Razvrstavanje krušnog brašna prema zahtjevima prerađivača primjenom statističkih metoda

Katić, Luka

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, FACULTY OF FOOD TECHNOLOGY / Sveučilište Josipa Jurja Strossmayera u Osijeku, Prehrambeno-tehnološki fakultet Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:109:294979

Rights / Prava: Attribution-NonCommercial-NoDerivatives 4.0 International/Imenovanje-Nekomercijalno-Bez prerada 4.0 međunarodna

Download date / Datum preuzimanja: **2024-04-20**

Repository / Repozitorij:

Repository of the Faculty of Food Technology Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
PREHRAMBENO-TEHNOLOŠKI FAKULTET OSIJEK

Luka Katić

RAZVRSTAVANJE KRUŠNOG BRAŠNA PREMA ZAHTJEVIMA PRERAĐIVAČA PRIMJENOM STATISTIČKIH METODA

DIPLOMSKI RAD

Osijek, rujan, 2019.

TEMELJNA DOKUMENTACIJSKA KARTICA

DIPLOMSKI RAD

Sveučilište Josipa Jurja Strossmayera u Osijeku
Prehrambeno-tehnološki fakultet Osijek
Zavod za procesno inženjerstvo
Katedra za modeliranje, optimiranje i automatizaciju
Franje Kuhača 20, 31000 Osijek, Hrvatska

Diplomski sveučilišni studij Procesno inženjerstvo

Znanstveno područje: Biotehničke znanosti
Znanstveno polje: Prehrambena tehnologija
Nastavni predmet: Modeliranje i upravljanje u prehrambeno-tehnološkim procesima
Tema rada je prihvaćena na X. redovitoj sjednici Fakultetskog vijeća Prehrambeno-tehnološkog fakulteta Osijek u akademskoj godini 2017./2018. održanoj 12. srpnja 2018. godine
Mentor: prof. dr. sc. *Damir Magdić*, trajno zvanje
Komentor: dr. sc. *Daniela Horvat*, znan. savjetnik, trajno zvanje

Razvrstavanje krušnog brašna prema zahtjevima prerađivača primjenom statističkih metoda

Luka Katić, 0113137991

Sažetak:
Tijekom 10 godina na Poljoprivrednom institutu u Osijeku prikupljeni su podaci za 16 izmjerenih i 3 izračunata kemijska i reološka svojstva brašna od 24 kultivara pšenice. Deskriptivnom statističkom i kemometrijskom analizom svojstava brašna određeni su međusobni odnosi i odnosi prema zahtjevima prehrambene industrije. Rezultati su obrađeni programskim paketom Statistica 13. Deskriptivnom statistikom izračunate su srednja vrijednost, standardna devijacija, minimalne i maksimalne vrijednosti svojstva te koeficijent varijabilnosti. Klaster analizom svrstane su određene grupe kultivara i zahtjeva po sličnim vrijednostima svojstava. Faktorskom analizom razvrstani su kultivari i zahtjevi po razlikama u prve dvije faktorske ravnine. Klasterska i faktorska analiza omogućile su precizno očitavanje sličnosti i razlika kultivara i zahtjeva proizvođača. Iz rasporeda kultivara i zahtjeva u prve dvije faktorske ravnine može se, s preciznošću većom od 99 %, očitati koji kultivar bi bio prikladan za određene zahtjeve za brašno. Ova informacija može biti korisna proizvođačima prilikom nabave sirovina.

Ključne riječi: brašno, deskriptivna statistika, kemometrija, zahtjevi proizvođača

Rad sadrži: 39 stranica
10 slika
6 tablica
29 literaturnih referenci

Jezik izvornika: hrvatski

Sastav Povjerenstva za ocjenu i obranu diplomskog rada i diplomskog ispita:

1.	doc. dr. sc. *Antun Jozinović*	predsjednik
2.	prof. dr. sc. *Damir Magdić*, trajno zvanje	član-mentor
3.	dr. sc. *Daniela Horvat*, znan. savjetnik, trajno zvanje	član-komentor
4.	izv. prof. dr. sc. *Đurđica Ačkar*	zamjena člana

Datum obrane: 11. rujan, 2019.

Rad je u tiskanom i elektroničkom (pdf format) obliku pohranjen u Knjižnici Prehrambeno-tehnološkog fakulteta Osijek, Franje Kuhača 20, 31000 Osijek.

BASIC DOCUMENTATION CARD

GRADUATE THESIS

University Josip Juraj Strossmayer in Osijek
Faculty of Food Technology Osijek
Department of Process Engineering
Subdepartment of Modelling, Optimization and Automatization
Franje Kuhača 20, HR-31000 Osijek, Croatia

Graduate program Process Engineering

Scientific area: Biotechnical sciences
Scientific field: Food technology
Course title: Modelling and management in food technology processes
Thesis subject was approved by the Faculty of Food Technology Osijek Council at its session no. X held on date, e.g. July 12, 2018.
Mentor: *Damir Magdić*, PhD, tenured prof.
Co-mentor: *Daniela Horvat*, PhD, tenured sci. adv.

The Classification of Bread Flour According to the Requirements of the Processors Using Statistical Methods

Luka Katić, 0113137991

Summary:

Over a period of ten years, the data for sixteen measured and three calculated chemical and rheological properties of twenty four wheat cultivars were measured at the Agricultural Institute Osijek. The descriptive statistics and chemometric analysis of wheat properties determined mutual relationships and its relations the demands of the food industry. The results were analysed through Statistica 13 program. Descriptive statistics of the results showed the mean value, the standard deviation, minimal and maximal value, and variability coefficient. Through cluster analysis, cultivar groups and demand groups were classified by similar value. Factor analysis classified cultivars and demands by diversity into the first two factor axes. Cluster and factor analysis enabled a precise reading of the similarities and differences of both the cultivars and the demands. From the position of the cultivars and the demands on the graphs from the first two factor analyses, it is possible to determine which cultivar is suitable for certain wheat demands, while being more than 99% accurate. This information can be useful to the manufacturers when buying raw materials.

Key words: wheat, descriptive statistics, chemometric, manufacturers demands

Thesis contains: 39 pages
10 figures
6 tables
29 references

Original in: Croatian

Defence committee:

1. *Antun Jozinović, PhD, assistant prof.* — chair person
2. *Damir Magdić, PhD, tenured prof.* — supervisor
3. *Daniela Horvat, PhD, tenured sci. adv.* — co-supervisor
4. *Đurđica Ačkar, PhD, associate prof.* — stand-in

Defence date: September 11, 2019.

Printed and electronic (pdf format) version of thesis is deposited in Library of the Faculty of Food Technology Osijek, Franje Kuhača 20, 31000 Osijek.

Veliko hvala mentoru prof. dr. sc. Damiru Magdiću na znanju koje je prenio na mene, strpljivosti, profesionalnosti, ljubaznosti i usmjeravanju ka inženjerskom načinu razmišljanja.

Zahvaljujem se i dr. sc. Danieli Horvat na profesionalnosti, pomoći i savjetima te Poljoprivrednom institutu Osijek na pristupačnosti.

Posebno se zahvaljujem roditeljima, prijateljima i djevojci Ani koji mi iz dana u dan pokazuju da imam punu podršku od njih i da mi čuvaju leđa u dobru i zlu.

Sadržaj

1. UVOD 7
2. TEORIJSKI DIO 1
2.1. Pšenica 2
2.1.1. Kemijske karakteristike pšenice 2
2.1.2. Fizikalne karakteristike pšenice 4
2.2. Brašno 5
2.2.1. Tipovi brašna 5
2.2.2. Svojstva brašna 6
2.3. Kruh i peciva 9
2.4. Matematičke i statističke metode 10
2.4.1. Deskriptivna statistika 10
2.4.2. Kemometrijske analize 11
3. EKSPERIMENTALNI DIO 13
3.1. Zadatak 14
3.2. Materijali i metode 14
3.2.1. Materijali 14
3.2.2. Metode 17
4. REZULTATI 22
4.1. Statistička obrada podataka 22
5. RASPRAVA 33
6. ZAKLJUČCI 36
7. LITERATURA 38

Popis oznaka, kratica i simbola

P	eng. *Protein*, udio proteina
SED	eng. *Sedimentation*, vrijednost sedimentacije
WG	eng. *Wet gluten*, vlažni gluten
GI	eng. *Gluten index*, gluten indeks
FN	eng. *Falling number*, broj padanja
FY	eng. *Flour yield*, izbrašnjavanje
WG/P	eng. *Wet gluten/Protein*, omjer vlažnog glutena i udjela proteina
WA	eng. *Water absorption*, sposobnost upijanja vode
DDT	eng. *Dough development time*, vrijeme razvoja tijesta
STAB	eng. *Stability*, stabilnost tijesta
R	eng. *Resistance*, otpor
DS	eng. *Degree of softening*, stupanj omekšanja
FQN	eng. *Farinograph quality number*, Farinografski broj kakvoće
E	eng. *Energy*, energija tijesta
R5MIN	eng. *Resistance after 5 minute*, otpor kroz pet minuta
RMAX	eng. *Maximum Resistance*, maksimalni otpor
EXT	eng. *Extensibility*, rastezljivost tijesta
R/EXT	eng. *Resistance/Extensibility*, omjer otpora i rastezljivosti tijesta
RMAX/EXT	eng. *Maximum Resistance/Extensibility*, omjer maksimalnog otpora i rastezljivosti tijesta
FJ	Farinografska jedinica
EJ	Ekstenzografska jedinica
QG	eng. *Quality group*, kvalitetna grupa
PCA	eng. *Principal components analysis*, analiza glavnih komponenti
CA	eng. *Cluster analysis,* klaster analiza

1. UVOD

Najvažniji proizvod pšenice svakako je brašno. Brašno služi kao baza velikog broja različitih proizvoda kao što su kruh, različita peciva, keksi, krekeri, vafli pa čak i u konditorskoj i farmaceutskoj industriji. Naravno, kada se pogleda ovakva paleta proizvoda kojima je baza brašno, može se zaključiti da je brašno jako važan ako ne i najvažniji proizvod za prehranu čovječanstva. Postoji više vrsta pšenica što nam dalje govori da postoji i više vrsta brašna. Vrsta brašna ovisi o biološkim, fizikalnim i kemijskim karakteristikama zrna, agrotehničkim karakteristikama, klimi ali i o načinu, odnosno tehnologiji mljevenja pšenice.

Svaki proizvod, prerađivači i proizvođači imaju određene zahtjeve za brašno ovisno o krajnjem proizvodu. Zahtjevi mogu biti uvjetovani zakonodavstvom, odnosno zakonski donesenim karakteristikama proizvoda, ali i politikom same tvrtke koja teži određenoj razini kvalitete. Stoga, uistinu je bitno usmjeriti pažnju na samu dobavu brašna kao sirovine i karakteristike dobavljane sirovine. Poznato je da kvaliteta sirovina u odnosu na krajnji proizvod utječe na ekonomske odrednice i krajnju dobit tvrtke. Naime, nerijetko su potrebni različiti dodatci odnosno aditivi koji bi, zbog nedovoljno kvalitete dolazne sirovine u odnosu na krajnji proizvod, osigurali karakteristike proizvoda unutar zadanih okvira. Aditivi su financijski izdatak koji bi se mogao regulirati kvalitetnijim izborom sirovine.

Lakše tumačenje velikog seta podataka omogućuje statistički pristup koji se zove kemometrija. Zapravo, radi se o primjeni statistike i alata statistike prilikom analize kemijskih podataka (Ukić, 2016). Podatci koji se najčešće analiziraju kao svojstva brašna su: vlažni gluten, broj padanja, razvoj tijesta, upijanje vode, stabilnost tijesta, rastezljivost tijesta, otpor, rezistencija, energija, kvalitetna grupa itd. Uređaji za analizu brašna su uređaji koji određuju reološka svojstva. To su uređaji poput farinografa, ekstenzografa, amilografa i alveografa.

Cilj ovog diplomskog rada je uvidjeti koliko kemometrija kao statistički pristup podatcima za određena svojstva brašna može pridonijeti razvrstavanju krušnog brašna prema zahtjevima prerađivača.

2. TEORIJSKI DIO

2.1. Pšenica

Pšenica je jedna od najvažnijih biljaka u vidu izvora hrane za čovjeka još od vremena prelaska s nomadskog na sjedilački način života. Geografsko podrijetlo pšenice još uvijek nije u potpunosti ustanovljeno. Arheološki nalazi ukazuju da se pšenica i njen uzgoj počeo razvijati na Sirijskoj visoravni negdje oko 6000 godina prije Krista (Belderok i sur., 2000). Daljnjim razvojem čovječanstva razvijaju se načini primjene i prerade pšenice. Tehnikom mljevenja dolazi do prvih oblika brašna a nadalje, primjenom vatre, do prvih oblika kruhova i peciva. Botanički, pšenica se svrstava u porodicu trava roda *Triticum* i postoji 27 baznih vrsta pšenice (Kljusurić, 2000). Razvojem genetičkog inženjerstva razvijale su se različite vrste i sorte pšenica koje su se razlikovale u svojim karakteristikama. Upravo ta raznolikost je potrebna s obzirom na veliku paletu krajnjih proizvoda baziranih na pšeničnom brašnu. Pšenica je jednogodišnja biljka koja se sastoji od korijena, stabljike, listova i klasa. Za prehranu, odnosno za proizvodnju brašna koristi se samo zrno tj. sjemenka.

Zajednički predak svih vrsta pšenica je jednozrna pšenica koja je križanjem s nepoznatom biljkom dala jednozrnu pšenicu sa sedam kromosoma koji određuju svojstva pšenice. No, ne koriste se sve vrste pšenice za industrijsku i svakodnevnu proizvodnju brašna. Naime, vrste pšenice se, na temelju strukture zrna, mogu grubo podijeliti na meke i tvrde. Od mekih pšenica, za proizvodnju brašna značajne su vrste *Triticum aestivum* i *Triticum compatum* (patuljasta pšenica), a od tvrdih pšenica *Triticum durum* (Kljusurić, 2000). Neke vrste pšenice sadrže manje glutena i stoga se manje koriste za proizvodnju kruha, dok se tvrde vrste s više glutena koriste za proizvodnju kruha.

2.1.1. Kemijske karakteristike pšenice

Pošto je zrno pšenice najbitnije za prehrambenu industriju odnosno za proizvodnju brašna, potrebno je objasniti kemijski sastav i morfologiju samog zrna. Naime, zrno pšenice se sastoji od omotača ploda i sjemena, aleuronskog sloja, endosperma i klice. Omotači ploda i sjemena zajedno čine posije, a za proizvodnju brašna najvažniji je endosperm (Ugarčić-Hardi, 1999a). Kemijski sastav zrna pšenice također ovisi o genetičkim predispozicijama i o vanjskim uvjetima kao što su klima, vlaga tla i zraka, karakteristike tla itd. Općenito se može reći da se zrno pšenice sastoji od ugljikohidrata, proteina, masti i mineralnih tvari i vitamina. Kemijski sastav pojedinog zrna literaturno se prikazuje odnosom masenih udjela proteina, škroba, šećera (celuloze i pentozana), masti i pepela (**tablica 1**).

