promjene organizacijskih aspekata u proizvodnji pšenice izazvani promjenama u sustavu potpora baziranih na izravnim plaćanjima a izazvani pristupom Republike Hrvatske u Europsku uniju i preuzimanjem direktnog utjecaja Zajedničke poljoprivredne politike na hrvatsku poljoprivredu. Naime, kako navodi (Balaž, 2009.), ukupna unutarnja politika Europske unije diktirana je prije svega zajedničkom poljoprivrednom politikom (engl. Common agricultural policy – CAP). Otkako je Europska unija prešla graničnu crtu poljoprivredne samodostatnosti u 80-im godinama prošlog stoljeća, Zajednička poljoprivredna politika Europske unije pretrpjela je radikalne reforme. Modernizacijom poljoprivrede i preorijentacijom gospodarstva EU na uslužne djelatnosti, broj ljudi koji rade na zemlji pao je na 7% (prije 50 godina iznosio je 20%). Usprkos tome, 10,4 milijuna ljudi još uvijek je zaposleno u poljoprivredi i više od 40% površine EU su poljoprivredna dobra. EU, što se tiče Zajedničke poljoprivredne politike, politički je i institucionalno spremna suočiti se s navedenim izazovima, jer su dosadašnja iskustva pokazala kako su sredstva neracionalno trošena te se takvim netržišnim mehanizmom negativno utjecalo na ekonomski razvoj same Europske unije, uslijed čega je osiguran optimalan raspored svih proizvodnih resursa

Zajednička poljoprivredna politika predstavlja izazov za proučavanje europskih integracija, ne samo zbog napretka u odnosu na ostale zajedničke politike, već i zbog svoje kompleksnosti i često nerazumljivosti. Financijska sredstva koje koristi poljoprivreda sačinjavaju gotovo polovinu zajedničkog proračuna, a instrumenti koje koristi vrlo su različiti. Kompleksnost politike proizlazi iz prirodno-geografskih karakteristika, uvjeta proizvodnje i komercijalizacije različitih proizvoda, klime i ekonomske situacije zemalja članica. Unutarnje poljoprivredno tržište podrazumijeva da roba podrijetlom iz jedne zemlje članice, može biti uskladištena u drugoj i komercijalizirana u trećoj zemlji članici. Može se izvoziti u treće zemlje iz bilo koje članice Unije, a proizvodi trećih zemalja mogu ući na unutarnje tržište prolazeći granice bilo kojeg dijela EU. Što je dovelo do ponude

velikog broja poljoprivrednih i prehrambenih proizvoda koji se nude europskim potrošačima (*Kandžija i Cvečić, 2008.*).

Ovim istraživanjem je potvrđena problematika negativnih trendova u poljoprivredi prikazanih makroekonomskim indikatorima. Bruto dodana vrijednost je smanjena za 3,1%, smanjen je broj zaposlenih u poljoprivredi za 3,5% i registriran je rast uvoza od 2,1% u 2013. godini, u odnosu na 2011. godinu.

Analizirajući makroekonomsko okruženje u Hrvatskoj, utvrđen je stalni vanjskotrgovinski i proračunski deficit, kao posljedica makroekonomske neravnoteže koja se očituje u većoj domaćoj potrošnji na ostvarenu vrijednost proizvodnje. Upravo su ti deficiti glavni razlog povećanja zaduženosti javnog sektora, tako i ukupnog gospodarstva (*Buturac, 2010.*).

Kako bi se utvrdilo pozicioniranje proizvodnje Republike Hrvatske u segmentu proizvodnje pšenice, opravdanim se pokazalo kompariranje s referentnom godinom 1990., kada su dostignuti maksimalni kvalitativni i kvantitativni proizvodni rezultati. Dobivene negativne vrijednosti indeksa rasta proizvodnje za razdoblje 2002.–2013. ukazuju zaostajanje proizvodnih rezultata za onima postignutim u referentnoj godini.

Biljna proizvodnja u Republici Hrvatskoj obilježena je sezonskim promjenama sukladno agro-klimatskim uvjetima. Analiza sveukupne poljoprivredne proizvodnje je komplementarna ako je sagledamo u propulzivnim uvjetima u kojima se odvija. Proizvodnja usjeva komplementarno se ogleda u nerazmjeru povećanja prihoda u odnosu na proizvodnju, preradu, doradu, distribuciju i potrošnju. Analizom i procjenom stanja i uvjeta proizvodnje usjeva, ukazano je na značaj poljoprivrede za ekonomski razvoj u RH. Temeljem dobivenih rezultata predložene su potencijalne mjere agrarne politike s ciljem povećanja proizvodnje, prerade i dorade žitarica (*Petrač i sur., 2005.*).

Anketnim upitnikom prikupljenim i obrađenim u ovom istraživanju (n=130), utvrđena je i zastupljenost ispitanika prema obliku poslovanja, gdje je utvrđeno da najveći broj ispitanika (97 odnosno 74,6%) proizvodi pšenicu na obiteljskim poljoprivrednim gospodarstvima. Analizom strukture farmi kao temljenog oblika poslovanja u poljoprivredi Republike Mađarske utvrđeno je kako se nakon političkih, ekonomskih i društvenih promjena od 1989.-1990. struktura oblika poslovanja značajno promijenila u odnosu na prethodno razdoblje. Nova struktura farme bitno se razlikuje po svojim obilježjima od strukture farme glavnih konkurenata, uglavnom ostalih zemalja članica EU. Protekla dva desetljeća nakon tranzicije trebala su biti dovoljna za procjenu karakteristika i glavnih

promjena u strukturi farme, odnosno trenutna važnost izdvojene teme je neupitna. Održivost, opstanak i konkurentost predstavljaju važan koncept koji bi se mogao mjeriti profitabilnošću poljoprivrednih posjeda. Vrlo je bitno odrediti glavne kriterije održivosti, opstanka i konkurentosti, no ne smijemo smetnuti s uma multifunkcionalnu ulogu poljoprivrede, s obzirom na to da ona može riješiti važne izazove, posebice u zadržavanju ruralne populacije i pomoći njihovim domaćinstvima (Tóth, 2013.).

Ako se promatra izdvojeno tržište pšenice u Republici Hrvatskoj, svi proizvođači pšenice zainteresirani su za kretanja na navedenom tržištu, jer svaki od njih prodaje svoj udio proizvoda, a zajedno oblikuju ukupnu količinu pšenice ponuđenu tržištu. Stoga je važno sve proizvođače pšenice promatrati zajedno, s obzirom kako njihova pojedinačna ponuda oblikuje tržišnu ponudu pšenice (*Zmaić, 2008.*). Usporedom kretanja otkupnih cijena obavljenim u ovom istraživanju, potvrđena je asimilacija hrvatskog tržišta pšenice s europskim, s naglaskom na razdoblje 2009.-2013. godine, gdje su otkupne cijene pšenice na godišnjem prosjeku bile u pravilu minimalno različite.

Vitalnosti i uspješnost gospodarskih subjekata iz poljoprivrede i prehrambene industrije, pokazuje kako prehrambena industrija ima puno veće potencijalne konkurentske sposobnosti, što ide u prilog i tendenciji razvoja gotovih, visokokvalitetnih i prepoznatljivih hrvatskih proizvoda za domaće i međunarodno tržište (*Leko-Šimić, 2002.*).

Konkurencija u mnogim današnjim industrijama vođena je od strane višestrukih saveza, tj. grupa kompanija koje međusobno surađuju u strateškim projektima i ponašaju se poput jednog poduzeća. Zbog nedostatka veličine ili nekih ključnih kompeticija, poduzeća biraju borbu na tržištu u suradnji s koalicijskim partnerima. Višestruki savezi predstavljaju izvor konkurentske i ekonomske moći (*Tipurić i Markulin, 2002.*). Što su veće razlike u početnim troškovnim odnosima između dvaju područja, to je veća moguća korist od trgovine (Tracy, 2000.).

S osvrtom na izdvojeni mlinski sektor, odnosno na provedene analize, može se ustvrditi kako u Republici Hrvatskoj nije zamjetna pozitivna suradnja između proizvođača. Prisutna je diverzifikacija subjekta s naglašenom negativnom međusobnom konkurencijom, a vezano na izostanak kooperativnosti prema strateškim projektima i zajedničkim tržišnim nastupima, kako na lokalnom hrvatskom, tako i na zajedničkom europskom tržištu. Republika Hrvatska koristi u preradi pšenicu iz vlastite proizvodnje (99,5%), a uvozi minimalne količine (0,5%), i to iz zemlja Europske unije.

