Procjena pekarske kvalitete kultivara ozime pšenice primjenom kemometrijske analize glavnih komponenata (PCA)

Filipović, Marija

Master's thesis / Diplomski rad

2018

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:109:368864

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

REPOZITORIJ PTFOS PREHRAMBENO-TEHNOLOŠKI FAKULTET OSIJEK dabar DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Repository / Repozitorij:

Repository of the Faculty of Food Technology Osijek

zir.nsk.hr

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

dabar DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
PREHRAMBENO – TEHNOLOŠKI FAKULTET OSIJEK

Marija Filipović

PROCJENA PEKARSKE KVALITETE KULTIVARA OZIME PŠENICE PRIMJENOM KEMOMETRIJSKE ANALIZE GLAVNIH KOMPONENATA (PCA)

DIPLOMSKI RAD

Osijek, srpanj 2018.

TEMELJNA DOKUMENTACIJSKA KARTICA
diplomski rad
Sveučilište Josipa Jurja Strossmayera u Osijeku
Prehrambeno-tehnološki fakultet Osijek
Zavod za prehrambene tehnologije
Katedra za tehnologije prerade žitarica
Franje Kuhača 20, 31000 Osijek, Hrvatska

Diplomski sveučilišni studij Prehrambeno inženjerstvo
Znanstveno područje: Biotehničke znanosti
Znanstveno polje: Prehrambena tehnologija
Nastavni predmet: Tehnologija proizvodnje i prerade brašna
Tema rada je prihvaćena na VIII. (osmoj) redovitoj sjednici Fakultetskog vijeća Prehrambeno-tehnološkog fakulteta Osijek u akademskoj godini 2017./2018. održanoj 28. svibnja 2018.
Mentor: prof. dr. sc. Daliborka Koceva Komlenić
Komentor: doc. dr. sc. Jasmina Lukinac Čačić
Pomoć pri izradi: Ana Šušak, dipl. ing.

Procjena pekarske kvalitete kultivara ozime pšenice primjenom kemometrijske analize glavnih komponenata (PCA)

Marija Filipović, 448-DI

Sažetak:
Istraživanje je obuhvatilo 54 sorte ozime pšenice roda 2017. godine zasijane na lokacijama osječkog i zagrebačkog područja. Kvaliteta uzoraka pšenice analizirana je mjerenjem fizikalno-kemijskih svojstava zrna i brašna, te reoloških pokazatelja kvalitete brašna, a njihova povezanost utvrđena je primjenom kemometrijske analize glavnih komponenata (PCA). Na temelju dobivenih rezultata utvrđena je statistički značajna razlika većine analiziranih parametara kvalitete pšenice između dvije lokacije, te su uzorci s osječke lokacije pokazali veće vrijednosti kvalitete. Provedenom PCA analizom moguće je objasniti 78% varijacije u promatranom skupu podataka koja je pojašnjena pomoću dvije glavne komponete. Fizikalno-kemijski te ekstenzografski pokazatelji kvalitete pšenice najveći utjecaj prvoj glavnoj komponenti F1, koja objašnjava oko 62% varijabilnosti uzoraka. Druga glavna komponenta doprinosi s 16,02 % pojašnjenju varijanci u promatranom skupu podataka, a tu dominiraju ekstenzografski pokazatelji kvalitete pšenice (O i O/R).

Ključne riječi: pšenica, kvaliteta, kultivar, multivarijantna analiza, analiza glavnih komponenti

Rad sadrži: 56 stranica
17 slika
9 tablica
0 priloga
37 literaturnih referenci

Jezik izvornika: hrvatski

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

1.	izv. prof. dr. sc. Marko Jukić	predsjednik
2.	prof. dr. sc. Daliborka Koceva Komlenić	član-mentor
3.	doc. dr. sc. Jasmina Lukinac Čačić	član-komentor
4.	doc. dr. sc. Ivana Rukavina	zamjena člana

Datum obrane: 20. srpnja 2018.