Tablica 1 Kemijski sastav pojedinih dijelova pšeničnog zrna (Ugarčić-Hardi, 1999a).

Dio zrna	Maseni udio (%)						
	Proteini	Škrob	Šećeri	Celuloza	Pentozani	Masti	Pepeo
Cijelo zrno (100 %)	16,07	63,07	4,32	2,76	8,1	2,24	2,18
Endosperm (81,5 %)	12,91	78,92	3,54	0,3	2,78	0,68	0,45
Aleuronski sloj (6,44 %)	32	_	6,82	6,41	15,44	8,16	10,93
Klica (3,24 %)	37,63	_	25,12	2,41	9,74	19,04	6,32
Ovojnice (8,82 %)	10,56	_	2,59	51,4	21,1	2,4	7,0

Endosperm je prema svom sastavu većinom građen od škroba tj. približno 80 %. Uzme li se u obzir da endosperm čini više od 80 % cijelog zrna, i činjenicu da je endosperm najvažniji za proizvodnju brašna, može se vidjeti da je škrob jedno od bitnih sastavnica i samog brašna. Proteini su također veoma važna sastavnica zrna pšenice pa tako i brašna. Najveći dio proteina koncentriran je u aleuronskom sloju i klici. Škrob je polisaharid koji je građen od molekula glukoze koje su međusobno povezane α 1-4 i α 1-6 vezama (Kljusurić, 2000). Višak hranjivih tvari se u endospermu skladišti u obliku škrobnih granula. Granula škroba građena je od amiloze i amilopektina u omjeru: 20-25 % amiloze i 75-80 % amilopektina. Amiloza predstavlja ravni lanac molekula glukoze međusobno povezanim α 1-4 vezama, a amilopektin predstavlja razgranatu strukturu međusobno povezanih molekula glukoze koja na mjestima grananja ima α 1-6 vezu. Škrob je važan za proces želatinizacije odnosno bubrenja prilikom prisustva vode i temperature u intervalu 60-80 °C (Ugarčić-Hardi, 1999a). Proteini koji se nalaze u pšenici su albumin, globulin, gliadin i glutenin. Proteini su se podijelili po sposobnosti topljenja u vodi. Naime, albumini i globulini su topljivi u vodi, dok gliadin i glutenin čine proteine netopljive u vodi. Proteini netopljivi u vodi bubre u prisustvu vode i međusobno tvore umreženu strukturu koja se naziva gluten i jedna je od najvažnijih karakteristika brašna.

2.1.2. Fizikalne karakteristike pšenice

Fizikalne karakteristike su također važne kako bi se mogla odrediti kvaliteta i namjena pšenice. Karakteristike koje se analiziraju su:

- Hektolitarska masa – masa jednog hektolitra pšenice izražena u kilogramima odnosno kg/hL. Ovisi o načinu sipanja, obliku i oštećenjima pšenice, staklavosti itd.
- Apsolutna masa – masa osušenih, neoštećenih 1000 zrna. Apsolutna masa se izražava u gramima (g).
- Oblik i krupnoća zrna – određuje se dužinom, širinom i debljinom izraženim u milimetrima (mm). Poželjno što krupnija i okruglija zrna.
- Specifična masa – funkcija odnosno omjer mase i volumena g/cm^3. Može se očitati kompaktnost endosperma.
- Tvrdoća i staklavost zrna – Kruh visoke kvalitete pravi se iz brašna s visokim udjelom proteina odnosno bjelančevina. Tvrdoća i staklavost zrna su određena udjelom bjelančevina u endospermu.
- Boja zrna – sortno svojstvo. Najčešće sorte su s crvenim, bijelim i miješanim zrnom. Odstupanje od ovih boja većinom je znak fizičkog ili biološkog oštećenja.
- Oštećenost zrna – rezultat manipulacije zrnom prije same prerade. Potrebno odrediti stupanj oštećenosti i značenje istog za prinos i kvalitetu proizvoda.Čistoća zrna i primjese - uzima se kao kvalitetno svojstvo, budući da svaka primjesa smanjuje vrijednost pšenice, a neke primjese teško se ili nikako ne mogu izdvojiti, tako da se prerađuju zajedno s zrnom pšenice. Postoje crne primjese, bijele primjese i korovsko sjemenje (Krička i sur., 2002).

2.2. Brašno

Mljevenjem zrna pšenice dobiva se brašno. Ovisno o zahtjevima za brašno melje se cijela sjemenka ili samo endosperm. Ako je zahtjev za brašno s većim udjelom mekinja tj. tamnijim brašnom, onda se melje cijelo zrno. Nadalje, ako je zahtjev za brašno sa što manjim udjelom mekinja tj. za bijelo brašno, onda se melje samo endospermni dio zrna dok se omotač zrna odvaja.

2.2.1. Tipovi brašna

Kada se brašno razvrstava po tipovima, tada je kriterij raznolikosti udio pepela, odnosno mineralnih tvari brašna (Horvat, 2010). Naravno, brašna se ne razlikuju samo u mineralnom sastavu, nego i u udjelu škroba, celuloze, vitamina i drugih sastojaka karakterističnih za brašno. Što su više uklonjeni omotač i klica dobije se brašno nižeg tipa, odnosno brašno s manje hranjivih tvari. Tip brašna se označava tako da se maseni udio mineralnih tvari pomnoži s 1000. Tako npr. ako brašno sadrži 0,45 % mineralnih tvari radi se o brašnu T-450. Po propisima, pšenično brašno se svrstava u tipove: T-400 (bijelo brašno), T-500 (bijelo brašno), T-850 (polubijelo) i T-1100 (crno) i brašna između ovih intervala (**tablica 2**) (Žeželj, 2005). Za pretpostaviti je da nema svako brašno točno određeni tip odnosno točan udio minerala kako bi se fiksno mogao svrstati u navedene tipove. Stoga, postoje i prijelazni tipovi i intervali udjela mineralnih tvari koji određuju pripadnost određenog brašna nekom od tipova brašna.

Tablica 2 Tipovi brašna prema intervalu udjela mineralnih tvari

Maseni udio (%)	Tip brašna
0,45	Krupica i bijelo brašno T-450
0,45-0,55	Bijelo brašno T-500
0,55-0,60	Bijelo brašno T-550
0,65-0,75	Polubijelo brašno T-700
0,75-0,85	Polubijelo brašno T-800

Bijela brašna sadrže malo proteina i celuloze ali je kvaliteta glutena dobra što daje dobru pecivost kao karakteristiku bijelog brašna. Polubijela brašna sadrže više proteina, masti i celuloze ali i veću enzimsku aktivnost koja nadalje znači lošija reološka svojstva. Gluten je za polubijela brašna lošije kvalitete u odnosu na bijela brašna.

2.2.2. Svojstva brašna

Svojstva brašna koja se analiziraju u svrhu određivanja kvalitete brašna i njene optimalne namjene su vlažni gluten, broj padanja, moć upijanja vode, razvoj tijesta, stabilnost tijesta, rezistencija, stupanj mekšanja, rastezljivost, kvalitetna grupa, otpor, maksimalni otpor, omjer otpora i rastezljivosti, energija i maksimalni viskozitet. Neka od tih svojstava se ubrajaju u reološka svojstva tijesta koje brašno tvori u kombinaciji s vodom i mjerenja se vrše na uređajima kao što su farinografi, ekstenzografi, amilografi i alveografi.

Kao što je spomenuto proteini brašna netopljivi u vodi su gliadin i glutenin. Prilikom dodatka vode ti proteini bubre i tvore međusobnu mrežastu strukturu koja se naziva gluten. Ispiranjem brašna vodom ostaje vlažni gluten. Udio vlažnog glutena izražava se u postotku i veoma je važan za karakteristike tijesta i krajnjeg proizvoda. Ako je udio vlažnog glutena ispod 14 % označava se kao veoma mali i može se reći da u tom udjelu pridonosi loše karakteristike tijesta (**tablica 3**).

Tablica 3 Udio vlažnog glutena i ocjena takvog brašna (Kljusurić, 2000).

Udio vlažnog glutena (%)	Ocjena
≤14	Vrlo mali
14-20	Mali
21-24	Zadovoljavajući
25-27	Dobar
≥27	Vrlo dobar

Broj padanja je karakteristika u korelaciji s α-amilazom tj. enzimskom aktivnošću. On je obrnuto proporcionalan amilolitičkoj aktivnosti. Broj padanja se definira kao ukupno vrijeme od trenutka ulaganja kivete suspenzije (tijesta) u vodenu kupelj pa do kraja penetracije miješalice viskozimetra kroz škrobni gel, odnosno vrijeme potrebno za miješanje smjese u kojoj se škrob nalazi u fazi likvefakcije (Ugarčić-Hardi, 1999b).

Prilikom miješanja brašna i vode dobije se tijesto. Konzistencija i svojstva tijesta uvelike ovise o količini dodane vode i o moći upijanja vode. Moć upijanja vode također je bitno i iz ekonomskog aspekta jer utječe na prinos krajnjeg proizvoda. Moć upijanja vode zavisi o sposobnosti proteina u brašnu da kemijski ili fizikalno adsorbiraju vodu i pri tome bubre tvoreći

koloidni sustav (Kljusurić, 2009). Stupanj izmeljavanja je obrnuto proporcionalan moći upijanja vode. Moć upijanja vode izražava se u postotcima i u pekarstvu vrijednosti su od 50 % (slaba brašna) do 65 % (jaka brašna) (Kljusurić, 20009). Mjerenja moći upijanja vode odvijaju se na farinografu.

Farinograf je uređaj kojim se određuju određena reološka svojstva tijesta. Farinograf je zapravo uređaj koji mjeri otpor koje tijesto vrši prilikom miješanja. Mjerenje se vrši u intervalu od prvog formiranja tijesta, maksimalnog razvoja do zaustavljanja miješalice. Graf koji nam prikazuje korelaciju otpora (ordinata) izraženog u farinografskim jedinicama (FJ) i vremena (apscisa) izraženog u minutama naziva se farinogram. Dogovoreno je da maksimalna konzistencija tijesta na farinogramu bude točno 500 farinografskih jedinica (Ugarčić-Hardi, 1999b). Dakle, potrebno je znati koliko vode je potrebno dodati da bi se dobila određena konzistencija. Taj podatak nam otkriva moć upijanja vode. Veličine koje se mogu iščitati s farinograma su:

- Razvoj tijesta – vrijeme u minutama (min) od početka mjerenja do postignute optimalne konzistencije.
- Stabilnost tijesta – vrijeme u minutama (min) kroz koje je konzistencija tijesta konstantna.
- Rezistencija tijesta – vrijeme u minutama (min) koje predstavlja zbroj vremena razvoja i stabilnosti tijesta.
- Stupanj mekšanja – označava razliku u čvrstoći tijesta od početka mekšanja i daljnjeg miješanja nakon 15 min. Izražava se u farinografskim jedinicama (FJ).Rastezljivost i elastičnost – širina krivulje odnosno amplituda pomicanja pisača prilikom ispisa farinograma.
- Kvalitetna grupa – povezana s kvalitetnim brojem. Kvalitetni broj predstavlja površinu ispod krivulje konzistencije i linije povučene kroz sredinu farinograma (Kljusurić, 2000).

Ekstenzograf je također uređaj za mjerenje reoloških svojstava. Ekstenzograf radi na temelju mjerenja otpora izraženog u ekstenzografskim jedinicama (EJ) koje tijesto pruža od razvlačenja do kidanja. Tijesto se prethodno zamijesi na farinografu 5 minuta, te se oblikuje i stavlja u

kalupe na odmaranje tijekom 45 minuta. Nakon toga provodi se mjerenje (razvlačenje komada tijesta pomoću kuke ekstenzografa do pucanja). Ukupni postupak se ponavlja (Hoseney, 1994). Veličine koje se mogu iščitati pomoću ekstenzografa su:

- Otpor – veličina sile kojom se tijelo suprotstavlja rastezanju. Izražava se u EJ. Označava se slovom O.
- Rastezljivost (otpor rastezanju) – Označava se slovom R. Rastezljivost je dužina osnovice ekstenzograma na apscisi od početka rastezanja do pucanja. Izražava se u milimetrima (mm).
- Omjer otpora i rastezljivosti – O/R predstavlja vladanje tijesta prilikom rastezanja.
- Maksimalni otpor – predstavlja maksimalnu visinu krivulje na ekstenzogramu. Izražava se u EJ.
- Energija – predstavlja površinu koju ograđuje krivulja ekstenzograma i apscisa. Što je veća površina veća je energija utrošena na rastezanje i pucanje tijesta. Izražava se u cm^2 (Kljusurić, 2000).

Maksimalna viskoznost se mjeri na amilografu. Amilograf je zapravo viskozimetar koji pri miješanju određuje amilolitičku aktivnost enzima. Izražava se u Brabenderovim jedinicama (BU). Što je veća maksimalna viskoznost, niža je aktivnost enzima.

2.3. Kruh i peciva

Kako su se ljudi kroz povijest upoznavali s tehnikama uzgajanja žitarica i upotrebe vatre, nastajali su prvi primitivni kruhovi ili pogače. Prvi kruhovi su bili beskvasni. Daljnjim razvojem pekarstva dodavao se kvasac i ostali sastojci koji su pridonijeli okusu, teksturi, volumenu i ostalim bitnim karakteristikama. Poznato je da su u različitim dijelovima svijeta rasle različite vrste pšenice čije je brašno također određivalo vrstu kruha i peciva. Naime, u nekim dijelovima svijeta pečenjem tijesta od pšeničnog brašna dobiju se štruce kruha dok u drugima, zbog nedovoljnog dizanja tijesta, pogače. Ovisno o vrsti brašna postoje različite vrste kruhova i peciva kao npr. kruh od raženog brašna, integralnog brašna, bijeli kruh, crni kruh, kukuruzni, ječmeni, zobeni itd. Prema Pravilniku o žitaricama, mlinskim i pekarskim proizvodima, tjestenini, tijestu i proizvodima od tijesta (2005) kruh i drugi pekarski proizvodi dobivaju se miješanjem, oblikovanjem i pečenjem tijesta od mlinskih proizvoda pšenice i drugih žitarica i njihovih mješavina, vode ili druge dopuštene tekućine, kuhinjske soli i pekarskog kvasca. Peciva su, zapravo, proizvodi koji nastaju kombinacijom tijesta i različitih prehrambenih dodataka. Tijesto za pecivo također ima određene zahtjeve koje brašno mora osigurati. Danas je kruh glavna prehrambena namirnica većine europskih zemalja i Sjedinjenih Američkih država i glavni izvor ugljikohidrata, kompleksa vitamina B i minerala (Ambrosewicsz-Walacik i sur., 2016). Zahtjevi proizvođača za brašno su određeni prema karakteristikama kruha i peciva koje se žele dobiti kako bi proizvod bio konkurentan na tržištu.