4.2. Konkurentnost hrvatske proizvodnje i prerade pšenice u međunarodnim okvirima

Konkurentnost hrvatske proizvodnje i prerade pšenice je prikazana u ovom istraživanju izračunom koeficijenta Troškovi domaćih resursa (DRC), formiranjem analitičke matrice (PAM). PAM je odabran kao analitički okvir za izračun koeficijenta DRC, kojim je izmjerena eventualna komparativna prednost proizvodnje pšenice. Izračunom izdvojenog koeficijenta (DRC) nije potvrđena konkurentnost hrvatske proizvodnje pšenice, u odnosu na EU tržište, obzirom kako su dobiveni koeficijenti prikazali manju vrijednost dodanih vrijednosti u odnosu na pripadajuće troškove izražene u ekonomskim cijenama za referentne 2011., 2012. i 2013. godine, odnosno za izdvojeni segment prerade pšenice također je primijenjena metoda troškova domaćih resursa i obavljen je izračun razine konkurentnosti za referentne godine 2011. i 2012. Dobiveni rezultat za navedene godine odgovaraju vrijednosti broja 1, što ukazuje na neutralan status, odnosno dobivena dodana vrijednost identična je pripadajućim troškovima za izdvojeni segment.

Uspoređujući konkurentnost hrvatskih proizvođača pšenice s dostupnim podacima o konkurentnosti proizvodnje pšenice u Albaniji utvrđeni su drugačiji aspekti zaštite tržišta pšenice i u isto vrijeme, razina utjecaja promjene cijena na proizvodnju pšenice. Stoga su analizirane aktualne komparativne prednosti proizvodnje pšenice u Albaniji i njezine glavne odrednice. Utjecaj učinka promjena u svjetskom gospodarskom okruženju utvrđen je analizom ulaznih cijena, makro-cijena (tečaja, kamatne stope, itd.) Obavljena je procjena mogućeg statusa eventualne komparativne prednosti proizvodnje pšenice do 2015., s ciljem davanja smjernica pozitivnim agro- političkim implikacijama za godine koje dolaze, kako bi se smanjili negativni učinci liberalizacije trgovine i promicanje trgovinske integracije (Agraja, 2006.).

Istraživanje o konkurentnosti pšenice provedeno je i u Pakistanu za razdoblje od tri godine (2001.-2003.), gdje su analizirani dostupni podaci za dvije glavne provincije s najrazvijenijom poljoprivrednom proizvodnjom - Punjab i Sindh. Temeljem dobivenih podataka određene su prosječne vrijednosti kako bi se dobila ocjena nacionalnog scenarija konkurentnosti. Za obavljanje izračuna korišteni su podaci o financijskim uvjetima poslovanja odnosno određivanjem parametara ekonomskih cijena koji su korišteni za procjenu komparativne prednosti proizvodnje pšenice. Imajući u vidu važnost pšenice za

cjelokupno gospodarstvo, analiza je provedena za dva režima cijena, uvozne i izvozne cijene. Rezultati analize pokazali su kako je na komparativna prednost iskazana izračunom koeficijenta DRC samo kao uvoznika pšenice, obavljenim izračunom na paritetne izvozne cijene utvrđeno je kako Pakistan kao proizvođač pšenice nije konkurentan na svjetskom tržištu i nema komparativnu prednost u proizvodnji pšenice (Anwar i sur., 2005.).

Obavljenim terenskim istraživanjem utvrđeni su tipovi i podrijetlo pšeničnog brašna zastupljenog u maloprodaji na izdvojenom uzorku devet nacionalnih maloprodajnih trgovačkih lanaca. Na tržištu zatečeni proizvodi imali su navedenu zemlju podrijetla Republika Hrvatska, od ukupno osamnaest registriranih proizvođača, odnosno nije zatečeno brašno proizvedeno izvan Republike Hrvatske. Od ukupnog broja registriranih proizvođača (18 proizvođača pšeničnog brašna prodaje svoje proizvode u maloprodajnim trgovačkim lancima (9%) u odnosu na 193 registrirana u registru Ministarstva poljoprivrede). Diferenciranost mlinskih hrvatskih proizvoda pri eventualnom izvozu na tržište EU može biti izražena ako se pokaže kako kupci mogu davati prednost privremeno ili trajno nekim od postojećih proizvoda, u usporedbi s proizvodima od novog ulaznika (Bain, 1956.).

Može li se konkurentnost hrvatskih maloprodavača temeljiti na izvornim hrvatskim proizvodima, s obzirom kako je Republika Hrvatska postala dio svjetskog tržišta i multinacionalni maloprodajni lanci s ponudom širokog spektra prehrambenih proizvoda iz različitih zemalja postupno preuzimaju dio hrvatskih potrošača. Hrvatska maloprodajna poduzeća moraju stoga pronaći način kako konkurirati u novonastalim tržišnim uvjetima. Analiziranom ulogom asortimana u postizanju konkurentske prednosti hrvatskih maloprodajnih poduzeća stavlja se naglasak na značenje podrijetla prehrambenih proizvoda koji se pojavljuju na policama prodavaonica. Rezultati istraživanja provedenog na reprezentativnom uzorku stanovništva Republike Hrvatske pokazali su kako su hrvatski potrošači upoznati s prednostima i nedostacima genetski modificirane hrane i žele da im se osigura njihovo temeljno pravo na izbor i hranu (jer ona predstavlja jednu od primarnih ljudskih potreba) koja ne ugrožava njihovo zdravlje (*Brčić-Stipčević i Renko, 2003.*).

Analizom Organizacije za ekonomsku suradnju i razvoj (OECD) prikazan je konzultativni pregled literature o konkurentnosti, produktivnosti i učinkovitosti u poljoprivrednom i poljoprivredno-prehrambenom sektora. S ciljem pojašnjavanja pojmova i terminologije koji se koriste u ovom području, te je prikazana kritička procjena pristupa i pokazatelja koji se koriste u literaturi za mjerenje konkurentnosti, produktivnosti i učinkovitosti na sektorskoj i

poljoprivrednoj razini. Također su opisana najnovija otkrića o rastu produktivnosti i promjenama u relativnoj konkurentnosti između podsektora i država, i samih odrednica konkurentnosti, uz identificiranje glavnih problema u provedbi istih. Zaključeno je kako više pažnje treba posvetiti analizi poljoprivredno-prehrambenog sektora s isticanjem faktora necjenovne konkurentnosti, kao i utjecaju državne intervencije na konkurentnost (*Latruffe, 2010.*).

Ovim istraživanjem obavljena je ocjena ekonomske učinkovitosti, odnosno nacionalne konkurentnosti proizvodnje i prerade pšenice također metodom izračuna koeficijenta DRC, prema zadanim scenarijima; održavanje proizvodnje na postojećoj razini (DRC proizvodnja 1,19 - negativna konkurentnost, DRC prerada 1 - neutralni status), na razini smanjenja za 50% za oba proizvođačka faktora (DRC proizvodnja 2,39 - nekonkurentnost, DRC prerada nepromijenjena - neutralna 1), minimiziranje mlinskog sektora uz održavanje proizvodnje pšenice na jednakoj razini (DRC proizvodnja 1,19 negativna konkurentnost, DRC prerada iznosi 0,45, što ukazuje na konkurentno poslovanje).

Postoji veliki broj različitih metodologija i pokazatelja nacionalne konkurentnosti. Poseban je naglasak stavljen na povezanost tzv. tvrdih indikatora konkurentnosti prema istraživanjima različitih institucija i mekih (anketnih) percepcija o stanju konkurentnosti. Razina konkurentnosti hrvatskoga gospodarstva sagledana je sa stajališta različitih metodologija pa je s velikom pouzdanošću i primjenom dviju različitih tehnika analize zaključeno kako je nedvojbeno metodologija WEF koju objavljuje tzv. Global Competitiveness Index ponajbolje u velikoj skupini analiziranih tranzicijskih zemalja opisuje napredak po pojedinim područjima i korelira s ostvarenom razinom gospodarskog razvitka. Potom po pouzdanosti slijedi EBRD metodologija, a na začelju je metodologija kojom se koristi Svjetska banka – Doing Business (*Lovrinčević i sur., 2008.*).

U makroekonomskom okruženju s izraženim recesivnim tržišnim poremećajima, koji direktno utječu na formiranje profitabilne i konkretne proizvodnje i prerade pšenice, funkcionalnost proizvodnosti izdvojenih sektora u Republici Hrvatskoj je upitna, a trendovi smanjenja produktivnosti, smanjenja broja proizvodnih jedinica i kvalitete finalnih proizvoda su višestruko prisutni.