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

BASIC DOCUMENTATION CARD
graduate thesis
Josip Juraj Strossmayer University of Osijek
Faculty of food technology Osijek
Department of Food technologies
Subdepartment of Cereal technology
Franje Kuhača 20, HR-31000 Osijek, Croatia

Graduate program Food Engineering
Scientific area: Biotechnical sciences
Scientific field: Food technology
Course title: Technology of flour production and processing
Thesis subject: was approved by the Faculty of Food Technology Osijek Council at its session no. VIII. held on May 28, 2018.
Mentor: *Daliborka Koceva Komlenić,* PhD, prof.
Co-supervisor: *Jasmina Lukinac Čačić*, PhD, assistant prof.
Technical assistance: Ana Šušak

Baking Quality Evaluation of Winter Wheat Cultivars with the Application of the Chemometric Technique Principal Component Analysis (PCA)

Marija Filipović, 448-DI

Summary:
The study included 54 varieties of winter wheat cultivars harvested in 2017 in the locations of Osijek and Zagreb. The quality of wheat samples was analyzed by measuring the physical-chemical properties of grain and rheological quality properties of flour. Their correlation was determined using the chemometric technique of principal component analysis method (PCA). Based on the obtained results, statistically significant difference were observed for samples from different locations. Samples from the Osijek location showed higher quality values for most of the analyzed parameters. The PCA analysis performed explains 78% variations in the observed data set, which was explained by two components. Physical-chemical and extensographic wheat quality indicators have the greatest impact on the first component F1, which accounts for about 62% of sample variability. The second component contributes with 16.02% clarification of variance in the observed data set, dominated by extensographic wheat quality parameters (O and O / R).

Key words: wheat, quality, cultivars, multivariate analysis, principal component analysis

Thesis contains:
56 pages
17 figures
9 tables
0 supplements
37 references

Original in: Croatian

Defense committee:

1.	Marko Jukić, PhD, associate prof.	chair person
2.	Daliborka Koceva Komlenić, PhD, prof.	supervisor
3.	Jasmina Lukinac Čačić, PhD, assistant prof.	co-supervisor
4.	Ivana Rukavina, PhD, assistant prof.	stand-in

Defense date: July 20, 2018.

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

Sadržaj

1. UVOD **1**

2. TEORIJSKI DIO **3**

1. PŠENICA 4

1.1. Morfološka svojstva 4

1.2. Kemijska svojstva pšeničnog zrna 5

1.3. Pšenično brašno 6

2. METODE 7

2.1. Određivanje udjela vode u pšenici 7

2.2. Određivanje udjela pepela u pšenici 8

2.3. Određivanje udjela proteina (bjelančevina) u pšenici 8

2.4. Određivanje sedimentacijske vrijedosti (po Zeleny-u) 9

2.5. Određivanje mase 1000 zrna 10

2.6. Određivanje hektolitarske mase 10

2.7. Izbrašnjavanje 11

2.8. Određivanje udjela vode u brašnu 12

2.9. Određivanje udjela vlažnog glutena 12

2.10. Određivanje reoloških svojstava farinografom 13

2.11. Određivanje reoloških svojstava ekstenzografom 14

2.12. Određivanje amilografom 15

2.13. Određivanje „broja padanja“ 16

3. MULTIVARIJANTNA ANALIZA PODATAKA (engl. *Multivariate analysis*) 18

3.1. Faktorska analiza (engl. *Factor analysis*) 19

3.2. Analiza glavnih komponenata (engl. *Principal Component Analysis*) 22

3.3. Višestruka regresija (engl. *Multiple Regression*) 28

3.4. Klaster analiza (engl. *Cluster analysis*) 28

3.5. Regresijska analiza metodom najmanjih kvadrata (engl. *Partial least squares method*) 29

3. EKSPERIMENTALNI DIO **30**

3.1. Zadatak 31

3.2. MATERIJALI 31

3.3. METODE 31

3.3.1. Određivanje kvalitete uzoraka pšenice 31

3.3.1.1. Fizička svojstva zrna 31

3.3.1.2. Kemijsko–tehnološka svojstva zrna i brašna 31

3.3.1.3. Reološki pokazatelji kvalitete 32
3.3.2. Analiza obrada podataka primjenom metode glavnih komponenata 32
3.3.2.1. Osnovna statistička analiza pokazatelja kvalitete pšenice 32
4. REZULTATI I RASPRAVA 34
4.1. Rezultati mjerenja fizikalno-kemijskih i reoloških analiza brašna i tijesta 35
4.2. Obrada rezultata fizikalno-kemijskih i reoloških analiza brašna i tijesta primjenom metode PCA 42
4.2.1. Procjena broja glavnih komponenti 44
5. ZAKLJUČCI 50
6. LITERATURA 53