2.4. Matematičke i statističke metode

2.4.1. Deskriptivna statistika

„Opisna ili deskriptivna statistika je grana statistike koja se bavi prikazom osnovnih svojstava skupova statističkih podataka“ (web 1). Uloga opisne statistike je organizirati skupove podataka i prikazati ih sažeto i pregledno kako bi se iz njih mogla interpretirati situacija koju oni opisuju.

Opisna statistika može biti korisna u dvije svrhe:

- Opisivanje skupova podataka izračunatima vrijednostima,
- Prikazivanje odnosa među varijablama (web 2).

Mjere koje se koriste u opisnoj statistici mogu se podijeliti u dvije skupine, a to su: mjere centralne tendencije i mjere disperzije podataka.

Mjere centralne tendencije nastoje što je bolje moguće opisati prosječnog člana skupa podataka. Također, daju najbolju opisnu sliku o promatranim podatcima. Mjere centralne tendencije su:

1. Aritmetička sredina ili srednja vrijednost podataka– zbroj svih vrijednosti varijabli u skupu podataka podijeljen s brojem varijabli. Dakle, ako postoji niz varijabli $x_1, x_2, x_3, x_4, \ldots x_n$, onda je aritmetička sredina prikazana izrazom (1). Aritmetička sredina označava se oznakom $\bar{x}_n$, broj varijabli označava se oznakom *n*. Npr. u nizu 1, 2, 3,4, 5 *n* je 5, a $\bar{x}_5$ je 3.

$$\bar{x}_n = \frac{1}{n}\sum_{i=1}^{n} x_i \qquad (1)$$

2. Medijan – središnja vrijednost varijabli, odnosno, ona vrijednost varijable u nizu podataka za koju vrijedi da je barem pola varijabli manje ili jednako od te vrijednosti, i da je barem pola varijabli veće ili jednako od te vrijednosti varijable.
3. Mod – predstavlja određenu vrijednost u određenom setu podataka koja se najviše pojavljuje. Npr. u setu podataka 1, 2, 3, 3, 3, 4, 5 mod je 3.

Mjere disperzije podataka daju nam informacije o raspršenosti vrijednosti varijabli. Mjere disperzije podataka su:

1. Raspon podataka – predstavlja najveću razliku među vrijednostima varijabli, odnosno razliku između najveće i najmanje varijable. Raspon podataka izražava se izrazom (2).

$$R = \max_{1 \le i \le n} x_i - \min_{1 \le i \le n} x_i = x_n - x_1 \tag{2}$$

2. Varijanca – predstavlja zbroj kvadrata razlike srednje vrijednosti i svake vrijednosti u nizu podataka podijeljen s brojem varijabli. Varijanca se izražava izrazom (3). Varijanca je mjera disperzije podataka koja se najčešće koristi.

$$S_n{}^2 = \frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})^2 \tag{3}$$

3. Standardna devijacija - predstavlja kvadratni korijen varijance. Standardna devijacija se također često koristi kao mjera disperzije podataka i izražava se izrazom (4).

$$S_n = \sqrt{S_n{}^2} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})^2} \tag{4}$$

4. Koeficijent varijabilnosti – predstavlja udio standardne varijacije u srednjoj vrijednosti izražen u postotcima (5).

$$CV = \frac{S_n}{\bar{x}_n} * 100\ [\%] \tag{5}$$

2.4.2. Kemometrijske analize

Kemometrija je znanstvena disciplina koja je spojila računalnu tehnologiju s analitičkom kemijom te se i razvija paralelno s razvojem istih.

Kemometrija je primjena statistike u analizi kemijskih podataka. Naziv je osmišljen 1970-ih, a u svojim se početcima uglavnom bavila obradom podataka dobivenih instrumentalnim analitičkim tehnikama uključujući jednostavne izračune poput dekonvolucije kromatografskih ili spektrofotometrijskih pikova (Brereton, 2007). Konvolucija je zapravo količina preklapanja dvaju funkcija od kojih je jedna prethodno zrcaljena. Suprotno od konvolucije je dekonvolucija koja predstavlja matematički postupak izdvajanja jednog analita iz preklopljenih odziva. Ono što je jedan od glavnih ciljeva ovog pristupa podatcima, odnosno skupu podataka, je izvlačenje relevantnih podataka iz cijelog skupa.

Kemometrijske metode koje se koriste prilikom obrade podataka u ovom radu su: faktorska analiza, klasterska analiza i analiza glavnih komponenti. Ove metode će se koristiti prilikom obrade podataka o sastavu i svojstvima različitih kultivara pšenice i brašna tijekom višegodišnjeg razdoblja u svrhu pronalaska najprikladnijih kultivara za proizvodnju bijelog brašna prema zahtjevima prerađivačke industrije.

2.4.2.1. Faktorska analiza (FA)

Faktorska analiza je skup statističko-matematičkih postupaka kojima se polazeći od većeg skupa varijabli, utvrđuje manji skup temeljnih varijabli ili faktora (Fulgosi, 1984). Zapravo cilj je naći grupu varijabli koje su značajne, odnosno relevantne i koje su ujedno slične u smislu da se, iako je svaka zasebno nezavisna, zajedno mijenjaju. Također, potrebno je definirati grupe varijabli tj. što točno one znače i što mjere mjerna osjetila koja su dala te podatke. Zapravo, potrebno je odrediti korelaciju početnih varijabli kako bi se iz korelacije analizom došlo do prikrivenih (latentnih) varijabli, odnosno faktora. Faktorska analiza koristi se matričnom algebrom tj. operacijama s vektorima i matricama. Radi se o simetričnoj matrici R koja po svojoj simetrali ima jedinice. Te jedinice označavaju ovisnost svake varijable same o sebi. Ostali članovi matrice osim simetrale su potencijalne ovisnosti parova različitih varijabli. Korelacije između izvorne varijable i faktora nazivaju se faktorska opterećenja i ključne su za razumijevanje prirode faktora. Kvadrat faktorskih opterećenja je komunalitet i predstavlja udio varijance određene izvorne varijable u ukupnoj varijanci (zbroj varijanci svih varijabli u analizi) koji je objašnjen uvrštenim faktorom (Fulgosi, 1984). Onaj ostatak koji nije komunalitet je zapravo specifična varijanca tj. udio varijance faktora u ukupnoj varijanci. Rješavanjem matrice pokušavaju se dobiti 0 i 1 kako bi se došlo do temeljnih varijabli. Može se reći da su krajnji rezultati faktorske analize upravo faktori koji su uzorak početnih varijabli i koji objašnjavaju povezanost analiziranih svojstava ili pojava.

2.4.2.2. Klaster analiza (CA)

Klaster analiza je naziv za statističku tehniku čija je primarna svrha grupiranje objekata temeljem osobina koje posjeduju (Hair i sur., 2010). Zapravo se radi o klasificiranju promatranih podataka na temelju određenih sličnosti. Prilikom klasificiranja tvore se skupine s više varijabli. Ovaj pristup omogućuje da se analiziraju skupine sastavljene od više varijabli. Ovakav način daje klaster analizi kao metodi multivarijantnu dimenziju. Dakle, klaster analiza temelji se na analizi objekata koje opisuju određene varijable. Za razliku od ostalih

multivarijantnih statističkih tehnika, klaster analiza varijable ne procjenjuje empirijski već koristi one varijable koje su zadane od strane samog istraživača (Devčić, 2012). Kako se umjesto stvarnih objekata koriste varijable koje ih opisuju, te varijable se obrađuju matematičkim putem i bitno ih je znati izabrati. Često se kao varijable koriste faktori koji su dobiveni faktorskom analizom. Cilj ove analize je izrada klasifikacija i prepoznavanja sličnosti u određenom skupu podataka.

2.4.2.3. Analiza glavnih komponenti (PCA)

PCA ili analiza glavnih komponenata je najjednostavnija metoda multivarijantne statistike. Možemo ju definirati kao način prikaza podataka u svrhu pronalaženja njihovih sličnosti i različitosti (Devčić, 2012). Razvojem računala i mogućnošću korištenja ove metode uz veliku točnost, ova metoda je postala najraširenija kemometrijska metoda. Dakle, matematičkim putem se izračunavaju nove varijable odnosno glavne komponente koje će u sebi imati gotovo većinu varijacije početnog velikog skupa varijabli.

Osnovni koraci u analizi glavnih komponenata su sljedeći:

1. S obzirom da je većina biometričkih setova podataka konstruirana iz varijabli različitih skala i jedinica mjerenja potrebno je standardizirati varijable tako da im je prosjek 0, a varijanca 1 kako bi sve bile na jednakoj razini u analizi,

2. Izračunati matrice korelacija između svih izvornih standardiziranih varijabli,

3. Pronaći svojstvene vrijednosti glavnih komponenata,

4. Odbaciti one komponente koje su nositelji proporcionalno malog udjela varijance i koristiti prvih nekoliko koje nose 80 – 90 % ukupne varijance što se bolje može uočiti nakon razrade faktorske analize (Pecina, 2006).

3. EKSPERIMENTALNI DIO

3.1. Zadatak

Zadatak rada je primijeniti deskriptivne statističke i kemometrijske metode analize na 24 različita kultivara pšenice s 19 izmjerenih svojstva brašna proizvedenog od njih, tijekom razdoblja od 10 godina (2005.-2014. god). Potrebno je utvrditi varijabilnost svojstava i sastava kultivara pšenice te prema zahtjevima prerađivačke industrije odrediti najprikladnije kultivare za proizvodnju krušnog brašna.

3.2. Materijali i metode

3.2.1. Materijali

Nazivi 24 kultivara pšenice na kojima su se vršile analize na Poljoprivrednom institutu Osijek su:

1. Alka (AL)
2. Bezostaja 1 (BE)
3. Demetra (DE)
4. Divana (DI)
5. Dubrava (DU)
6. Felix (FE)
7. Ficko (FI)
8. Golubica (GO)
9. Katarina (KA)
10. Libellula (LI)
11. Lucija (LU)
12. Osječka Crvenka (OC)
13. Osječanka (OS)
14. Osječka 20 (OS20)
15. Renata (RE)
16. Sana (SA)
17. Slavonija (SL)
18. Sirban Prolific (SP)
19. Srpanjka (SR)
20. Super Žitarka (SŽ)
21. Tena (TE)
22. U1
23. Zlatna dolina (ZD)
24. Žitarka (ŽI).

Svojstva pšenice i brašna analizirana su u laboratoriju Poljoprivrednog instituta Osijek u čijem vlasništvu je i površina na kojoj su kultivari pšenice uzgojeni. Analizirani su kultivari sa spomenute površine u razdoblju od 10 godina. Naime, nakon žetve pšenica se sortira i čisti te ide na analizu samoga zrna. Nadalje se pšenica melje kako bi se dobilo brašno od kojih će se moći napraviti zamjes u svrhu analize farinografskih i ekstenzografskih svojstava brašna.

Svojstva pšenice i brašna dobivene od pšenice korištena u diplomskom radu su: udio proteina, vrijednost sedimentacije, udio vlažnog glutena, gluten indeks, broj padanja, izbrašnjavanje, omjer udjela vlažnog glutena i udjela proteina, sposobnost upijanja vode, vrijeme razvoja tijesta, stabilnost tijesta, otpor tijesta kidanju, stupanj mekšanja, farinografski broj kakvoće tijesta, energija tijesta, otpor tijesta kidanju nakon 5 minuta, maksimalan otpor tijesta kidanju, rastezljivost tijesta, omjer otpora tijesta kidanju i rastezljivosti tijesta, omjer maksimalnog otpora tijesta kidanju i rastezljivosti tijesta.

3.2.1.1. Zahtjevi proizvođača

Prikupljeni zahtjevi parametara kvalitete proizvođača Škojo d.o.o., ZG Pekarne „Klara“ d.d., Klas d.d. i Koestlin d.d. za krušna brašna i brašna za pecivo navedeni su u **tablicu 4.** U tablici se može primijetiti da pojedini parametri za određeni proizvod nisu definirani, što znači da parametar nije presudan za dostizanje određenog nivoa kvalitete namjenskog proizvoda.

Tablica 4 Zahtjevi proizvođača za krušna brašna i brašna za pecivo

	VLAŽNI GLUTEN (%)	BROJ PADANJA (s)	UPIJANJE VODE (%)	STUPANJ OMEKŠANJA (FJ)	KVALITETNA GRUPA	RASTEZLJIVOST (min)	OTPOR 5 MIN (EJ)	O/R	MAX OTPOR (EJ)	ENERGIJA (cm^2)	MAX VISKOZITET (EJ)
KRUH, PECIVO, 500, Min	24	220	57	18	B1	165			400		
KRUH, PECIVO, 500, Max	45	280	64	60	B1	204			514		
KRUH, PECIVO, 850, Min	24	220	59	18	B1	160			300		
KRUH, PECIVO, 850, Max	45	280	64	60	B1	204			514		
KRUŠNO, 800, Min	24		57	18		150	150			70	300
KRUŠNO, 800, Max	45		64	80		190	362			115	750
BRAŠNO_850, 850, Min	25		60	18		150	200			50	300
BRAŠNO_850, 850, Max	45		64	100		190	200			115	750
BRAŠNO_500_400, 500/400, Min	22		53	70	C1	120	200		300		350
BRAŠNO_500_400, 500/400, Max	27		60	120	C1	180	400		600		750
PECIVO, 500, Min	20		53	80	C1	140			350	65	400
PECIVO, 500, Max	23		60	115	B1	155			400	80	700
PECIVO, 500 3G, Min	20		50	60	B1	150		1,5	350	80	
PECIVO, 500 3G, Max	24		52	90	B2	170		1,7	420	85	
PECIVO, 700, Min	20		57	80	C1	140			350	65	
PECIVO, 700, Max	23		62	120	B2	160			400	80	
OŠTRO BRAŠNO, 500 3G, Min	20		50	70	B2	130		2	350	60	
OŠTRO BRAŠNO	22		60	100	B1	140		2,5	450	70	

3.2.2. Metode

3.2.2.1. Određivanje udjela proteina

Proteini se određuju relativno brzo. Koristi se tehnologija infracrvene transmisije (NIT). Uređaj za određivanje proteina koji je korišten u ovom diplomskom radu je NIT analizator Infratec 1241. Udio proteina se određuje po standardnoj metodi HRN ISO 5983-2:2005.