5. ZAKLJUČCI

Na temelju dobivenih rezultata istraživanja konkurentnosti hrvatske proizvodnje i prerade pšenice, izdvojeni su sljedeći zaključci:

1. Procjenom međunarodne konkurentnosti hrvatske proizvodnje pšenice provedeno je istraživanje s ciljem prikupljanja parametara za izračun koeficijenta konkurentnosti troškova domaćih resursa (DRC).

1.1. Izračunom izdvojenog koeficijenta, a temeljem prikupljenih i analiziranih podataka za referentne 2011., 2012. i 2013. istraživanjem obuhvaćene godine, nije potvrđena konkurentnost hrvatske proizvodnje pšenice, s obzirom kako su dobiveni rezultati bili veći od vrijednosti 1, što ukazuje na nekonkurentnu proizvodnju.

1.2. Za izdvojeni segment prerade pšenice također je primijenjena metoda troškova domaćih resursa i obavljen je izračun razine konkurentnosti za referentne godine 2011. i 2012. Dobiveni rezultat za navedene godine odgovaraju vrijednosti broja 1, što ukazuje na neutralan status, odnosno prerada nije konkurentna, ali nije ni nekonkurentna.

2. Provedenim istraživanjem na terenu može se zaključiti kako se hrvatska proizvodnja i prerada pšenice mora uklopiti u instrumente provedbe Zajedničke poljoprivredne politike Europske unije, u skladu sa specifičnim potrebama i mogućnostima definiranja prioriteta, odnosno nastaviti daljnje prilagodbe sa zacrtanim ciljevima razvoja: Povećanje dohotka od proizvodnje pšenice kroz poticanje većih i produktivnijih gospodarstava, povećanje dohotka prateće industrije prerade pšenice uslijed povećanja obima proizvodnje i ekspanzije poljoprivrednog razvitka u cjelini zajedno s rastom udjela u međunarodnoj razmjeni prerađivačke industrije proizvodnje hrane, koji nije direktno povezan s poljoprivrednim gospodarstvom, odnosno direktnom poljoprivrednom proizvodnjom.

3. Kako bi se ocijenili ekonomski učinci na proizvodnju i preradu pšenice u Republici Hrvatskoj, provedena je analiza scenarija s ciljem simuliranja negativnih i pozitivnih uvjeta za proizvodnju i preradu pšenice. Scenarij analiza provedena je kroz izračun koeficijenta troškova domaćih resursa (DRC), za svaki zadani scenarij.

3.1. Optimističnim scenarijem predviđeno je održavanje proizvodnje na postojećoj razini, analizom dostupnih podataka za 2012. godinu prerade pšenice i za 2013. godinu proizvodnju pšenice utvrđeno je kako DRC za proizvodnju pšenice iznosi 1,19, što ukazuje

na negativnu konkurentnost. Koeficijent DRC za preradu pšenice iznosi 1, što ukazuje na neutralni status konkurentnosti u izdvojenom segmentu, a prema zadanom scenariju.

3.2. Pesimističnim scenarijem predviđeno je smanjenje proizvodnje i prerade pšenice za 50%. Izračunom koeficijenta troškova domaćih resursa za proizvodnju pšenice, sukladno navedenom smanjenju, utvrđena je visina koeficijenta DRC od 2,39, koja ukazuje na visoku nekonkurentnost. Vrijednost koeficijenta DRC za preradu pšenice ostaje nepromijenjena-neutralna (1), s obzirom na to da se scenarijem smanjila vrijednost prihoda i rashoda.

3.3. Scenarij kojim je predviđeno minimiziranje sektora prerade pšenice uz zadržavanje postojeće proizvodnje pšenice, utvrđeno je kako koeficijent DRC za proizvodnju pšenice ostaje nepromijenjen 1,19, odnosno proizvodnja pšenice je nekonkurentna. Nasuprot tome, uz predviđeno smanjenje broja mlinova, odnosno troškova onih koji ostanu obavljati djelatnost prerade, tj. prihodi ostaju isti ali se troškovi znatno smanjuju, a vrijednost dobivenog koeficijenta DRC iznosi 0,45, što ukazuje na konkurentno poslovanje sektora prerade pšenice u takovim insceniranim uvjetima.

4. Hrvatska ima povoljne agroklimatološke uvjete koji omogućuju visoko kvalitetnu proizvodnju pšenice.

4.1. Istraživanjem je utvrđeno usporedbom proizvodnih rezultata s referentnom godinom 1990., kako je u razdoblju 2002.-2013. godina požnjeveno pšenice prosječno manje 51%, kako je prosječni prinos u razdoblju 2002. -2013. bio manji za 10%, a kako se u navedenom razdoblju proizvodilo 51,2% pšenice manje nego u 1990. godini. Rezultati proizvodnje pšenice koji su bili najveći u 80-tim godinama prošlog stoljeća, zaključno s 1990. godinom, nikada u povijesti suvremene i samostalne Republike Hrvatske nisu postignuti navedeni podaci ukazuju na pozitivnu perspektivu buduće proizvodnje pšenice u Republici Hrvatskoj s mogućnošću povećanja udjela na tržištu Europske Unije.

4.2. Republika Hrvatska se s prosječnom godišnjom proizvodnjom pšeničnog brašna od 460.302 t nalazi na 14. mjestu, od ukupno 23 izdvojene zemlje članice udruge The European Flour Millers. Analizom razine prosječne proizvodnje po proizvodnoj jedinici-mlinu za izdvojene zemlje članice, Republika Hrvatska s vrijednosti 2.423 t je na 20. mjestu, odnosno u iskorištenost proizvodnih kapaciteta od 40% je na začelju zajedno s Rumunjskom. Što upućuje na zaključak kako prostora za povećanje proizvodnje pšeničnog

brašna ima, uz uvjet prihvaćanja suvremenih trendova u proizvodnji, odnosno prilagodbi postojećim tržišnim uvjetima u Europskoj uniji.

4.3. Višegodišnje smanjene vrijednosti proizvodnje pšenice, slaba iskorištenost postojećih prerađivačkih kapaciteta ukazuju na prisutnost disekonomije koja je izražena zbog ekonomske recesije, dugih rokova naplate i isporučenih roba i usluga, teškog gospodarskog položaja i stagnacije proizvodnih aktivnosti, nedostatka sredstava domaćih otkupljivača pšenice, prisutnosti sive ekonomije na tržištu, učestalosti vremenskih nepogoda i šteta na usjevima pšenice, nepovoljnog položaj proizvođača brašna u odnosu s trgovinom, pogotovo s velikim trgovačkim lancima (18 proizvođača pšeničnog brašna prodaje svoje proizvode u maloprodajnim trgovačkim lancima (9%) u odnosu na 193 registrirana u registru Ministarstva poljoprivrede). Republika Hrvatska koristi u preradi pšenice iz vlastite proizvodnje (99,5%), uvoze se minimalne količine i to iz zemalja članica Europske Unije (0,5%).

5. Istraživanjem je utvrđeno kako se proizvodnja pšenice u Republici Hrvatskoj, usporedbom s ostalim zemljama članicama Europske Unije, nalazi na 22. mjestu s prosječnom proizvodnjom u razdoblju 2002.-2013. godine od 776.500 t (0,57% ukupne vrijednosti proizvedene pšenice u Europskoj Uniji). U registre mlinara, uvoznika i proizvođača brašna, namjenskih smjesa i koncentrata – upisano je 193 mlinara, 11 proizvođača namjenskih smjesa i koncentrata, 47 uvoznika brašna, 35 uvoznika namjenskih smjesa i koncentrata, te 7 pravnih subjekata koji se bave prepakiranjem brašna. Prema evidencijama Ministarstva poljoprivrede 10 najvećih mlinara proizvede 70% domaćeg brašna (od cca 400.000 t), a 5 najvećih uvoznika uveze 73% brašna iz uvoza (od cca 2.200 t). Navedeni prikupljeni i obrađeni podaci upućuju na zaključak kako zadržavanje postojeće proizvodnje i prerade pšenice osigurava zapošljavanje i određenu razinu gospodarske stabilnosti u ruralnom, istraživanjem obuhvaćenom području. S obzirom na recesijom opterećene uvjete za obavljanje poslovne djelatnosti u Republici Hrvatskoj i članstvo u Europskoj Uniji, s osvrtom na negativan rezultat konkurentnosti proizvodnje i neutralan prerade pšenice predložen u ovom radu, prostor za napredak u količini i kvaliteti proizvodnje je prisutan.