Popis tablica

Tablica 1 Ulazni podatci u analizi PCA 25
Tablica 2 Utjecaj lokacije na kvalitetu ozime pšenice roda 2017. godine 35
Tablica 3 Utjecaj lokacije na reološka svojstva ozime pšenice roda 2017. godine 36
Tablica 4 Deskriptivna statistika pokazatelja kvalitete 27 sorti ozime pšenice na dvije lokacije: Osijek i Zagreb 42
Tablica 5 Pearson-ova korelacijska matrica pokazatelja kvalitete ozime pšenice 43
Tablica 6 Pearson-ova korelacijska matrica pokazatelja kvalitete ozime pšenice na različitim lokacijama nakon selekcije varijabli koje su pokazale visoku korelaciju 44
Tablica 7 Matrica kovarijanci za standardizirane vrijednost (korelacijska matrica) 45
Tablica 8 Vrijednosti svojstvenih vektora u prve tri glavne komponente 46
Tablica 9 Korelacija promatranih varijabli i glavnih komponenti 48

Popis slika

Slika 1 Uređaj za određivanje sedimentacijske vrijednosti po Zeleny-u 9
Slika 2 Shopperova vaga 10
Slika 3 Farinograf 13
Slika 4 Ekstenzograf 14
Slika 5 Amilograf 15
Slika 6 Uređaj za određivanje FN po Hagberg-Pertenu 16
Slika 7 Faktorska analiza podataka 20
Slika 8 Analiza glavnih komponenti – geometrijski prikaz glavnih komponenti F1 i F3 22
Slika 9 Geometrijski prikaz rješenje PCA metodom 24
Slika 10 Vrijednosti hektolitarske mase ispitivanih uzoraka pšenice 37
Slika 11 Raspodjela ispitivanih uzoraka pšenice prema udjelu proteina i sedimentacijskoj vrijednosti 38
Slika 12 Raspodjela ispitivanih uzoraka pšenice prema razredima kakvoće 39
Slika 13 Vrijednosti vlažnog glutena ispitivanih uzoraka pšenice 40
Slika 14 Raspodjela ispitivanih sorti pšenice na kvalitetne grupe 41
Slika 15 Scree test svojstvenih vrijednosti po glavnim komponentama 46
Slika 16 Prikaz pojedinih pokazatelja kvalitete pšenice prema glavnim komponentama F1 i F2 47
Slika 17 PCA analiza pokazatelja kvalitete pšenice na temelju vrijednosti dvije glavne komponente . 49

1. UVOD

Pšenica je kultura koja se dobro prilagođava klimi i tlu, te ima puno vrsta i kultivara. Postoje ozime i jare forme, pa se uzgaja gotovo posvuda. Pšenica je najvažniji ratarski usjev, a uzgaja se na oko 23 % svjetskih obradivih površina. Značajnosti pšenice svjedoči podatak da je po ukupnoj proizvodnji druga, (odmah iza kukuruza), najvažnija ratarska kultura u svijetu te je nezamjenjiva u prehrani ljudi. Pravilan izbor sorte za određeno područje uzgoja daje odgovarajuću sigurnost u proizvodnji, jer neuspjesi u proizvodnji često nastaju zbog nepravilno određenog sortimenta, kao i zbog nepoznavanja specifičnosti u uzgoju pojedinih sorti. U domaćoj proizvodnji gotovo sve površine zauzimaju visokorodne sorte domaćeg podrijetla. Sorte koje se u nas uzgajaju imaju uglavnom zadovoljavajuću otpornost na različite vremenske uvjete. (Jurišić, 2008)

Pšenična zrna su glavni prehrambeni proizvod koji se melje do brašna i krupice potrebnih za izradu kruha, peciva, keksarskih proizvoda, kolača i tjestenine. Pšenično brašno, pšenična krupica i pšenična prekrupa su proizvodi koji se dobivaju mljevenjem endosperma pšenice nakon izdvajanja usploda i klice (Pravilnik, 81/2016).

Pšenica se prije svega koristi kao krušna biljka, koristi se u proizvodnji piva, alkohola i bio goriva. Pored toga, ovojnice pšenice koje se odvajaju u procesu proizvodnje mlinskih proizvoda zovu se posije koje se mogu koristiti za prehranu čovjeka i za ishranu stoke.

Pšenica mora ispunjavati određene uvjete kvalitete i higijenske ispravnosti, a kvalitetu zrna pšenice čini više pokazatelja. Tehnološki pokazatelji kvalitete pšenice procjenjuju se na temelju reoloških svojstava brašna dobivenog iz pšenice, reološkim metodama pomoću farinografa, ekstenzografa, alveografa i amilografa.