3.2.2.2. Određivanje udjela vlažnog glutena

Kako je već spomenuto prilikom dodatka vode netopljivi proteini u brašnu bubre i tvore gluten. Daljnjim ispiranjem tijesta te odvajanja viška vode dobije se vlažni gluten. Udio vlažnog glutena određuje se po standardnoj metodi HRN ISO 7495:1999. Za određivanje glutena potrebno je odvagati 10 g uzorka (brašna) te pomiješati sa 5-6 cm^3 vode i zamijesiti do određene konzistencije. Nadalje, tijesto se ispire s 2 %-tnom vodenom otopinom NaCl-a kroz 10-20 min prilikom kojeg se potroši 1 L spomenute otopine. Nakon ispiranja se zaostali vlažni gluten pritisne staklenom pločom s ciljem uklanjanja zaostale vode. Na kraju se zaostali gluten izvaže, podijeli s 10 g i pomnoži s 100 radi izražavanja udjela vlažnog glutena u postotcima.

3.2.2.3. Određivanje broja padanja

Određivanje broja padanja je metoda koja određuje aktivnost enzima α-amilaze u pšenici i brašnu. Na temelju broja padanja se može utvrditi kolika je oštećenost klice, ili proklijalost zrna. Metoda se temelji na spravljanju suspenzije brašna i vode u toploj kupelji gdje dolazi do želatinizacije škroba. Miješalica viskozimetra pada kroz suspenziju i što brže padne do dna kivete to znači da je aktivnost α-amilaze veća i da je škrobni gel razgrađen te je viskoznost manja. Broj padanja se točno definira kao ukupno vrijeme od trenutka ulaganja kivete sa suspenzijom u vodenu kupelj, pa do kraja penetracije miješalice viskozimetra kroz škrobni gel. Izražava se u sekundama. Optimalan raspon je između 250 i 300 sekundi. Ako je broj padanja ispod 150 sekundi, pšenica je proklijala. Određivanje broja padanja radi se po standardnoj metodi ICC No. 107/1.

3.2.2.4. Određivanje sedimentacijske vrijednosti

Metoda se temelji na svojstvu glutena da bubri u prisutnosti mliječne kiseline. Dakle uzorak pšenice se melje i prosijava te tretira mliječnom kiselinom kroz određeni vremenski period. Nakon toga se suspenzija ostavlja da se taloži. Sedimentacijska vrijedno se izražava u cm^3 što je zapravo volumen taloga. Sedimentacijska vrijednost određuje se po standardnoj metodi HRN EN ISO 5529:2010.

3.2.2.5. Određivanje farinografskih svojstava: moć upijanja vode, stabilnost tijesta, vrijeme razvoja tijesta i stupanj mekšanja

Svojstva koja se određuju na farinografu određuju se po standardnoj metodi HRN ISO 5531-1:1999. Moć upijanja vode, stabilnost tijesta, vrijeme razvoja tijesta i stupanj omekšanja su svojstva tijesta i brašna koja se mogu ispitati pomoću farinografa koji daje ispis grafa koji se naziva farinogram. Farinogram (**slika 1**) je graf na kojem se na osi ordinate nalaze farinografske jedinice a na osi apscise nalazi vrijeme u minutama. U uređaju se radi zamjes 300 grama uzorkovanog brašna s vodom i mjeri otpor miješanju tijesta. Farinogram se ispisuje nakon 15 minuta. Moć upijanja vode je u postotku izražena količina vode koju je potrebno dodati u zamjes da bi tijesto dobilo konzistenciju od 500 farinografskih jedinica. 500 FJ je dogovorena točka punog razvoja tijesta. Stabilnost tijesta se izražava u minutama i na farinogramu je zapravo vrijeme između postignute konzistencije od 500 FJ do početka opadanja konzistencije tijesta ispod 500 FJ. Vrijeme razvoja tijesta se također izražava u minutama i na farinogramu je to vrijeme od početka dodavanja vode u zamjes do postignute maksimalne konzistencije tijesta. Stupanj omekšanja se izražava u farinografskim jedinicama i na farinogramu predstavlja odstupanje krajnje točke srednje linije farinograma od linije konzistencije.

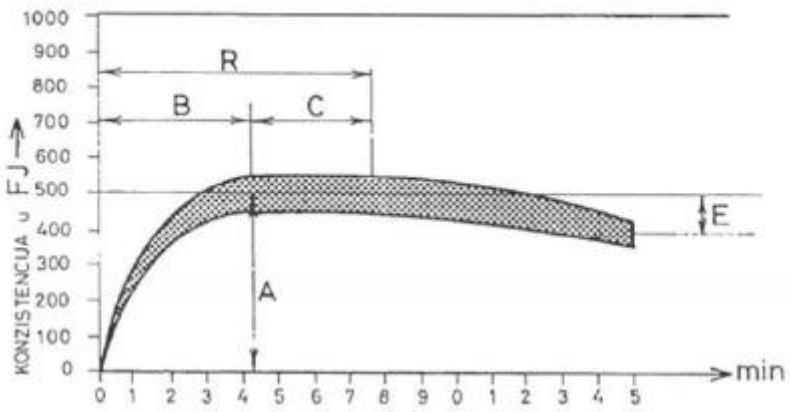

Slika 1 Farinogram (Đaković, 1980)

3.2.2.6. Određivanje ekstenzografskih svojstva: otpor tijesta, energija tijesta, otpor tijesta kroz 5 minuta, rastezljivost i maksimalan otpor

Svojstva koja se određuju na ekstenzografu određuju se po standardnoj metodi HRN ISO 5530-2:2005. Otpor tijesta, energija tijesta i rastezljivost tijesta su ekstenzografska svojstva i određuju se na uređaju ekstenzografu. Naime, radi se o uređaju koji silom konstantne jačine, smjera i brzine djeluje na tijesto do točke pucanja tijesta. Otpor koji tijelo pruža rastezanju i kidanju daje krivulju koja se naziva ekstenzogram (**slika 2**). Prvo je potrebno napraviti adekvatan zamjes. Zamjes se osigurava u miješalici farinografa gdje se dodaje 300 g uzorkovanog brašna, 6 g soli i 2 % vode manje nego što je moć upijanja vode brašna dobivena farinografom. Nakon 5 minuta miješenja, krivulja farinograma bi trebala biti na oko 500 FJ (+/-10). Nakon toga se zamjes dijeli na dva dijela po 150 g koji idu u homogenizator. Nakon homogenizatora se komadi tijesta oblikuju za daljnju provedbu mjerenja i polažu u temperiranu komoru. Oblikovani komad tijesta stavlja se u specifični kalup koji nadalje postaje dio u sustavu poluga. Kukica zakačena za tijesto vuče tijesto do točke pucanja, a otpor je registriran preko pisača krivulje. Os apscisa na ekstenzogramu predstavlja vrijeme, a os ordinata ekstenzografske jedinice. Otpor tijesta, prema ekstenzogramu, predstavlja visinu krivulje nakon pet minuta od početka očitavanja otpora koje tijesto pruža razvlačenju i izražava se u EJ. Maksimalan otpor predstavlja visinu maksimalne točke krivulje tijekom mjerenja i izražava se također u EJ. Energija je izražena u cm^2 što nije uobičajeno. Radi se zapravo o površini ispod krivulje na farinogramu. Pomoću integrala funkcije krivulje ili planimetriranjem moguće je odrediti površinu ispod krivulje koja se onda dalje ubacuje u određene formule koje daju iznos energije u adekvatnijim mjernim jedinicama. Ono što je potrebno znati je da je to energija koju je potrebno uložiti da bi došlo do pucanja tijesta prilikom razvlačenja. Rastezljivost je duljina dužine na apscisi izražena u milimetrima koja je omeđena točkom početka razvlačenja tijesta i točkom kidanja tijesta. Ostala ekstenzografska svojstva su omjeri spomenutih svojstava.

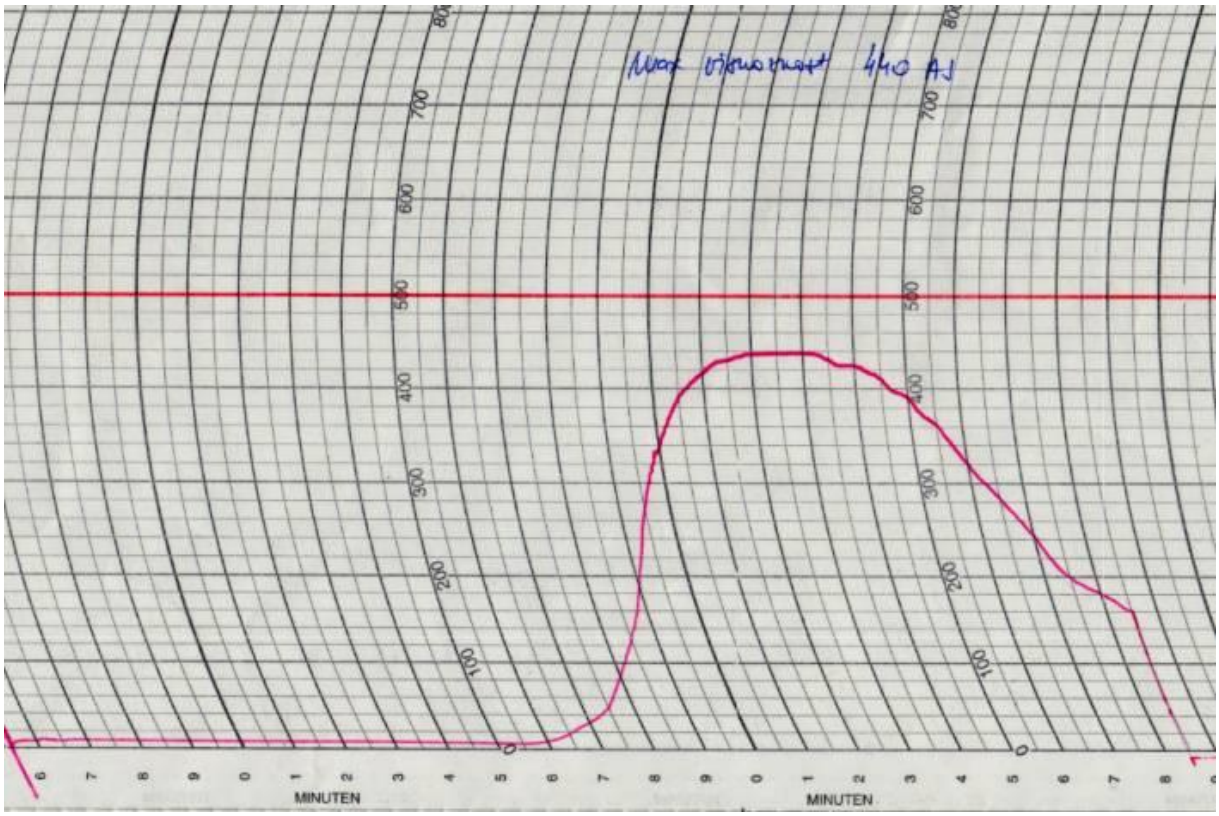

Slika 2 Ekstenzogram (web 3)

3.2.2.7. Klaster analiza

Na izmjerenim vrijednostima 19 svojstava brašna proizvedenih od 24 kultivara pšenice primijenjena je klaster analiza računalnim programom Statistica 13. Klasterska analiza ima tendenciju grupiranja promatranih veličina, rezultata, informacija, podataka u klastere, odnosno grupe unutar kojih ti rezultati nisu nužno ovisni jedni od drugih nego su samo u određenoj mjeri po redu veličina slični. Eng. *Dendogram* je dijagram koji zorno prikazuje klastere hijerarhijski poslagane. Na dnu se nalaze kultivari koji se povezuju linijama u klastere. Linijama se povezuju u tom trenutku kultivari najsličniji po vrijednosti. Naravno, prema nižim izmjerenim vrijednostima varijabli, manje je klastera jer se sve više kultivara stavlja pod jedan klaster. Također, što je po okomici linija spajanja u klastere udaljenija od dna, to su članovi klastera različitiji. Također je prikazan dendogram koji prikazuje zahtjeve proizvođača.

3.2.2.8. Analiza glavnih komponenti

Na izmjerenim vrijednostima 19 svojstava brašna proizvedenih od 24 kultivara pšenice primijenjena je analiza glavnih komponenti računalnim programom Statistica 13. Prilikom analize glavnih komponenti analizirani su kultivari pšenice, svojstva brašna od kojih su

proizvedeni i zahtjevi proizvođača. U prvom slučaju radi se o kultivarima pšenice odnosno njihovim svojstvima, svako svojstvo ima svojstvenu vrijednost i kao takvo ima udio u ukupnoj varijanci promatranih podataka. Naime, udio u ukupnoj varijanci nam govori koliko to utječe na cjelokupni svojstveni profil promatranog seta podataka. Ono svojstvo koje ima najviše udjela u varijanci postaje prva glavna komponenta. Takav postupak omogućuje da smanjimo broj varijabli koje promatramo, a da prilikom obrade podataka zaključujemo s velikom preciznošću iako smo neke varijable zanemarili. U drugom slučaju može se vidjeti raspored pojedinih svojstva na temelju srednjih vrijednosti svojstva, a koje su izračunate za svaki kultivar. Na temelju ove slike može se vidjeti sličnost ili različitost utjecaja pojedinog svojstva na varijabilnost cjelokupnog seta izmjerenih podataka kroz 10 godina.

3.2.2.9. Kutijasti dijagram (eng. *Box and Whisker plot*)

Kutijasti dijagram grafički prikazuje raspon vrijednosti određenog svojstva (varijable) za sve kultivare. Dakle, pomoću ovakvog prikaza možemo vidjeti maksimalnu udaljenost vrijednosti nekog svojstva od srednje vrijednosti tog svojstva.

4. REZULTATI

4.1. Statistička obrada podataka

Vrijednosti ekstenzografskih i farinografskih svojstava brašna mjerene su i prikupljane tijekom 10 godina (2005.-2014.) u laboratoriju Poljoprivrednog instituta Osijek. Mjerenja su provođena svaku godinu na istim kultivarima pšenice kojih je ukupno 24 (**tablica 5**). Ekstenzografska i farinografska svojstva su, kao što je vidljivo iz tablica sa zahtjevima proizvođača, krucijalna za kvalitetu proizvoda navedenih proizvođača. Ukupno je 19 svojstava koja se svake godine mjere na brašnu proizvedenom od analiziranih kultivara. Rezultati mjerenja su obrađeni programom „Statistica“ pomoću kojeg je provedena deskriptivna statistika (srednja vrijednost, standardna devijacija, minimalne i maksimalne vrijednosti svojstva te koeficijent varijabilnosti) i kemometrijska analiza podataka (analiza glavnih komponenti i klaster analiza).