6. Na osnovu provedene ankete i zadanih parametara utvrđivanja stavova, strukture i povezanosti između pojedinih komponenti koje su bile uvjetovane specifičnim uvjetima proizvodnje i prerade pšenice, zaključeno je sljedeće:

6.1. Deskriptivne karakteristike varijabli stavova o proizvodnji pšenice odnose se na četiri tematska područja s pripadajućim tvrdnjama: makroekonomske, tehničko-tehnološke tvrdnje, tržišne i tvrdnje koje se odnose na međunarodno okruženje i koncepciju proizvodnje pšenice. Analizom makroekonomskih tvrdnji, najvišu vrijednost medijana ima procijenjeni Potencijal poljoprivredne proizvodnje u RH. U području Tehničko-tehnoloških tvrdnji, najvišu vrijednost medijana (4) ima najbolje procijenjeni Agrotehnika proizvodnje pšenice na gospodarstvu ispitanika. U području tržišnih tvrdnji, najvišu vrijednost medijana (4) ima Razina kvalitete proizvedene pšenice u protekloj godini. U području tvrdnji o međunarodnom okruženju i koncepciji proizvodnje, najvišu vrijednost medijana (4) ima Proizvodnja pšenice na Vašem gospodarstvu u protekloj godini. Varijabla koja opisuje vlasničku strukturu, dobiveni rezultat ukazuje kako je znatno veći udio zemljišta u privatnom vlasništvu u odnosu na zemljište za koje se plaća najam. Među varijablama iznosa troškova, najveći iznos sredstava troši se za pribavljanje mineralnih gnojiva, zatim slijede troškovi održavanja vlastite mehanizacije, troškovi pribavljanja sjemenskog materijala, dok najmanje troškova iziskuje eventualni najam mehanizacije za potrebe proizvodnje pšenice u ispitanom uzorku. Provedena je deskriptivna analiza i za skupinu varijabli prerade pšenice: makroekonomske, tehničko-tehnološke, tržišne, koncepcijske i tvrdnje o međunarodnom okruženju. Analizom makroekonomskih tvrdnji, uočljivo je kako najvišu vrijednost medijana (5) ima varijabla RH ima preveliku birokraciju. U području tehničko-tehnoloških tvrdnji, najvišu vrijednost medijana (4) imaju varijable Ocijenite razinu iskorištenja kapaciteta proizvodnje u Vašem poduzeću i varijabla Ocijenite potrebu uvođenja novih tehnologija u Vašem poduzeću. U području tržišnih tvrdnji, najvišu vrijednost medijana (4) imaju varijable S većim brojem proizvođača pšenice surađujemo dugi niz godina te Ocijenite brojnost konkurenata na tržištu. U području koncepcijskih tvrdnji, najvišu vrijednost medijana (4) imaju varijable: Ocijenite razinu zadržavanja postojećih poslovnih partnera, Ocijenite razinu kvalitete Vaših proizvoda u odnosu na konkurenciju te varijabla Ocijenite vjernost krajnjih potrošača Vašim finalnim proizvodima. U području tvrdnji o međunarodnom okruženju, najveću vrijednost medijana (4) imaju varijable Ocijenite razinu zadržavanja postojećih poslovnih partnera, Ocijenite razinu kvalitete Vaših proizvoda u odnosu na konkurenciju te Ocijenite vjernost krajnjih potrošača Vašim finalnim proizvodima.

6.2. Latentna struktura područja stavova o proizvodnji pšenice za skupinu varijabli koje se odnose na makroekonomske tvrdnje pokazala je da postoje dvije latentne dimenzije u

ovom području: Utjecaj države te Potencijali proizvodnje i regulativa. Sva ostala područja stavova pokazala su jednodimenzionu strukturu: tehničko-tehnološke, tržišne i međunarodno okruženje s koncepcijom proizvodnje. Sve latentne dimenzije pokazale su i zadovoljavajuću pouzdanost.

6.3. Istraživanjem je potvrđena povezanost područja stavova o proizvodnji pšenice, jer su utvrđene prosječne niske pozitivne povezanosti između područja stavova o proizvodnji pšenice. Najviše vrijednosti korelacija pronađene su između Prihoda od pšenice i Otkupa pšenice, Otkupa pšenice i tehničko-tehnoloških tvrdnji, kao i Otkupa pšenice i međunarodnog okruženja.

6.4. Provedenom analizom potvrđene su razlike između županija u područjima stavova o proizvodnji pšenice te u varijablama vezanim uz proizvodnju pšenice. S obzirom kako su pronađene tri statistički značajne razlike između županija u odnosu na tvrdnje o područjima stavova o proizvodnji pšenice: tehničko-tehnološke (najveći prosječni rezultat za Osječko-baranjsku županiju, a najniži za Brodsko-posavsku); makroekonomske (najveći prosječni rezultat za Brodsko-posavsku županiju, a najniži za Vukovarsko-srijemsku); Prihod od pšenice (najveći prosječni rezultat za Osječko-baranjsku županiju, a najniži za Virovitičko-podravsku). Među odabranim varijablama vezanim uz proizvodnju pšenice, statistički značajne razlike u odnosu na županiju pronađene su samo kod četiri varijable: vlasničku strukturu nad zemljištem koje obrađujete – vlasništvo (najveći prosječni rezultat za Požeško-slavonsku županiju, a najniži za Virovitičko-podravsku); vlasničku strukturu nad zemljištem koje obrađujete – najam (najveći prosječni rezultat za Virovitičko-podravsku, a najniži za osječko-baranjsku županiju); iznos troškova mineralnih gnojiva u kunama/ha za proizvodnju pšenice (najveći prosječni rezultat za Požeško-slavonsku županiju, a najniži za Brodsko-posavsku županiju); iznos troškova najma mehanizacije u kunama/ha za proizvodnju pšenice (eventualno) (najveći prosječni rezultat za Požeško-slavonsku županiju, a najniži za Brodsko-posavsku županiju).

6.5. Analizom nije utvrđena značajna razlika između OPG-a i obrta u područjima stavova o proizvodnji pšenice. Odnosno, nije se pokazalo kako će se razlike pokazati zbog uvjetovanosti specifičnim uvjetima proizvodnje pšenice u odnosu na način poslovanja, odnosno mjerama stimulacije od strane države, ali i troškovima koje nosi određeni oblik poslovanja.

6. LITERATURA

1. Agrađa L. (2006): *Assessing the comparative advantage of wheat produced in Albania*, Cuviller Verlag, Göttingen.
2. Anwar S., Hussain Z, Javed M.S. (2005): *Comparative Advantage and Competitiveness of Wheat Crop in Pakistan*, *The Lahore Journal of Economics*, p. 101-110.
3. Atkin C. (2009): *Competitiveness of Wheat Production in eastern Europe*, *Global Cost of Production Challenge*, Bidwell.
4. Baban Lj. (1994.): *Utjecaj europskog tržišta na prilagodbu hrvatske poljoprivredne ponude*, Zbornik; *Poljoprivreda i proizvodnja hrane u novom europskom okruženju*, Hrvatska akademija znanosti i umjetnosti, ISBN 9531540306, Zagreb: 25-46.
5. Bain J.S. (1953): *Barriers to New Competiton (Their Character and Consequences in Manufacturing Industries)*, Cambridge, UK, p. 114
6. Balaž D. (2009.): *Zajednička poljoprivredna politika Europske unije, bitna odrednica budućnosti agrarne proizvodnje u Republici Hrvatskoj*, završni rad, Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku.
7. Balaž D., Leko Šimić M., Štimac H. (2012): *Marketing Environment in Croatian Food Industry*, 32th Scientific Symposium: *From Old Industries to a New Entrepreneurial Development Structure – Reality and Challenges for Pforzheim and Osijek*, Faculty of Economics in Osijek – Josip Juraj Strossmayer University in Osijek, Hochschule Pforzheim – Pforzheim University; Osijek; p. 233-241.
8. Batalha M., Perosa B., Filho H. (2009): *A competitiveness analysis of wheat agri-systems in Mercosur*, VII International PENSA Conference, Sao Paulo, Brazil.
9. Bezić H., Cerović Lj, Galović T. (2011.): *Promjene u konkurentskim prednostima prerađivačke industrije Hrvatske*, Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu, 29(2): 465 – 487.
10. Bilić S. (2009.): *Izazovi ulaska u EU za hrvatsku poljoprivredu: očekivani status seljaka, zadruga i poljoprivrednih poduzeća*, *Sociologija i prostor*, 43, 1(167): 109-127.

11. Blagojević G., Macanić I., Mijić M., Sudarić T., Zmaić K. (2008.): Izvozno orijentirani rast i razvoj hrvatske poljoprivrede, 43. hrvatski i 3. međunarodni simpozij agronoma, Opatija, 156-160.
12. Brčić-Stipčević V., Renko S. (2003.): Može li se konkurentnost hrvatskih maloprodavača temeljiti na izvornim hrvatskim proizvodima? Zbornik Ekonomskog fakulteta u Zagrebu, 1(1): 163-175.
13. Buble (1997): Shell Global Scenarios to 2025, p. 182-19.
14. Bojnec Š. (2003): Three Concepts of Competitiveness Measures for Livestock Production in Central and Eastern Europe, *Agriculturae Conspectus Scientificus (ACS)*, 68(3): 209-220.
15. Buturac G. (2009.): Konkurentnost hrvatske međunarodne trgovine prema zemljama jugoistočne Europe, 18. Tradicionalno savjetovanje Ekonomska politika Hrvatske u 2011. godini, Opatija: 239-261.
16. Buturac G. (2009.): Strukturna obilježja izvoza i uvoza hrvatske prerađivačke industrije, *Ekonomski pregled*, 60 (9-10): 432-457.
17. Čačić D., Čačić J., Kovačević D., Tratnik M. (2007): Influence of Different Technologies on the Competitiveness of Strawberry Production in Croatia, *Agriculturae Conspectus Scientificus (ACS)*, 71 (4): 181-186.
18. Dhebibi B., Frija A. (2009.): Impact of Domestic Resource Costs on the Competitiveness of Tunisian Fresh Fruit and Vegetable Products Exports, International Conference "Energy, Climate Change and Sustainable Development, Hammamet.
19. Državni zavod za statistiku, Statistički ljetopis, (2013.): Internet stranica, http://www.dzs.hr/Hrv/Publication/stat_year.htm
20. Eurostat (2013): http://epp.eurostat.ec.europa.eu/portal/page/portal/agriculture/data/main_tables
21. FAO (2009): Wheat-flour, Investment centre division - agribusiness handbook, Rome, https://www.responsibleagroinvestment.org/sites/responsibleagroinvestment.org/files/FAO_Agbiz%20handbook_Wheat%20Flour.pdf

22. Franić R. (2008.): Agrarna i ruralna politika II, (vježbe), Ekonomski fakultet u Zagrebu, Zagreb.
23. Franić R. (2009.): Agrarna politika, konkurentnost i poljoprivredni dohodak, Ekonomski fakultet u Zagrebu, Zagreb.
24. Franić R., Kumrić O. (2006.): Sugar sector in Croatia, competitive or not?, presentation on EAAC, Chania, Crete, Greece.
25. Franić R., Žimbek T. (2003.): Pretpostavke za uključivanje poljoprivrede u proces pridruživanja Europskoj uniji, Izazovi ekonomske i pravne prilagodbe (Katarina Ott, ur.), Institut za javne financije i Friedrich Ebert Stiftung, Zagreb, 153-172.
26. Gelo R., Gelo T. (2008.): Hrvatska poljoprivreda u kontekstu pristupanja Hrvatske u Europsku Uniju, Poljoprivreda i privredni razvoj, Zagreb.
27. Gotovac V. (2011.): Strategije potpore za oporavak od krize u jugoistočnoj Europi, ocjena Republike Hrvatske, Global jobs pact, Budapest.
28. Grahovac P. (2005.): Ekonomika poljoprivrede, Golden Marketing - Tehnička knjiga (88), Zagreb.
29. Horak H., Mlikotin-Tomić D., Pecotić-Kaufman J., Šoljan V. (2006.): Europsko tržišno pravo, Školska knjiga, Zagreb.
30. Hrvatska gospodarska komora, Sektor za poljoprivredu i prehrambenu industriju, (2013.): Izvješće o poslovanju mlinsko-pekarskog sektora u RH, Zagreb
31. Isikli E., Yercan M. (2009.): Domestic resource cost approach for international competitiveness of Turkish horticultural products, African Journal of Agricultural Research 4(9): 864-869.
32. Khachatryan, N. (2002.): Assessing the market potential of brandy produced in Armenia, University of Hohenheim, Stuttgart, Germany.
33. Kandžija V., Cvečić I. (2008.): Makrosustav Europske unije, Ekonomski fakultet Sveučilišta u Rijeci, Rijeka.
34. Karácsony P. (2008): Analysis of competitiveness of hungarian wheat sector with porter's diamond model, Journal of Central European Agriculture, 9(3): 399-403.
35. Kalanj I., Križman-Pavlović D. (2008.): Uloga poslovnog pregovaranja u stjecanju konkurentske prednosti, Ekonomska istraživanja, 21(4): 62-81.

-
36. Kapaj A., Kapaj I., Deci E., Tabaku I., Guri F. (2010): Investigation of production opportunities and resource use efficiency in agricultural production of Albania, International Food and Agribusiness Management Association, Navigating the Global Food System in a New Era, Kongressdokument, IAMA, Boston, 19.-22.06.2010, 7 S.
 37. Koo W., Mao W., Sakurai T. (2005): Wheat demand in Japanese flour milling industry: a production theory approach, *Agricultural Economics*, 24(2): 167–178.
 38. Latruffe L. (2010): Competitiveness, Productivity and Efficiency in the Agricultural and Agri-Food Sectors, OECD Food, Agriculture and Fisheries Working Papers, No. 30, OECD Publishing.
 39. Liebl F., Postma T.J.B.M. (2005): How to improve scenario analysis as a strategic management tool, *Technological Forecasting and Social Change*, 72(2): 161–173.
 40. Lončarić, R., Tolušić, Z., Zmaić, K. (2003.): Croatian cereal market under condition of world market globalization, *Proceedings of International Congress Flour-Bread 03, 4th Croatian Congress of Cereal Technologists*, Opatija, 314-321.
 41. Lovrinčević Ž., Mikulić D., Rajh E. (2008.): Usporedba metodologija mjerenja konkurentnosti nacionalnog gospodarstva i položaj Hrvatske, *Ekonomski pregled*, 59 (11): 603-645.
 42. Matthews A., (1999): Assessment of competitiveness of Czech agriculture and food industry in the context of EU accession, The final report of the project FAO/TCP/CEH/8821, Volumes 1-8, MZe CR, FAO Rome, also www.vuze.cz
 43. Ministarstvo poljoprivrede Republike Hrvatske (2009.): Hrvatska poljoprivreda, brošura.
 44. Ministarstvo poljoprivrede Republike Hrvatske (2013.): Internet stranica, <http://www.mps.hr/> i <http://www.tisup.mps.hr/>
 45. Ministarstvo poljoprivrede Republike Hrvatske (2013.): Prijedlog zakona o izmjenama zakona o posebnim uvjetima za stavljanje brašna na tržište s konačnim prijedlogom zakona, <https://vlada.gov.hr/UserDocsImages//Sjednice/Arhiva//99.%20-%208.pdf>
 46. Ministarstvo poljoprivrede Republike Hrvatske, (2013.): Godišnje izvješće o stanju poljoprivrede u 2012. godini (Zeleno izvješće 2013.) <http://www.mps.hr/default.aspx?id=9567>

-
47. Monke E., Pearson S.R. (1989): *The Policy Analysis Matrix for Agricultural Development*. Ithaca, N.Y., U.S.A.: Cornell University Press.
 48. Obadić A. (2010.): *Hrvatski agrarni potencijali i ruralni razvoj*, 9. Predavanje, Studij: *Ekonomika poduzetništva*, Varaždin.
 49. Par V. (2001.): *Simulacijski modeli u hortikulturnoj proizvodnji Zagrebačke Županije i Grada Zagreba*, Završno izvješće, Ministarstvo poljoprivrede i šumarstva, Zagreb, Vijeće za istraživanja u poljoprivredi.
 50. Pearson S. (1991.): *Introduction to the Policy Analysis Matrix*, University of Stanford, Stanford.
 51. Petrač B., Sudarić T., Zmaić K. (2005): *Crop production in a function of agricultural and economic development*, *Prospects for the 3rd Millennium Agriculture / Doru C. Pamfil (ur.)*, Cluj Napocca, Romania, 196-201.
 52. Petrač B., Sudarić T., Zmaić K. (2005): *Reduction of marginal yield in cereal crops production and possibilities to increase their yield*, 3rd International Congress FLOUR - BREAD '05, Opatija, 340-346.
 53. Porter, M. (1990.): *The Competitive Advantage of Nations*, The Free Press, New York.
 54. Rašić-Bakarić I., Vizek M. (2010.): *Analiza konkurentnosti i strukturnih obilježja prerađivačke industrije Republike Hrvatske*, *Ekonomski pregled*, 61(5-6): 241-270.
 55. Ruiz E.M. (2003): *Autarkic Policy and Efficiency in the Spanish Industrial Sector. An Estimate of Domestic Resource Cost in 1958*, Department of Economic History, London School of Economics, United Kingdom.
 56. Singer S. (2007.): *Gospodarenje prirodnim resursima*, Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku.
 57. Stipetić I. (1991.): *Biljna proizvodnja u Hrvatskoj 1885-1990*, Agrarno-ekonomske studije, knjiga 1., Zagreb.
 58. *The European Four Millers (2012): QUESTIONNAIRE*, Brussels.
 59. Tijanić L. (2010.): *Regionalna (ne)konkurentnost u RH*, *Ekonomski pregled*, 61(7-8): 419-454.