Tablica 5 Izmjerena svojstva za brašna proizvedena od 24 kultivara pšenice

		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
		P	SED	WG	GI	FN	WG/P	FY	WA	DDT	STAB	R	DS	FQN	E	R5MIN	EXT	RMAX	R/EXT	RMAX/EXT
1	SP	16,97	32,30	43,60	56,13	306,25	2,57	63,61	56,73	2,52	0,74	3,25	86,20	54,10	37,50	104,40	203,10	124,20	0,53	0,65
2	U1	17,06	29,10	44,31	47,44	293,80	2,60	60,66	56,11	2,23	0,53	2,73	109,20	41,30	33,00	101,10	192,60	117,20	0,54	0,63
3	DU	15,11	50,00	34,84	80,65	315,30	2,30	69,15	59,85	3,86	1,46	5,31	69,40	89,60	58,60	208,70	153,00	279,40	1,36	1,84
4	LI	14,28	24,60	35,51	63,84	312,10	2,48	61,65	57,98	2,20	0,46	2,65	96,40	45,70	43,80	148,70	169,30	180,30	0,89	1,09
5	BE	14,21	53,10	33,43	83,07	266,30	2,35	71,21	58,25	3,04	1,67	4,74	53,90	108,50	80,50	303,00	144,70	428,90	2,12	2,98
6	ZD	12,81	27,40	29,92	81,50	286,40	2,34	55,11	54,61	1,81	0,66	2,50	91,60	45,70	44,50	182,40	146,40	214,40	1,27	1,49
7	TE	15,20	50,70	35,24	80,44	291,50	2,31	70,02	63,78	4,12	1,34	5,46	66,40	101,50	65,60	219,10	158,00	311,90	1,41	2,00
8	OC	14,70	49,70	35,24	85,09	364,60	2,40	74,01	60,49	4,57	1,60	6,17	58,30	112,80	71,60	257,00	152,60	356,10	1,73	2,38
9	OS20	13,70	31,50	34,53	66,11	347,40	2,51	69,66	60,59	2,32	0,43	2,76	95,40	51,00	26,70	123,70	136,30	132,00	0,93	0,98
10	OS	14,50	38,60	36,44	64,67	323,70	2,51	72,23	63,31	2,47	0,91	3,38	87,00	55,40	36,20	139,30	152,10	164,70	0,93	1,10
11	SL	13,55	49,30	32,72	75,42	345,90	2,41	68,61	60,67	2,69	1,13	3,81	74,20	72,40	58,60	219,60	153,20	284,40	1,48	1,94
12	ŽI	13,84	49,20	34,69	73,94	337,60	2,50	67,30	62,51	2,78	0,93	3,71	80,70	65,40	54,60	198,60	151,60	256,30	1,33	1,72
13	SR	13,35	46,50	29,15	94,37	372,10	2,17	69,40	57,21	2,97	0,86	3,81	50,60	93,30	93,50	361,60	141,30	513,50	2,62	3,69
14	DE	12,70	52,10	27,35	98,47	284,50	2,14	71,20	57,49	1,97	0,89	2,85	69,00	56,50	98,20	341,70	153,70	500,20	2,34	3,36
15	GO	14,30	61,30	34,56	90,78	333,90	2,41	71,02	60,62	5,19	2,07	7,25	41,10	133,40	77,80	225,70	174,40	339,10	1,34	2,01
16	SŽ	13,16	48,00	32,10	85,76	329,60	2,43	70,00	62,35	2,09	0,90	2,99	76,50	59,10	63,90	248,50	143,70	331,70	1,79	2,32
17	LU	12,93	49,30	27,66	97,35	320,30	2,13	68,00	58,60	3,50	0,76	4,28	50,60	94,50	98,20	323,30	153,20	502,80	2,18	3,32
18	AL	12,61	47,90	26,87	95,57	304,70	2,12	71,00	57,97	2,16	2,10	4,23	69,60	71,22	80,44	300,89	149,67	422,22	2,19	3,01
19	SA	12,81	35,70	28,38	84,33	259,90	2,19	68,80	57,04	2,20	0,91	3,11	101,10	49,90	42,90	166,20	150,00	204,50	1,15	1,39
20	FI	14,07	46,20	30,60	85,08	276,90	2,17	70,10	60,04	4,55	1,63	6,17	67,80	118,50	46,60	181,30	142,20	238,60	1,29	1,69
21	RE	14,06	56,50	30,38	96,40	380,20	2,15	71,30	58,17	2,86	2,90	5,74	47,90	112,20	98,80	323,70	156,40	496,10	2,17	3,26
22	KA	12,86	48,40	29,51	95,57	293,90	2,28	70,80	56,73	2,61	1,06	3,67	51,80	80,00	88,00	305,30	152,00	454,50	2,05	3,03
23	FE	12,95	50,70	27,92	96,27	365,60	2,15	69,60	59,90	2,00	0,87	2,90	47,70	92,60	89,90	318,60	150,40	461,10	2,19	3,14
24	DI	16,44	68,10	34,91	90,74	313,90	2,12	69,50	61,03	10,31	4,02	14,31	18,30	184,10	114,90	298,00	180,40	488,30	1,66	2,72

P = udio proteina, eng. *Proteins* (%), SED = vrijednost sedimentacije, eng. *Sedimentation* (cm^2), WG = vlažni gluten, eng. *wet gluten* (%), GI = gluten indeks, eng. *gluten index*, FN = broj padanja, eng. *falling number* (s), WG/P = omjer vlažnog glutena i udjela proteina eng. *wet gluten and protein ratio*, FY = izbrašnjavanja, eng. *flour yield* (%), WA sposobnost upijanja vode, eng. *water absorption* (%), DDT = vrijeme razvoja tijesta, eng. *dough development time* (min), STAB = stabilnost tijesta, eng. *stabillity* (min), R = otpor, eng. *resistance* (EJ), DS = stupanj omekšanja, eng. *degree of softening*, FQN = Farinografski broj kakvoće, eng. *farinograph quality number*, E = energija tijesta, eng. *dough energy* (cm^2), R5MIN = otpor kroz 5 minuta, eng. *resistance through 5 min* (EJ), EXT = rastezljivost tijesta, eng. *exstensibility* (mm), RMAX = maksimalni otpor, eng. *max resistance* (EJ), R/EXT = omjer otpora i rastezljivost tijesta, eng. *resistance and extensibility ratio*, RMAX/EXT = omjer maksimalnog otpora i rastezljivosti tijesta, eng. *max. resistance and extensibility ratio*, Vmax = maksimalni viskozitet, eng. *max viscosity*, Qg = kvalitetna grupa, eng*, quality group* (EJ).

Tablica 6 Deskriptivna statistička analiza vrijednosti svojstava brašna (19 svojstava iz 24 kultivara)

		Broj uzoraka	Srednja vrijednost	Pouzdanost -95,000%	Pouzdanost 95,000%	Minimum	Maksimum	Standardna devijacija	Pouzdanost SD -95,000%	Pouzdanost SD +95,000%	Koeficijent varijabilnosti
1	P	24	14,0904	13,5404	14,6404	12,6100	17,0600	1,3025	1,0124	1,8272	9,24421
2	SED	24	45,6750	41,1120	50,2380	24,6000	68,1000	10,8060	8,3986	15,1582	23,65847
3	WG	24	32,9101	30,9846	34,8356	26,8725	44,3105	4,5599	3,5440	6,3964	13,85564
4	GI	24	82,0406	76,1402	87,9410	47,4434	98,4670	13,9733	10,8602	19,6012	17,03214
5	FN	24	317,7646	303,6262	331,9030	259,9000	380,2000	33,4825	26,0231	46,9679	10,53689
6	WG/P	24	2,3231	2,2569	2,3893	2,1152	2,5953	0,1567	0,1218	0,2199	6,74660
7	FY	24	68,4975	66,7148	70,2802	55,1100	74,0100	4,2217	3,2812	5,9221	6,16334
8	WA	24	59,2511	58,2429	60,2593	54,6100	63,7800	2,3877	1,8558	3,3494	4,02980
9	DDT	24	3,2090	2,4594	3,9586	1,8100	10,3100	1,7752	1,3797	2,4902	55,31905
10	STAB	24	1,2846	0,9340	1,6352	0,4300	4,0200	0,8302	0,6453	1,1646	64,62930
11	R	24	4,4910	3,4461	5,5358	2,5000	14,3100	2,4744	1,9232	3,4711	55,09829
12	DS	24	69,1958	59,9546	78,4371	18,3000	109,2000	21,8851	17,0094	30,6995	31,62775
13	FQN	24	82,8634	68,3396	97,3873	41,3000	184,1000	34,3952	26,7325	48,2483	41,50836
14	E	24	66,8477	56,2939	77,4014	26,7000	114,9000	24,9933	19,4252	35,0597	37,38847
15	R5MIN	24	233,3495	199,7642	266,9349	101,1000	361,6000	79,5366	61,8170	111,5709	34,08476
16	EXT	24	156,6778	149,8421	163,5134	136,3000	203,1000	16,1881	12,5816	22,7080	10,33209
17	RMAX	24	325,1009	267,9881	382,2138	117,2000	513,5000	135,2542	105,1214	189,7292	41,60375
18	R/EXT	24	1,5620	1,3167	1,8074	0,5300	2,6200	0,5811	0,4516	0,8151	37,19909
19	RMAX/EXT	24	2,1558	1,7643	2,5474	0,6300	3,6900	0,9272	0,7206	1,3006	43,00877

P = udio proteina, eng. *Proteins* (%), SED = vrijednost sedimentacije, eng. *Sedimentation* (cm^2), WG = vlažni gluten, eng. *wet gluten* (%), GI = gluten indeks, eng. *gluten index*, FN = broj padanja, eng. *falling number* (s), WG/P = omjer vlažnog glutena i udjela proteina eng. *wet gluten and protein ratio*, FY = izbrašnjavanja, eng. *flour yield* (%), WA sposobnost upijanja vode, eng. *water absorption* (%), DDT = vrijeme razvoja tijesta, eng. *dough development time* (min), STAB = stabilnost tijesta, eng. *stabillity* (min), R = otpor, eng. *resistance* (EJ), DS = stupanj omekšanja, eng. *degree of softening*, FQN = Farinografski broj kakvoće, eng. *farinograph quality number*, E = energija tijesta, eng. *dough energy* (cm^2), R5MIN = otpor kroz 5 minuta, eng. *resistance through 5 min* (EJ), EXT = rastezljivost tijesta, eng. *exstensibility* (mm), RMAX = maksimalni otpor, eng. *max resistance* (EJ), R/EXT = omjer otpora i rastezljivost tijesta, eng. *resistance and extensibility ratio*, RMAX/EXT = omjer maksimalnog otpora i rastezljivosti tijesta, eng. *max. resistance and extensibility ratio*, Vmax = maksimalni viskozitet, eng. *max viscosity*, Qg = kvalitetna grupa, eng*, quality group* (EJ).

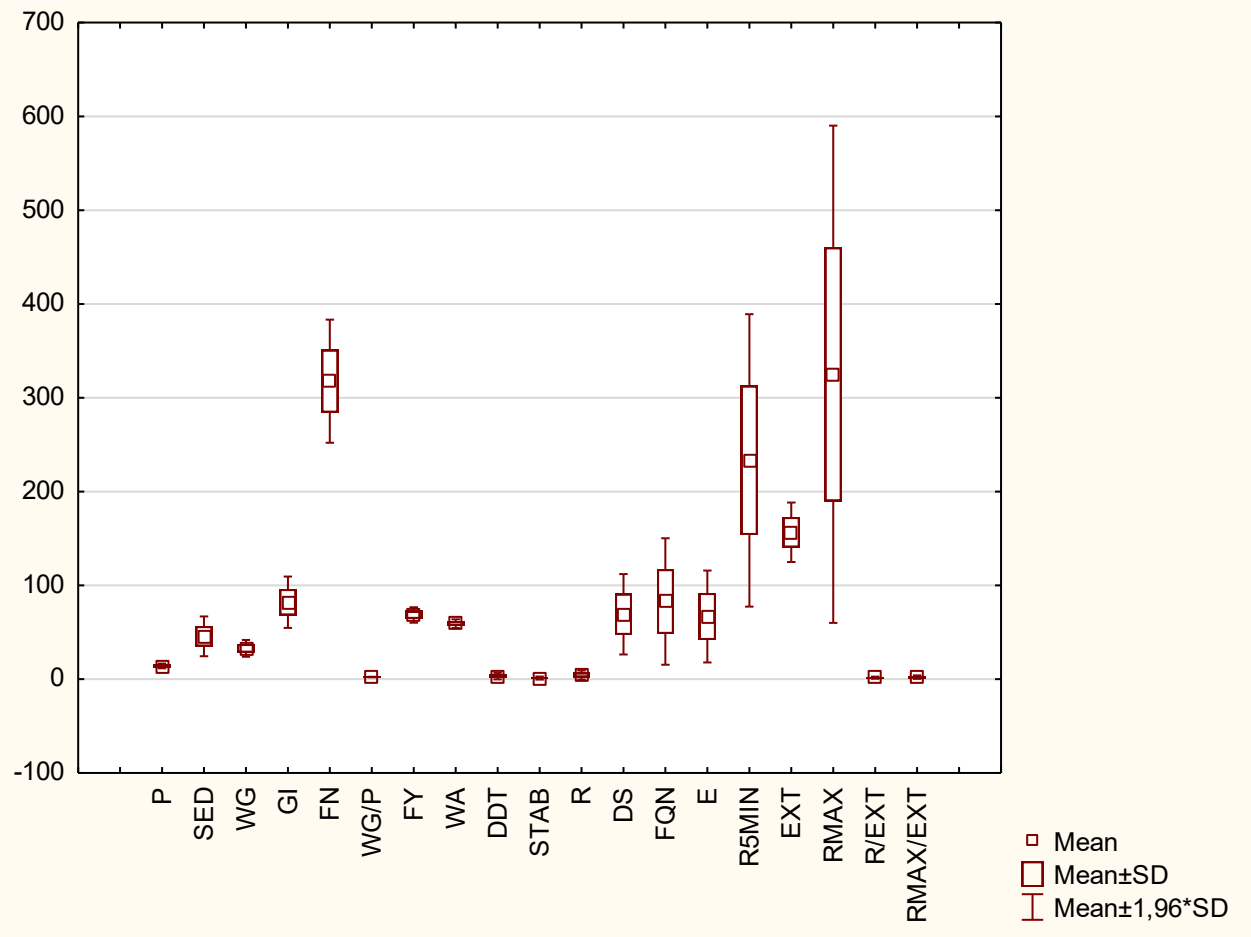

Slika 3 Kutijasti dijagram (eng. *Box and Whisker Plot*)

Eng. *Mean* = Srednja vrijednost; *Mean±SD*=Srednja vrijednost*±Standardna devijacija; Mean±1,96*SD*=Srednja vrijednost*±1,96*SD*

Na slici (**slika 3**) se može vidjeti da veliki raspon na ordinatnoj skali onemogućuje precizno očitavanje vrijednosti varijabli.