-
60. Tipurić D., Markulin G. (2002.): Strateški savezi-suradnjom poduzeća do konkurentne prednosti, Sinergija nakladništvo, Zagreb.
 61. Tóth O. (2013): Struktura farme i konkurentnost u mađarskoj poljoprivredi, *Agroeconomia Croatica*, 3(1): 3-5.
 62. Tracy M. (2000.): Hrana i poljoprivreda u tržišnom gospodarstvu, MATE, Zagreb.
 63. Tuna E., Georgiev N., Nacka M. (2013.): Analiza konkurentnosti u duhanskom podsektoru u Republici Makedoniji, *Agroeconomia Croatica*, 3(1): 53-60.
 64. Stipetić I. (1991.): Biljna proizvodnja u Hrvatskoj 1885-1990, Agrarno-ekonomske studije, knjiga 1., Zagreb.
 65. Šimić-Leko M. (2002.): Marketing hrane, Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku.
 66. Ugarčić-Hardi Ž. (2002.): Proizvodnja i tehnološka kvaliteta namjenskih sorti pšenica na području Slavonije i Baranje, Završno izvješće projekta 113 011, Prehrambeni fakultet Osijek, Osijek.
 67. Zmaić K. (2003.): Dinamika poljoprivrednih proizvoda u vanjskotrgovinskoj razmjeni Republike Hrvatske, *Ekonomski vjesnik : časopis Ekonomskog fakulteta u Osijeku*, Osijek, 14(1/2): 77-85.
 68. Zmaić, K., Lončarić, R., Sudarić T. (2005): Competitiveness of Croatian Agriculture as Presuppose of Penetration for EU Market, Improving the Performance of Supply Chains in the Transitional / ISHS (ed), Chaing Mai, Thailand.
 69. Zmaić K., (2008.): Osnove agroekonomike, Poljoprivedni fakultet u Osijeku, Osijek.

7. SAŽETAK

Analiza konkurentnosti je zahtjevan proces koji obuhvaća prikupljanje podataka i usporedbu varijabli na makro i mikro ekonomskoj osnovi. Za potrebe ovog rada obavljena je analiza prikupljanjem dostupnih podataka za Europsku Uniju, Republiku Hrvatsku i 5 županija istočne Hrvatske (130 uzoraka proizvođača i 18 uzoraka prerađivača pšenice). Analizom najviših i najnižih vrijednosti požnjevenih površina, ukupne proizvodnje i prosječnog prinosa u RH za izdvojeno razdoblje 2002.-2013. godine, utvrđeno je kako se najviše pšenice požnjelo 2002. godine (234.000 ha), a najmanje 2005. (146.000 ha), što predstavlja razliku od 37,6%. Najviše pšenice proizvedeno je 2013. godine (997.000 t), a najmanje 2005. godine (601.700 t), što je razlika od 39,7%, najveći prosječni prinos zabilježen je 2008. godine (5,8 t ha⁻¹), a najmanji 2003. godine (2,5 t ha⁻¹), što predstavlja razliku od 56,9%. Zemlje najveći proizvođači pšenice u EU su: Francuska s prosječnom proizvodnjom od 36.849.600 t (27 %), zatim Njemačka 23.149.200 t (17%), Velika Britanija 14.846.000 t (11%) i Poljska s prosječnom proizvodnjom od 8.931.000 t (7 %), a podaci se odnose na razdoblje 2002.-2013. Republika Hrvatska se ulaskom na tržište EU nalazi na 22. mjestu s prosječnom proizvodnjom u navedenom razdoblju od 776.500 t (0,57%). S obzirom kako je Republika Hrvatska u 80-tim godinama prošlog stoljeća proizvodila prosječno 1.550.000 t pšenice, prostora za poboljšanja i povećanja proizvodnje ima. S navedenom prosječnom proizvodnjom Republika Hrvatska bila bi na 16. mjestu po prosječnoj proizvodnji pšenice u Europskoj Uniji. Usporedbom kretanja otkupnih cijena pšenice u Republici Hrvatskoj s onima u Europskoj Uniji, uočeno je kako u razdoblju 2002.-2008. godine, cijene u Republici Hrvatskoj značajno odstupaju od tržišnih cijena u Europskoj Uniji, izuzev 2003. i 2006. godine, kada su odstupanja bila minimalna. Nakon početka pregovora s Europskom unijom 2005., zamjetne su manje oscilacije u formiranju otkupnih cijena pšenice, izuzev 2008. godine kada je razlika bila najveća (RH 1,9 kn, EU 1,3 kn). U razdoblju od 2009. sve do 2013. godine, sukladno približavanju ulasku Republike Hrvatske u punopravno članstvo, razlika prosječne otkupne cijene pšenice između Republike Hrvatske i Europske Unije bila je minimalna. Analizom razine proizvodnje pšeničnog brašna po proizvodnoj jedinici-mlinu za izdvojene zemlje članice, utvrđeno je kako je Republiku Hrvatska s vrijednosti od 2.423 tone na 20. mjestu, odnosno da je s iskorištenosti proizvodnih kapaciteta od 40% na začelju Europske unije. Iskorištenost proizvodnih kapaciteta ostalih zemlja članica je visoka. Najveća vrijednost od

85% evidentirana je u Nizozemskoj, 80% u Austriji, Njemačkoj i Velikoj Britaniji, a ostale zemlje članice koriste svoje prerađivačke kapacitete u mlinskom sektoru u rasponu od 60-80%, izuzev Španjolske, koja je na 50% iskorištenosti kapaciteta proizvodnje. Republika Hrvatska koristi u preradi pšenicu iz vlastite proizvodnje (99,5%), a uvoze se minimalne količine pšenice (0,5%), i to iz zemlja Europske Unije. Kako bi se utvrdilo stanje i trendovi na tržištu pšeničnog brašna u Republici Hrvatskoj, obavljeno je terensko istraživanje utvrđivanja ponude izdvojenog proizvoda u robnim maloprodajnim lancima aktivnim na području Republike Hrvatske. Analizom zastupljenosti prema pojedinačnom proizvodu utvrđeno je kako su najzastupljeniji proizvodi pšenično bijelo brašno (T-550) glatko ($Z=38$, 22%), zatim pšenično bijelo brašno (T-550) oštro ($Z=23$, 13,5%) i pšenično polubijelo brašno T-850, ($Z=21$, 12,2%). Preostali tipovi brašna zastupljeni su u približno proporcijalnim vrijednostima intervala ($Z=8-13$, 4,7-7,6%). Utvrđena visina ukupne zastupljenosti pšeničnog brašna po tipovima ($\sum Z=171$). Osamnaest proizvođača pšeničnog brašna prodaje svoje proizvode u maloprodajnim trgovačkim lancima (9%) u odnosu na 193 registrirana pri evidenciji Ministarstva poljoprivrede. Za potrebe istraživanja, a s ciljem utvrđivanja konkurentnosti segmenta proizvodnje pšenice u Republici Hrvatskoj, prikupljeno je i analizirano ukupno 130 upitnika. Prikupljanje podataka obavljeno je u razdoblju siječanj-lipanj 2013., ispunjavanjem upitnika na području pet županija istočne Hrvatske. Analizirane su posebno varijable ordinalnog tipa (pojedinačne varijable tematskih područja stavova o proizvodnji pšenice) i varijable kvantitativnog tipa (demografske i agroekonomske). Izvedene varijable (dobivene analizom glavnih komponenti za skupine varijabli stavova) dobivene su za područja: makroekonomske tvrdnje, tehničko-tehnološke, tržišne tvrdnje i tvrdnje o međunarodnom okruženju i koncepciji proizvodnje. Zatim su utvrđeni demografski i agroekonomski pokazatelji vezani uz proizvodnju pšenice, te su utvrđene povezanosti između tematskih područja stavova o proizvodnji pšenice, kao i razlike između županija te oblika gospodarstva u stavovima o proizvodnji pšenice. Analizom prikupljenih podataka o preradi pšenice obuhvaćeno je ukupno 18 mlinova različitih preradbenih kapaciteta i starosti izgradnje, s ciljem prikupljanja podataka o činjeničnom stanju, uvjetima proizvodnje i prodaje, a zbog sagledavanja konkurentne pozicije izdvojenog sektora na tržištu Republike Hrvatske i jedinstvenom tržištu Europske Unije. U ovom slučaju analizirane su također posebno varijable ordinalnog tipa (pojedinačne varijable tematskih područja stavova o preradi pšenice) i varijable kvantitativnog tipa (demografske i agroekonomske). Prosječnim