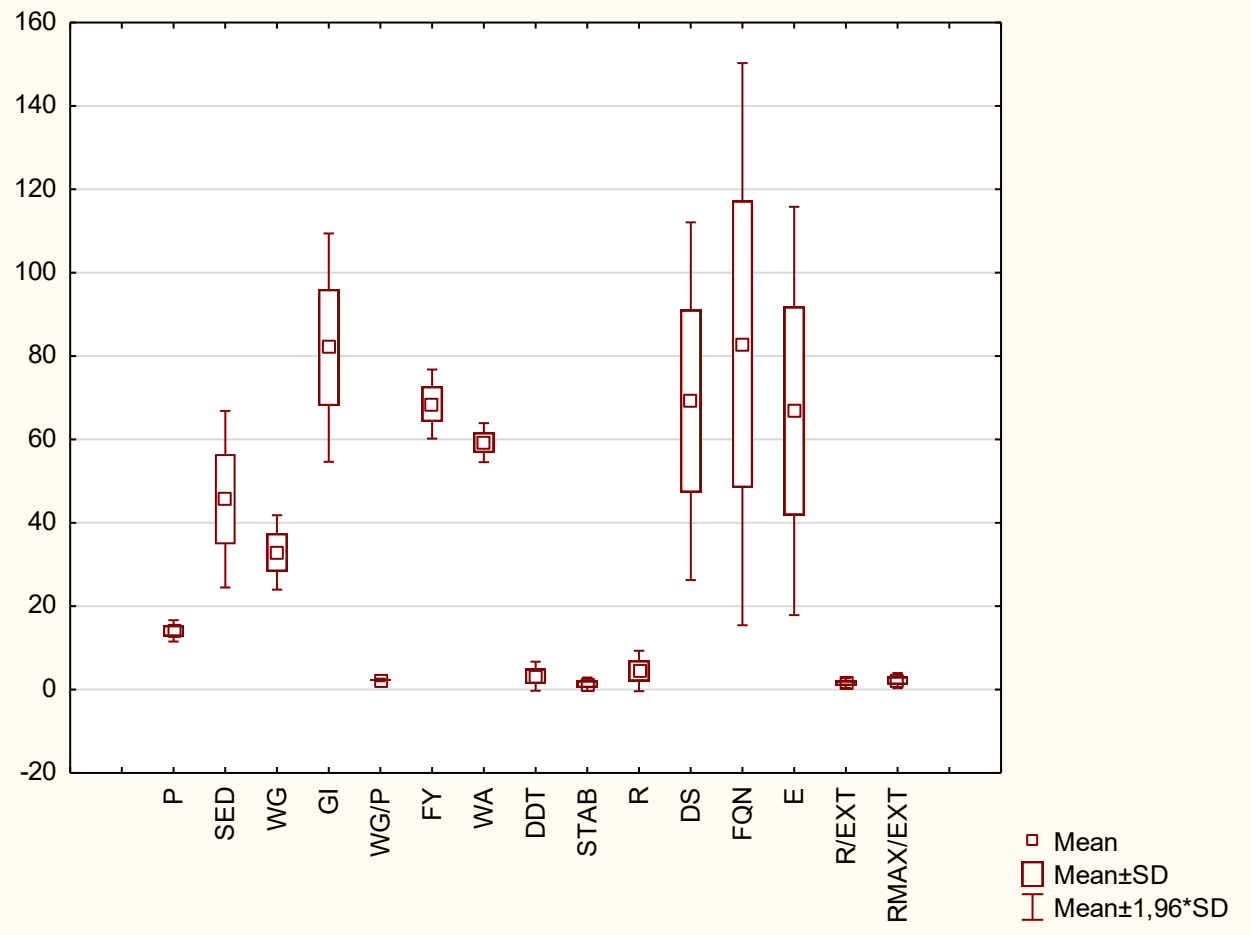

Slika 4 Kutijasti dijagram za svojstva koja su u međusobno bližem rasponu

Kako bi lakše uočavali raspone podataka za pojedino svojstvo, izbačena su s apscisne osi kutijastog dijagrama svojstva čija je izmjerena vrijednost veća od 160.

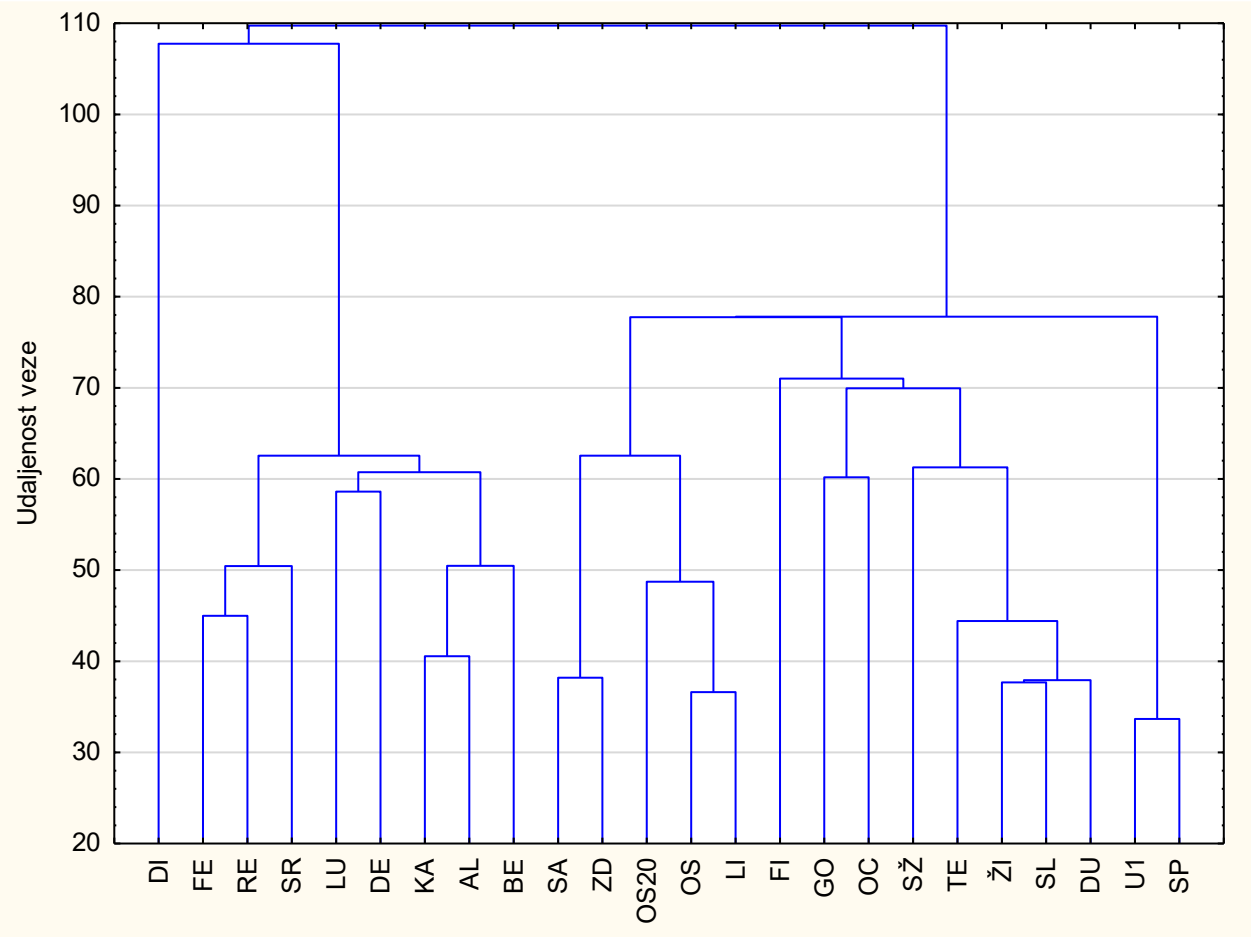

Slika 5 Dendogram klasterske analize 24 kultivara pšenice

Na slici (**slika 5**) prikazan je dendogram koji prikazuje koji kultivari mogu pripadati u zajednički klaster ili grupu.

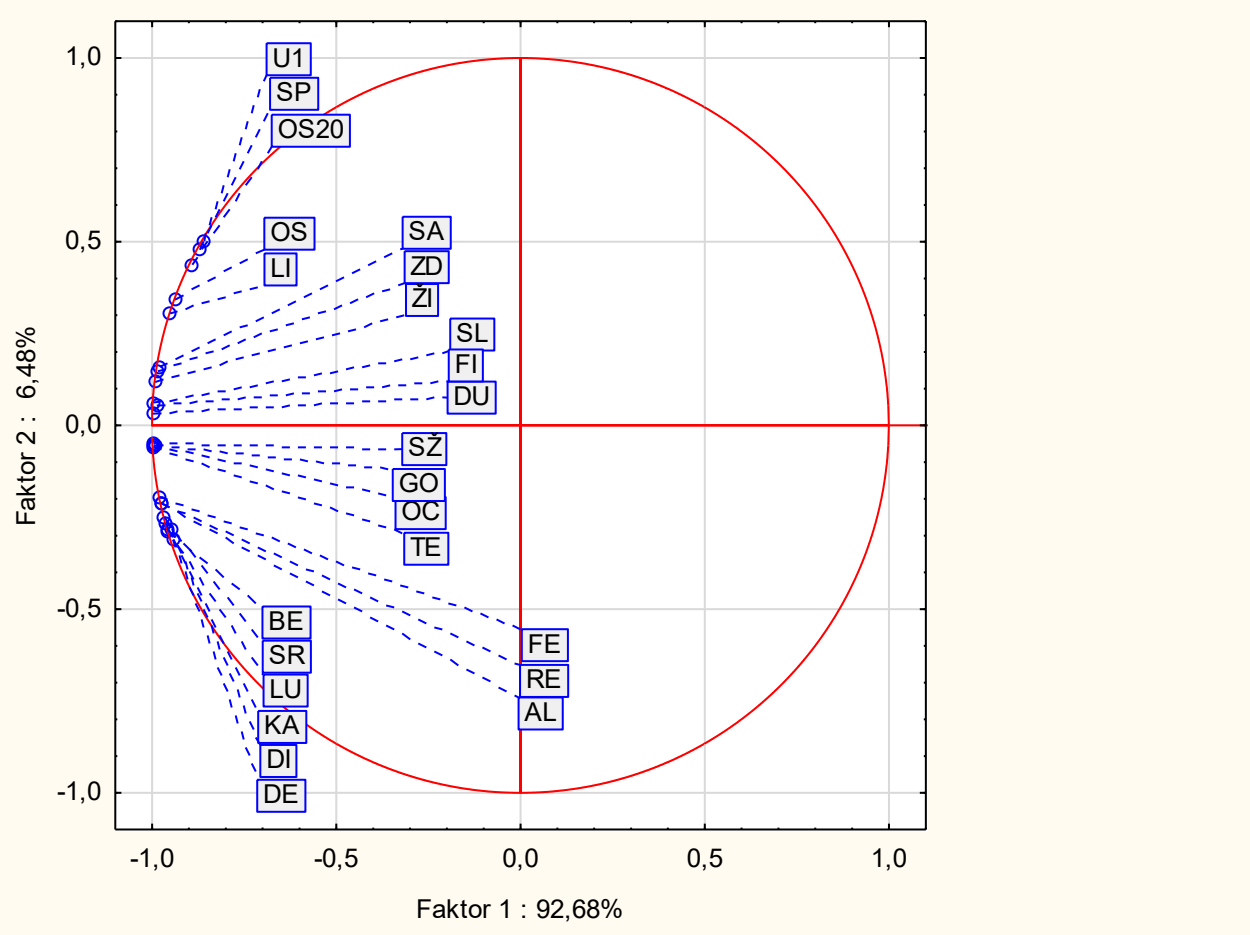

Slika 6 Grupiranje kultivara pšenice u prve dvije faktorske ravnine

Prikazane su pozicije kultivara pšenice na temelju cjelokupnog seta izmjerenih vrijednosti. Vidljive su razlike kultivara na temelju svojstava. Na slici (**slika 6**) se prikazuje grupiranje kultivara u dvije faktorske ravnine pomoću prve dvije glavne komponente koje obuhvaćaju 99,16 % ukupne varijance. Može se primijetiti da je druga glavna komponenta (*Factor 2*) po okomici zaslužnija za grupiranje kultivara.

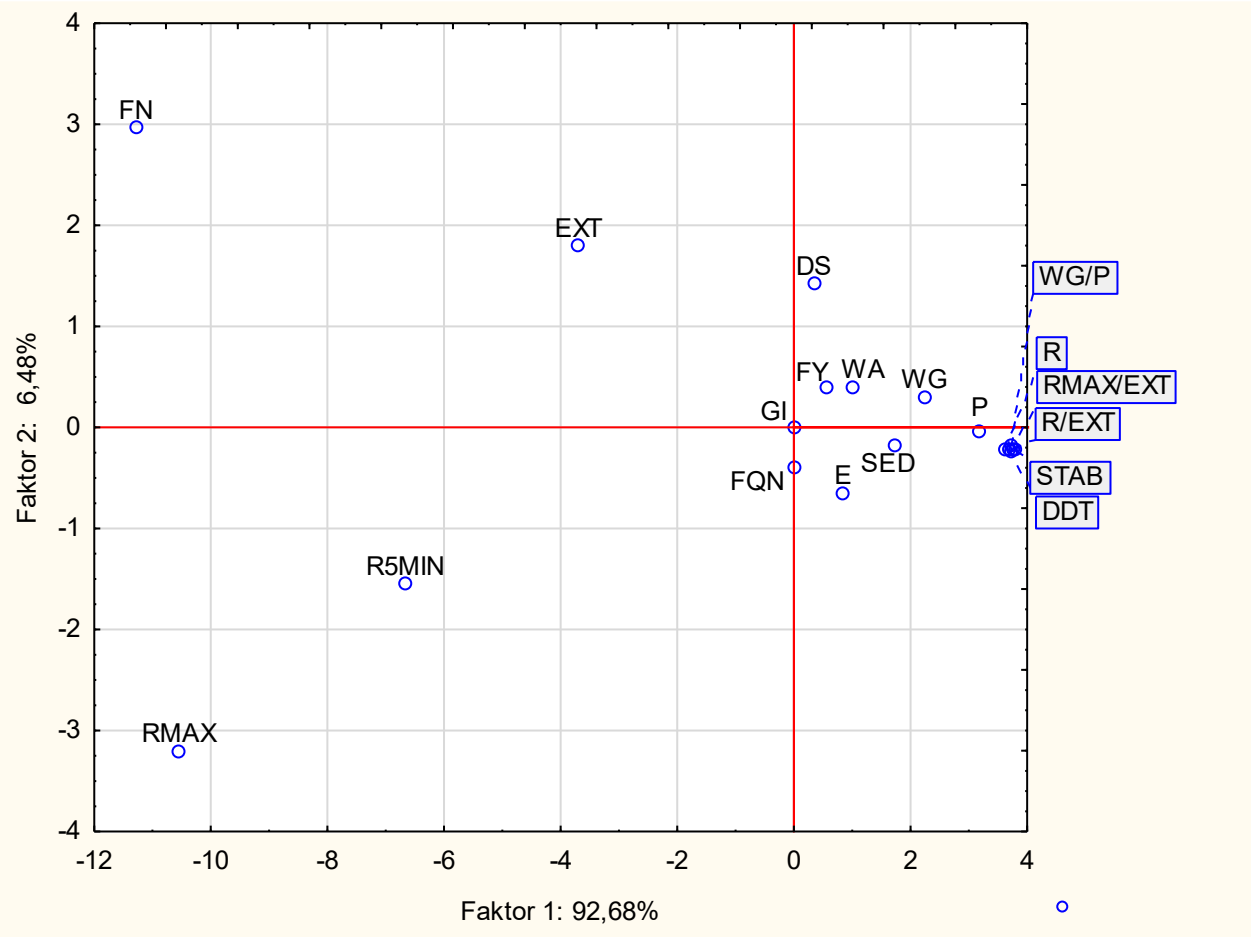

Slika 7 Grupiranje svojstava pšenice u prve dvije faktorske ravnine

Na slici (**slika 7**) su prikazana svojstva pšenice raspoređene u prve dvije faktorske ravnine koje obuhvaćaju 99,16 % ukupne varijance.

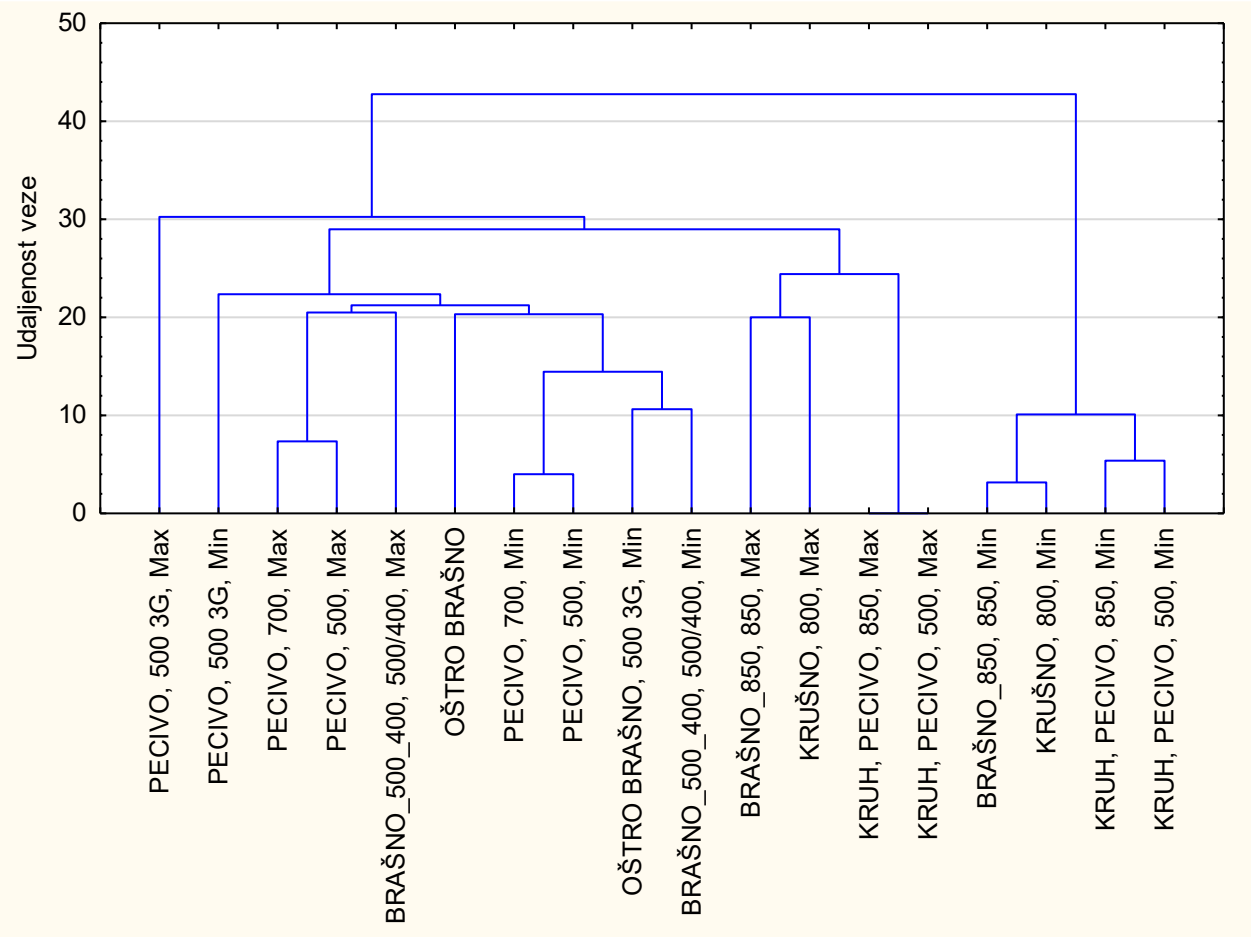

Slika 8 Dendogram klasterske analize krušnog brašna koje prerađivači zahtijevaju

Na slici (**slika 8**) vidljiv je grafički rezultat klasterske analize zahtijevanih tipova krušnog brašna gdje se određena brašna mogu svrstati u klastere po slični vrijednostima zahtijevanih svojstava brašna. Tako će, npr. isto brašno zadovoljiti sva četiri zahtjeva na kraju apscisne osi.

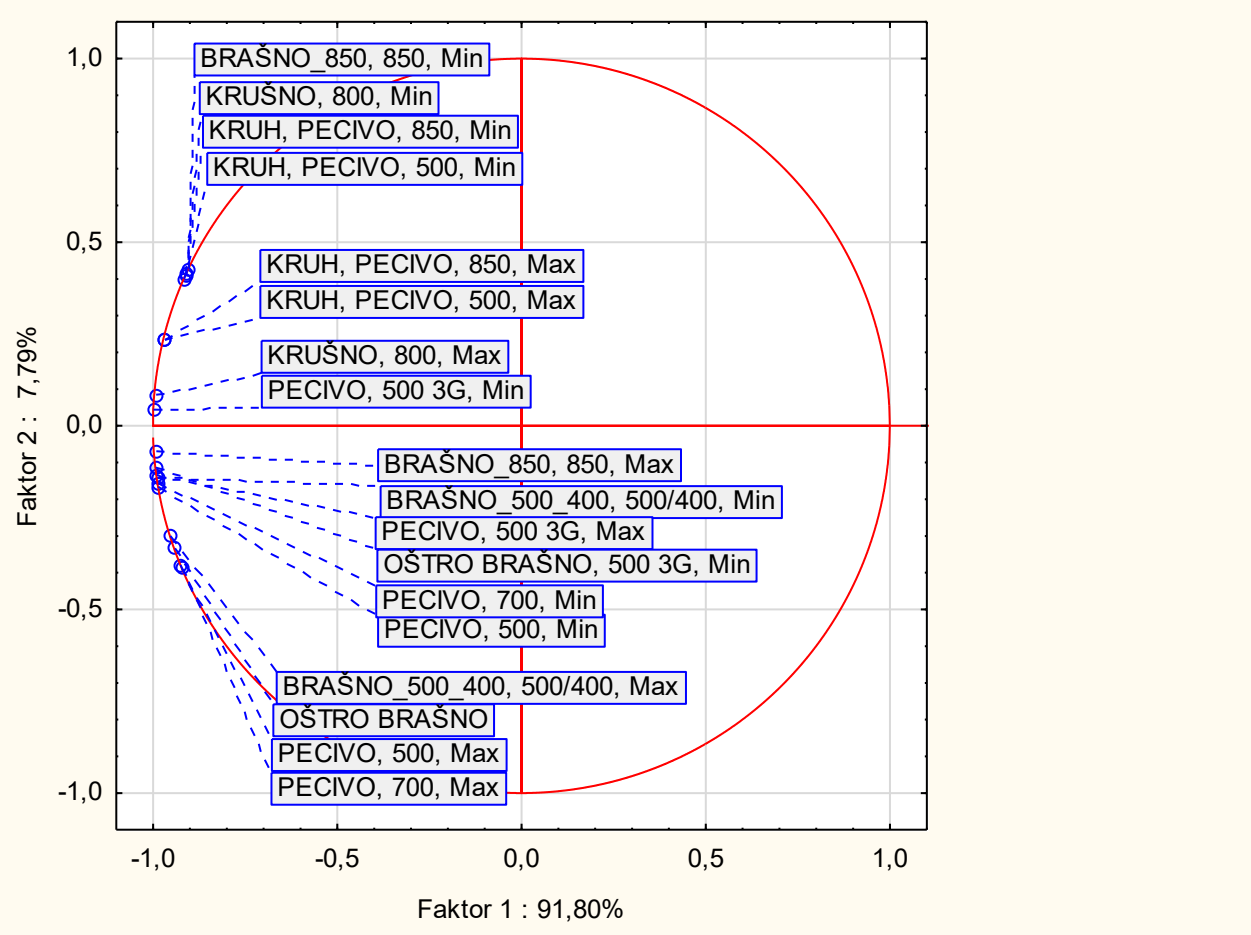

Slika 9 Grupiranje vrsta krušnog brašna i brašna za peciva u prve dvije faktorske ravnine

Na slici **(slika 9**) je vidljivo grupiranje vrsta krušnog brašna i brašna za pecivo unutar prve dvije faktorske ravnine. Prve dvije glavne komponente obuhvaćaju 99,59 % ukupne varijance. Može se vidjeti jasnije grupiranje po osi y. Proizvode koji su bliži po zahtijevanim svojstvima bit će moguće proizvesti korištenjem istog brašna.

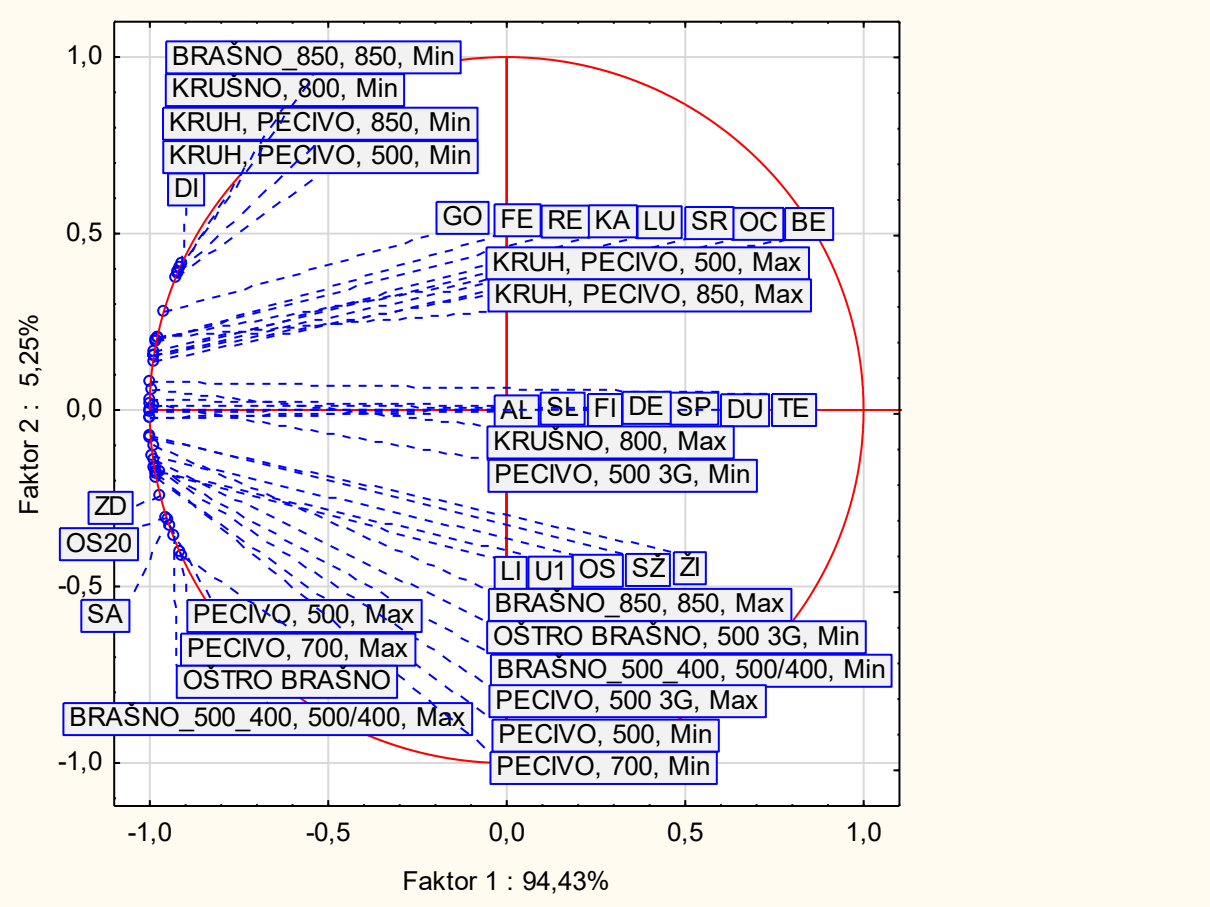

Slika 10 Grupiranje zahtjeva proizvođača za proizvode i kultivara u prve dvije faktorske razine

Na slici (**slika 10**)je vidljivo zajedničko grupiranje zahtjeva proizvođača za krušno brašno i brašno za pecivo zajedno s kultivarima pšenice. Prve dvije glavne komponente obuhvaćaju 99,68 % ukupne varijance. Kultivari koji su na ovom grafičko prikazu fizički bliži zahtjevima za brašno za određeni proizvod imaju veći potencijal dati kvalitetan proizvod. Takva informacija je korisna proizvođaču prilikom nabave sirovine

5. RASPRAVA

U **tablici 4** prikazani su definirani zahtjevi proizvođača za namjensku kvalitetu brašna. Najvažnija svojstva kvalitete prema definiranim zahtjevima su: vlažni gluten, upijanje vode, stupanj omekšanja, kvalitetna grupa, maksimalni otpor i rastezljivost. Kada se promatra raspon vrijednosti za pojedina zahtijevana svojstva, može se primijetiti da ne postoji puno velikih oscilacija u vrijednostima. Najveće raspone vrijednosti imaju: stupanj omekšanja u rasponu od 18 do 120 FJ, otpor u rasponu od 150 do 400 EJ, maksimalni otpor u rasponu od 300 do 600 EJ, energija u rasponu od 60 do 115 cm^2 i maksimalni viskozitet u rasponu od 300 do 750 EJ.