zbrojem procjena za pojedinačne stavove tematskih područja stavova o preradi pšenice, dobilo se podatke o razlikama u pozitivnosti stavova za područja tvrdnji: makroekonomske, tehničko-tehnološke, tržišne, koncepcijske i tvrdnje o međunarodnom okruženju. Najpozitivniji stavovi pronađeni su za tehničko-tehnološke tvrdnje, a najnegativniji za tematske makroekonomske tvrdnje. Obavljeni su izračuni konkurentnosti primjenom metode Troškovi domaćih resursa (DRC), formiranjem analitičke matrice (PAM), (Monke, Pearson 1989.) Izračunom izdvojenog koeficijenta (DRC) nije potvrđena konkurentnost hrvatske proizvodnje pšenice, prema paritetnim domaćim cijenama u odnosu na EU tržište. Za izdvojeni segment prerade pšenice, primjenom navedene metode utvrđen je neutralan status konkurentnosti prema DRC koeficijentu. Obavljena je ocjena ekonomske učinkovitosti hrvatske proizvodnje i prerade pšenice također metodom izračuna koeficijenta DRC, prema zadanim scenarijima; održavanje proizvodnje na postojećoj razini (DRC proizvodnja 1,19 - negativna konkurentnost, DRC prerada 1 - neutralni status), na razini smanjenja za 50% za oba proizvođačka faktora (DRC proizvodnja 2,39 - nekonkurentnost, DRC prerada nepromijenjena - neutralna 1), minimiziranje mlinskog sektora uz održavanje proizvodnje pšenice na jednakoj razini (DRC proizvodnja 1,19 negativna konkurentnost, DRC prerada iznosi 0,45, što ukazuje na konkurentno poslovanje). Analizom prikupljenih podataka utvrđene su moguće potrebite prilagodbe standarda poslovanja, vanjske trgovine, vanjsko-trgovinske zaštite i domaće potpore u okviru Zajedničke poljoprivredne politike (ZPP). S obzirom na prikupljene podatke u recesijskim uvjetima proizvodnje i prerade te obavljenju analizu, potvrđena je prisutnost diseconomije između sektora proizvodnje i prerade pšenice, potvrđeno je da zadržavanje, odnosno povećanje proizvodnje i prerade pšenice, pozitivno utječe na stabilnost ruralnih istraživanjem obuhvaćenih područja. Obavljeni izračuni temeljem prikupljenih podataka u recesijskim uvjetima pokazali su međuovisnost proizvodnje i prerade pšenice, isto tako je utvrđeno kako postoje uvjeti za kvantitativno i kvalitativno povećanje proizvodnje i prerade pšenice u Republici Hrvatskoj.

Ključne riječi: konkurentnost, pšenica, mlinska industrija, DRC, Repubika Hrvatska, Europska unija

8. SUMMARY

COMPETITIVENESS OF CROATIAN PRODUCTION AND PROCESSING OF WHEAT ON THE EU MARKET

The competitiveness analysis is a demanding process that includes data collection and comparison of variables in the macro-and micro-economic basis. For the purposes of this study, an analysis of the available data for the European Union, Croatia and 5 counties of eastern Croatia (130 samples producers and processors of 18 samples of wheat). The analysis of the highest and lowest values of harvested area, total production and average yield in Croatia for a separate period 2002nd to 2013th years, it has been found to be the most wheat is harvested 2002nd year (234,000 ha) and the least 2005th (146,000 ha), which represents a difference of 37.6%. Most wheat is produced 2013th year (997,000 tons), and at least 2005th year (601,700 tons), a difference of 39.7%, the highest average yield was recorded 2008th year (5.8 t / ha) and lowest 2003rd year (2.5 t / ha), a difference of 56.9%. The country's largest producers of wheat in the EU are France with an average production of 36,849,600 tons (27%), followed by Germany 23,149,200 tons (17%), United Kingdom 14,846,000 tons (11%) and Poland with an average production of 8931.000 tones (7%), the data relate to the period 2002nd to 2013th Croatia's joining the EU market ranks 22nd with an average production in that period 776,500 tons (0.57%). Considering that the Republic of Croatia in the 80s of the last century produced an average of 1.55 million tons of wheat, there is a possibility of increasing production of wheat in Croatia. With the above production Croatia would be the 16 position in the European Union by the total production of wheat. Comparison of purchase prices of wheat in the Republic of Croatia with the European Union, noted that in the period 2002nd to 2008th year, prices in Croatia significantly higher than market prices in the European Union, except for the 2003rd and 2006th year when the deviation was minimal. After the start of negotiations with the EU 2005th, are less noticeable fluctuations in the formation of purchase prices of wheat, except for the 2008th year when the difference was greatest (RH 1.9 EUR, EU 1.3 EUR). Over a period of 2009th until the 2013th year, according to the approximation of Croatian accession to full membership, the average difference between the purchase price of wheat between Croatia and the EU was minimal. The analysis of the level of production of wheat flour per production unit-mill statutory member countries, it was found that the Republic of Croatia with 2,423 tons worth the 20 position, and the production capacity utilization of 40% on the back of the European Union. Utilization of production capacities of other Member States is high, the maximum values of 85% was recorded in the Netherlands, 80%, Austria, Germany and the UK have 80% utilization, the remaining member countries use their processing facilities mill-sector in the range of 60-80%, with the exception of Spain, which is at 50% capacity utilization of production. The Republic of Croatia in the processing of wheat from its own production (99.5%), the minimum quantity imported and the country of the European Union (0.5%). In order to determine the status and trends in the market of wheat flour in the Republic of Croatia, conducted the field research establishing offers unbundled products in department retailers

active on the Croatian territory. The analysis of the individual product it was found that the most common wheat white flour products (T-550) smoothly ($Z = 38$, 22%), followed by wheat white flour (T-550) sharply ($Z = 23$, 13.5%) and semi-white wheat flour type 850, ($Z = 21$, 12.2%). The remaining types of flour are represented in approximately proportion to the value of the interval ($Z = 8-13$, 4.7 to 7.6%). Fixed Height overall representation of wheat flour by type ($\bullet Z = 171$). For research purposes, with the aim of determining the competitiveness of segments of wheat production in Croatia, are collected and analyzed a total of 130 questionnaires. Data collection was carried out in January-June 2013, filling out questionnaires in the area of five counties of eastern Croatian. Were analyzed separately ordinal variable type (single variable thematic areas attitudes on wheat production) and variable quantitative (demographic and agro). Derived variables (obtained from the analysis of the main components for the group variables attitudes) were obtained from areas: macroeconomic arguments, technical and technological, market claims and allegations of the international environment and production concept. They then determined the demographic and agro economic indicators related to the production of wheat, and established the connection between the thematic areas of views on the production of wheat, as well as the differences between counties and forms of economy in the attitudes of wheat production. The data analysis of wheat processing, covered a total of 18 mills of different processing capacities and age of building, in order to collect data on the facts, the conditions of production and sales, and for an overview of the competitive position of separated sector on the Croatian market and the single market of the European Union. In this case analyzed are also particularly variable of ordinal type (individual variables thematic areas attitudes on wheat processing) and variable quantitative (demographic and agro). Average sum of estimates for individual attitudes thematic areas of attitudes about the processing of wheat, yield information about the differences in positivity rates for areas allegations: macroeconomic, technical and technological, market, and conceptual claims about the international environment. The most positive attitudes were found for technical and technological claims, and the most negative for thematic macro-economic claims. Calculations were performed using the competitiveness of domestic resource costs (DRC), the formation of the analytical matrix (PAM) (Monke, Pearson 1989). Calculating the isolated coefficient (DRC), has not confirmed the competitiveness of Croatian wheat production, domestic prices towards parity in relation to the EU market. To separate the wheat processing segment, the application of these methods is determined by neutral status competitiveness by DRC coefficient. Today was the economic efficiency rating of Croatian production and processing of wheat also method of calculating the coefficient of the DRC, preamble set scenarios; maintain production at current level (DRC production 1,19 - negative competitiveness, DRC processing 1 - neutral status), the level of reduction of 50% for both manufacturing factors (DRC production of 2,39 - not competitiveness, DRC processing not changed - a neutral one), minimizing the mill sector while maintaining the production of wheat at the same level (DRC production of 1,19 negative competitiveness, DRC processing is 0,45 indicating a competitive business). The analysis of the data identified necessary adjustments are possible standards of business, foreign trade, foreign trade protection and domestic support under the Common Agricultural Policy (CAP). Given the data collected in the recessionary conditions of production and processing, and

performed analysis confirmed the presence diseconomy between sectors of production and processing of wheat, and also confirmed that maintaining or increasing the production and processing of wheat positively affects the stability of rural areas covered by the survey. Performed calculations based on data collected in recessionary conditions have shown the interdependence of production and processing of wheat also was found to exist for a quantitative and qualitative increase in the production and processing of wheat in Croatia.