U tablici 5 nalazi se izmjerenih 19 svojstva na 24 kultivara pšenice kroz 10 godina. Mjerenja su provedena u Laboratoriju za kvalitetu pšenice na Poljoprivrednom Institutu Osijek. **Tablica 6** pokazuje rezultate deskriptivne statistike. Ovi podatci su izračunati na temelju podataka iz **tablice 5** Koeficijenti varijabilnosti pokazuju koliko se vrijednost određenog svojstva mijenjala ili koliko je stabilna. Najstabilnije vrijednosti su se pokazale za moć upijanja vode, izbrašnjavanje, omjer vlažnog glutena i proteina i udio proteina što potvrđuje literaturni izvor (Stojanović, 2019). Najvarijabilnija svojstva su: vrijeme razvoja tijesta, stabilnost tijesta i otpor.

Slika 3 prikazuje kutijasti dijagram koji također opisuje koliko su vrijednosti svojstva odstupale od srednje vrijednosti kroz vremenski period od 10 godina. Može se vidjeti da su maksimalni otpor, otpor nakon 5 minuta, broj padanja i farinografski broj kakvoće najviše odstupali od srednje vrijednosti kroz 10 godina. **Slika 4** pokazuje isti kutijasti dijagram s izbačenim svojstvima čija vrijednost prelazi 160 a to su: maksimalni otpor, otpor nakon 5 minuta, rastezljivost i broj padanja.

Na slici 5 može se vidjeti dendogram koji opisuje klastersku analizu. Kultivari su prema vrijednostima svojstva grupirani u klastere. Može se vidjeti da Divana (DI) potpuno odudara od svih drugih klastera kao i U1 i S. Prolific (SP). **Na slici 8** nalazi se dendogram za zahtjeve proizvođača za određene proizvode. Na tom dendogramu može se vidjeti da Brašno 850, 850, Min; Krušno, 800, Min; Kruh i pecivo, 850, Min; Kruh, pecivo, 500, Min spadaju u jedan klaster i da mogu koristiti isto brašno, a koje bi ispunilo zahtjeve proizvođača.

Na slici 6 može se vidjeti raspored kultivara u prve dvije faktorske ravnine. Kultivari su raspoređeni po svojim razlikama u svojstvima. Prve dvije faktorske ravnine obuhvaćaju 99,15 % ukupne varijance. Može se primijetiti da se kultivari koji su fizički bliže Divani (DI) kao

što su Lucija (LU), Katarina (KA), Demetra (DE) i Srpanjka (SR), razlikuju po drugoj faktorskoj ravnini od U1, S. Prolifica (SP), Osječke 20 (OS20). To znači da se ta brašna ne mogu koristiti za proizvodnju kruha jednakih svojstava i kvalitete. U1 i S. Prolific (SP) su kultivari kojima bi trebalo dodati Divanu (DI) kao aditiv da ako bi se npr. želio dobiti kruh koji ima dobar volumen.

Slika 7 na kojoj su raspoređena svojstva u prve dvije faktorske analize govori o tome koliki utjecaj imaju u objašnjavanju ukupne varijance. Može se vidjeti da svojstva kao što su RMAX, R5MIN i FN imaju velik utjecaj na objašnjavanje ukupne varijance. Također, svojstva kao što su: WG, P, RMAX/EXT, R/EXT, STAB i DDT imaju također veliki utjecaj na objašnjavanje ukupne varijance ali se na grafu nalaze blizu što je u skladu s literaturnim izvorom (Vasilj, 2016). Stoga je moguće uzeti samo jedno od tih svojstava kako bi opisali utjecaj na ukupnu varijancu za sva svojstva koja su navedena. Prve dvije faktorske ravnine obuhvaćaju 99,16 % ukupne varijance.

Slika 9 pokazuje raspored zahtjeva proizvođača za krušna brašna u prve dvije faktorske ravnine kojima je obuhvaćeno 99,59 % ukupne varijance. Zahtjevi su također raspoređeni po razlikama i može se vidjeti da *Factor* 2 pridonosi preglednom rasporedu i uočavanju razlika. Zahtjevi koji su na suprotnim stranama u odnosu na središnju os *Factora* 2 ne mogu biti zadovoljeni istim brašnom, ali zahtjevi koji su na grafu blizu mogu koristiti istu sirovinu za proizvodnju kvalitetnog proizvoda. **Slika 10** još bolje pokazuje koje brašno odgovara određenim zahtjevima. Vidljivi su zahtjevi proizvođača i kultivari raspoređeni u prve dvije faktorske ravnine kojima je obuhvaćeno 99,68 % ukupne varijance. Što su kultivari bliže zahtjevima imaju veći potencijal proizvesti kvalitetan proizvod bez dodataka aditiva. Može se vidjeti da Divana (DI) odudara od svih kultivara i da zadovoljava zahtjeve za Brašno 850, Min; Krušno, 800, Min; Kruh, Pecivo, 850, Min; Kruh, Pecivo, 500 min. To je vidljivo i u klasterskoj analizi. Također, Divana bi mogla poslužiti kao aditiv drugim brašnima kako bi povećali udio proteina što daje na volumenu kruha što potvrđuje literaturni izbor (Belošević, 2005). Zahtjevima za Kruh, Pecivo, 500, Max i Kruh, Pecivo, 850, Max odgovaraju kultivari Felix (FE), Renata (RE), Katarina (KA), Lucija (LU), OS Crvenka (OC), Bezostaja 1 (BE), dok je Golubica (GO) malo udaljeniji od spomenutih zahtjeva i moguće je da bi bio potreban dodatak određene količine aditiva. Zahtjevima Krušno, 800, Max i PECIVO, 500 3G, Min odgovaraju kultivari Alka (AL), Slavonija (SL), Ficko (FI), Demetra (DE), S. Prolific (SP), Dubrava (DU) i Tena (TE). Zahtjevima za Brašno_850, 850, Max; Oštro Brašno, 500 3G, Min; Brašno_500_400, 500/400, Min; Pecivo, 500 3G, Max; Pecivo, 500, Min; Pecivo, 700, Min odgovaraju kultivari Lucija (LU), U1, Osječanka

(OS), S. Žitarka (SŽ), Žitarka (ŽI). Pokazalo se da zahtjeve za Brašno_500_400, 500/400, Max; Oštro Brašno, 500 3G, Max; Pecivo 500, Max i Pecivo, 700, Max mogu zadovoljiti kultivari Osječanka 20 (OS20) i Sana (SA), što pokazuje i blizina navedenih zahtjeva i kultivara na grafu. S druge strane, može se vidjeti da je Zlatna dolina (ZD) malo udaljeniji kultivar na grafu od spomenutih zahtjeva, te se može pretpostaviti potreba za dodavanje određene količine aditiva kako bi se dobio kvalitetan proizvod sa spomenutim zahtjevima.

6. ZAKLJUČCI

Svojstva 24 kultivara izmjerena su na Poljoprivrednom Institutu u Osijeku, deskriptivna statistika je izračunata na temelju izmjerenih vrijednosti kultivara. Zahtjevi proizvođača za proizvode dobiveni su od strane samih proizvođača.

Zaključci koje je moguće izvesti na temelju rezultata deskriptivne statistike:

- Najveći koeficijent stabilnosti imaju vrijeme razvoja tijesta, stabilnost tijesta i otpor,
- Najmanji koeficijent stabilnosti imaju moć upijanja vode, izbrašnjavanje, omjer udjela vlažnog glutena i proteina, udio proteina.

Zaključci koje je moguće izvesti na temelju kemometrijske analize podataka:

- Klasterskom analizom grupirani su zahtjevi i kultivari po sličnim vrijednostima. Ovo klasiranje u grupe ne znači da su članovi u grupi međusobno povezani nego da su im vrijednosti slične. Divana po svojim svojstvima odudara od svih drugih klastera. U1 i S.Prolific također odudaraju od drugih klastera. Brašno_850, 850, Min; Krušno, 800, Min; Kruh i pecivo, 850, Min; Kruh, pecivo, 500, Min po zahtjevima spadaju u isti klaster i stoga se za proizvodnju brašna koje ispunjava zahtjeve tog klastera može koristiti isti kultivar.
- Faktorska analiza prikazuje raspored zahtjeva i kultivara po raznolikosti. Proizvodi čiji su zahtjevi bliži na grafu imaju veću mogućnost da se proizvode od istog brašna. Što su na grafu kultivari bliži zahtjevima, to je veća mogućnost da će taj kultivar dati kvalitetan proizvod bez dodataka aditiva.
- Analizu glavnih komponenti možemo definirati kao način prikazivanja podataka u svrhu pronalaženja njihovih sličnosti i razlika. Matematičkim putem se računaju nove varijable odnosno glavne komponente.

Prikazivanjem zahtjeva proizvođača i kultivara u prve dvije faktorske ravnine kojima se obuhvaća 99, 68 % ukupne varijance mogu se izvući sljedeći zaključci:

- Brašno_850, Min; Krušno, 800, Min; Kruh, Pecivo, 850, Min; Kruh, Pecivo, 500 min može se proizvesti od Divane. Također, Divana može služiti kao aditiv drugim kultivarima.
- Kruh, Pecivo, 500, Max i Kruh, Pecivo, 850, Max može se proizvesti od Felix, Renata, Katarina, Lucija, OS Crvenka, Bezostaja 1. Golubica je kultivar kojemu je potrebno dodati aditive da bi se proizveo proizvod unutar zahtjeva kvalitete.

- Krušno, 800, Max i PECIVO, 500 3G, Min odgovaraju kultivari Alka, Slavonija, Ficko, Demetra, S. Prolific, Dubrava i Tena.
- Brašno_850, 850, Max; Oštro Brašno, 500 3G, Min; Brašno_500_400, 500/400, Min; Pecivo, 500 3G, Max; Pecivo, 500, Min; Pecivo, 700, Min odgovaraju kultivari Lucija, U1, Osječanka, S. Žitarka, Žitarka.
- Brašno_500_400, 500/400, Max; Oštro Brašno, 500 3G, Max; Pecivo 500, Max i Pecivo, 700, Max odgovaraju kultivari Osječka 20 i Sana. Za Zlatnu dolinu je potrebno dodati aditive kako bi proizveli odgovarajući proizvod.

Ovakve informacije korisne su proizvođačima prilikom nabave sirovine jer se pravilnim izborom sirovine može dobiti proizvod zahtijevane kvalitete uz manje troškove proizvodnje. To znači da izborom pravog kultivara potpuno ili djelomično izbjegavamo potrebu za dodavanjem aditiva koji znače skuplju proizvodnju.

7. LITERATURA

Ambrosewicz-Walacik M, Tanska M, Rotkiewicz D, Andrzej Pietak: Effect of NaCl Addition on Bread Characteristics, Food technology and Biotechnology, **54**(2): 172-179, Olsztym (Polland), 2016.

Belderok B, Mesdag H, Donner DA: Bread – Making quality of wheat, A century of breeding Europe, Dordrecht, 2000.

Belošević S: Reološka svojstva brašna ozimih i jarih pšenica žetve 2003. Diplomski rad, Prehrambeno.biotehnološki fakultet u Zagrebu, Zagreb, 2005.

Brereton RG: Applied Chemometrics for scientists, Wuley, Chichester, 2007.

Devčić K, Tonković Pražić I, Župan Ž: Klater analiza: primjena u marketinškim istraživanjima, Zbornik radova Međimurskog veleučilišta u Čakovcu **3**(1):15-22, 2011.

Đaković Lj: Pšenično brašno, fizičko-hemijski osnovi određivanja tehnološkog kvaliteta pšeničnog brašna. Tehnološki fakultet Zavod za izdavanje udžbenika Novi Sad, 1980.

Fulgosi A: Faktorska Analiza, Školska knjiga, Zagreb, 1984.

Hair JF, Black WC, Babin BJ, Anderson RE: Multivariate Data Analysis – A Global Perspective, Upper Saddle River NJ: Prentice Hall, 2010.

Kljusurić S : Uvod u tehnologiju mljevenja pšenice, Prehrambeno-tehnološki fakultet, Metković, 2000.

Krička T, Jukić Ž, Voća N, Voća S, Maksić D: Mathematical Models of Influence of total Admixtures and Kernel Moisture on Hectoliter Weigh of Wheat, Agriculturae Conspects Scientificus, Vol. 67, No. 2, 91-99, Zagreb, 2002.

Pecina M: Metode multivarijantne analize-osnove, Interna skripta, Agronomski fakultet, Sveučilište u Zagrebu, Zagreb, 2006.

Pravilnik o žitaricama, mlinskim i pekarskim proizvodima, tijestu i proizvodima od tijesta, (NN78/2005).

Stojanović F: Primjena kemometrijskih metoda za razvrstavanje namjenskog brašna prema zahtjevima prerađivača. Diplomski rad, Prehrambeno-tehnološki fakultet u Osijeku, Osijek, 2019.

Ugarčić-Hardi Ž: Tehnologija proizvodnje i prerade brašna, Opći dio i skladištenje žitarica, Interna skripta. Prehrambeno-tehnološki fakultet, Osijek, 1999a.

Ugarčić-Hardi Ž: Tehnologija proizvodnje i prerade brašna, Pekarstvo, Interna skripta. Prehrambeno-tehnološki fakultet, Osijek, 1999b.

Ukić Š: Nazivlje u kemometriji, Časopis kemičara i kemijskih inženjera Hrvatske, **65**(3-4): 181-182, Zagreb, 2016.

Vasilj I: Kemometrijski model zavisnosti svojstava kvalitete pšeničnog zrna i brašna. Diplomski rad, Prehrambeno-tehnološki fakultet u Osijeku, Osijek, 2016.

Web1: Huzjak M: Opisna statistika. 2016. http://dama.math.hr/hnm/index.php?title=Opisna_statistika [05.07.2018]

Web 2: The Regents of the University of Michigan: *Descriptive statistics*. 2017. https://www.researchconnections.org/childcare/datamethods/descriptivestats.jsp [08.07.2018]

Web 3: Inspecto: *Žetva pšenice u Hrvatskoj rod 2017*. 2017. https://www.inspecto.hr/hr/blog/zetva-psenice-u-hrvatskoj-rod-2017/ [05.03.219]

Žeželj M: Tehnologija žita i brašna, Beograd, Glas javnosti 2005.

Žeželj M: Tehnologija žita i brašna- knjiga II, Beograd, Glas javnosti, 2005.