Keywords: competitiveness, wheat, milling industries, DRC, Croatia, European Union

9. PRILOG

Opći uvjeti kvalitete pšenice kao sirovine za mlinsku industriju – norma Europske unije

Pod pšenicom se podrazumijeva zrnena masa vrste *Triticum aestivum* koja sadrži najmanje 80% osnovne zrnene mase. Pšenica mora biti zdrava, zrela, svojstvenog izgleda, mirisa i okusa. Pod kvalitetom pšenice podrazumijeva se skup svojstava pšenične mase koje se određuju preko:

a) Organoleptičkih svojstava

Ne smije imati miris i okus na plijesni, skladište, štetočine, na sjemenke korova, na strane tvari kao što su petrolej, sumpor, sredstva za zaštitu bilja i uništavanje štetočina.

b) Količine i vrste primjesa

Primjesi su svi sastojci koji nisu osnovna zrnena masa i dijele se na organske i anorganske primjese i primjese životinjskog podrijetla. Organske primjese dijele se na organske bijele i organske crne primjese. Organske bijele primjese nisu štetne za ljudsko zdravlje (lomljenja zrna, štura zrna, druge žitarice, proklijala zrna i nagrižena zrna – npr. žitne stjenice). Organske crne primjese su primjese koje su štetne za ljudsko zdravlje ili utječu na boju, miris i okus žitarica i njihovih proizvoda (korovi, glavica raži – bolest raženog zrna, pokvarena zrna, glavničava zrna – snijet, nečistoće organskog porijekla. Anorganske primjese su zemlja, pijesak, prašina, staklo, metal i drugo. Primjese životinjskog porijekla su dijelovi insekata i insekti.

Standardna kvaliteta: udio nečistoća 5%

c) Količine vlage

viša cijena $\leq 13,5\%$ \geq niža cijena pšenične zrnene mase

d) Hektolitarska masa ili volumna masa – masa 1 hektolitra ili 1000 L pšenične zrnene mase preračunata na 13,5% vlage u pšenici

niža cijena ≤ 76 kg/hl \geq viša cijena pšenične zrnene mase

e) Sedimentacijska vrijednost

SE - Pod sedimentacijskom vrijednošću podrazumijeva se volumen nastalog taloga dobivenog pod određenim uvjetima u suspenziji brašna i mliječne kiseline prema standardnoj metodi. Kreće se u rasponu od 0-70 cm³.

f) Klase kvalitete pšenice (količina proteina i SE)

Količina proteina – metodom po Kjeldahlu (količina N x 5,7 n % na s.tv. zrna)

Klase kvalitete

4. SE > 40 proteini > 13% s.t.
5. SE > 30 proteini > 11,5% s.t.
6. SE > 18 proteini > 10% s.t.

Ostale pšenice ne mogu se upotrebljavati za prehranu ljudi.

g) Prisutnosti štetočina

Pšenice za ljudsku upotrebu ne smiju sadržavati žive skladišne štetočine.

h) Prisutnosti mikroorganizama

Prisutnost mikroorganizama i ostatka sredstava za zaštitu bilja regulirano je posebnim Pravilnicima.

i) Prisutnosti ostatka sredstava za zaštitu bilja i uništavanje korova i štetočina

Prisutnost ostatka sredstava za zaštitu bilja regulirano je posebnim Pravilnicima.

(Ministarstvo poljoprivrede Republike Hrvatske, 2013.)

ŽIVOTOPIS

Pristupnik Davor Balaž rođen je 24. listopada 1973. godine u Osijeku, RH. Osnovnu školu završio je u Vladislavcima. Maturirao je s odličnim uspjehom 1992. godine u Poljoprivrednom školskom centru Osijek. Godine 1992. upisuje Poljoprivredni fakultet u Osijeku, četverogodišnji studij - smjer Ratarstvo, na kojem je i diplomirao 1997. godine, uz mentorstvo prof.dr.sc. Irme Kalinović, s radom "Skladištenje suncokreta u IPK Tvornici ulja Čepin".

Godine 1997. i 1998. pohađa školovanje pri Hrvatskom vojnom učilištu „Petar Zrinski“ i stječe čin poručnika.

Do sada je bio zaposlen u IPK Osijek, RJ Vuka i Čepin, na radnom mjestu tehnologa u ratarskoj proizvodnji (1999.-2005.). Godine 2005. zapošljava se u Ministarstvu poljoprivrede, šumarstva i vodnog gospodarstva u Ravnateljstvu za tržišnu i strukturnu potporu na radnom mjestu savjetnika za trgovinske mjere. Godine 2008. prelazi u Upravu poljoprivrede i prehrambene industrije, Sektor inspeksijskih poslova, na radno mjesto inspektora u Ministarstvu poljoprivrede, gdje radi do danas.

U 2007. godini boravi u Wageningen (Nizozemska) i Leuven (Belgija), u okviru kolegija Zajednička poljoprivredna politika Europske Unije, u organizaciji MTEC-A, Wageningen Business School i University of Leuven.

U ožujku 2008. godine upisuje poslijediplomski specijalistički studij „Upravljanje ekonomskim razvojem“ na Ekonomskom fakultetu u Osijeku, gdje je 11.01.2010. uspješno obranio magistarski specijalistički rad pod naslovom „Zajednička poljoprivredna politika Europske unije, bitna odrednica razvoja poljoprivredne proizvodnje u Republici Hrvatskoj“ uz mentorstvo prof.dr.sc. Ivane Barković.

Poslijediplomski doktorski studij „Poljoprivredne znanosti“, smjer "Agroekonomika" upisao je akademske 2010./2011. školske godine. Do sada je položio sve upisane module s prosječnom ocjenom izvrstan. Oženjen je i otac dvoje djece.

Popis objavljenih radova

1. Balaž D., Leko Šimić M., Štimac H. (2012): Marketing Environment in Croatian Food Industry, 32th Scientific Symposium: From Old Industries to a New Entrepreneurial Development Structure – Reality and Challenges for Pforzheim and Osijek, Faculty of Economics in Osijek – Josip Juraj Strossmayer University in Osijek, Hochschule Pforzheim – Pforzheim University; str. 33-41, Osijek
2. Balaž D. (2012): Market analysis of honey in Osijek-Baranya County, 1. International Conference "Greening Business through the Enterprise Europe Network", Poster session, Josip Juraj Strossmayer University of Osijek, Faculty of Agriculture in Osijek.
3. Balaž D., Crnčan A. (2013): Primjena HACCP sustava u proizvodnji konzumnih jaja, Zbornik radova 48. hrvatskog i 8. međunarodnog simpozija agronoma ,Poljoprivredni fakultet u Osijeku, str. 138-142 (poster,međunarodna recenzija, objavljeni rad, stručni), Dubrovnik.
4. Balaž D., Zmaić K. (2014): Competitvity of croatian milling industries; Domestic resource cost approach, Proceedings, 7th International Congress "Flour-Bread '13" and the 9th Croatian Congress of Cereal Technologists "Brašno-Kruh '13., str. 59-68 (prezentacija, međunarodna recenzija, objavljeni rad, stručni), Opatija.
5. Balaž D., Sindik J. (2014.): Analiza stavova proizvođača pšenice na području istočne hrvatske u odnosu na izdvojene agroekonomske pokazatelje, Poljoprivreda, 20(2): 53-60 (znanstveni rad).