U ovom radu provedena je analiza kvalitete pšenice mjerenjem fizikalno-kemijskih svojstava zrna i brašna te reoloških svojstava brašna različitih sorti pšenice zasijanih na različitim lokacijama. Cilj rada bio je primjenom metode glavnih komponenata ispitati povezanost izmjerenih parametara kvalitete pšenice (sličnosti i različitost uzoraka) te izdvojiti najvažnije parametre za procjenu kvalitete pšenice.

2. TEORIJSKI DIO

1. PŠENICA

Pšenica je jedna od najstarijih i najrasprostranjenijih od svih zrnatih usijeva. Prihvaćeno je da je pšenica uzgojena kao hrana oko 10000 – 8000 godina prije Krista. Zajedno s ostalim žitaricama pšenica je postala glavni razlog za prijelaz iz nomadskog načina života na sjedilački. Ljudi su se smjestili na jednom mjestu i uzgajali usjeve koji se mogu pohraniti dugo nakon žetve (Diamond, 1997).

Jedna je od tri najvažnije žitarice u svijetu uz rižu i kukuruz (Heywood 1993; Morrison and Wrigley 2004). Pšenica pripada redu Poales, porodici Poaceae (trave), potporodice Pooideae (klasaste trave), rodu Triticum. Pšenice postoje kao jare i ozime forme. Jara pšenica koja je posijana u proljeće razvit će se normalno i donjeti plod za razliku od ozima pšenice koja ima određene zahtjeve prema uvjetima vanjske okoline. Zahtijeva niže temperature (0-10°C) tijekom 10 do 35 dana. Ukoliko ti uvjeti nisu ispunjeni ona neće dati plod (Jurišić, 2008).

Pšenica je osnovna sirovina u mlinarstvu i kao takva razvrstava se prema kakvoći i namjenskim svojstvima brašna i drugih mlinarskih proizvoda koji se od nje dobivaju. Sorta je osnovni nosilac kvalitete, te razlike za istu sortu koje su vezane uz klimatske uvjete uzgoja, prirodni sastav zemljišta i gnojidbu, vlažnost tla i natapanje, način uzgoja i agrotehničku obradu, utjecaj bolesti i šetnika, trajanje vegetacije, veličinu zrna i drugo (Belak i sur., 2005).

1.1. Morfološka svojstva

Korijen je žilličast, a glavna masa korijenovih žila nalazi se u oraničnom sloju (do 40 cm dubine), a manji dio žila prodire znatno dublje (150 – 200 cm). U vrijeme klijanja sjemena javlja se primarno korijenje. Ozima pšenice najčešće klijaju s tri, a jara s pet korijenčića. Ovo korijenje je osnovno korijenje do busenja. Oko tri tjedna poslije nicanja iz čvora busenja izbija sekundarno korijenje.

Stabljika je cilindrična, sastavljena od koljenica i 5-6 članaka. Najduži članak je vršni na kojem izbija klas. Stabljika je šuplja izuzev kod nekih vrsta pšenice kod kojih je vršni članak ispod klasa ispunjen parehnimskim tkivom. Visina stabljike iznosi 50 -120 cm. U proizvodnji pšenice daje se prednost sortama kraće stabljike, jer su otpornije na polijeganje.

List se sastoji od plojke i rukavca između kojih se nalaze jezičak i uške. Pšenica ima dugu, linearnu plojku. Po veličini, obliku i boji jezička te uški mogu se razlikovati sorte. Najrazvijeniji su gornji i srednji listovi.

Cvijetovi su skupljeni u cvat – klas. Klas se sastoji od klasnog vretena na kojem se nalaze usjeci, pa ono ima koljenas izgled. Na usjecima se nalaze klasići naizmjenično s obje strane. Klasići se sastoje od vretenca, dvije pljeve i cvjetova. U jednom klasiću može biti 2-7 cvjetova. Cvijet se sastoji od dvije pljevice, dvije pljevičice, prašnika i tučka.

Plod kod pšenice je zrno. Može biti različite krupnoće ovisno o vrsti i sorti. U klasu se obično razvije oko 30-40 zrna (Gargo, 1997).

Zrno pšenice je ovalnog oblika s uzdužnom brazdom usječenom u endosperm. Različite je veličine, ovisno o sorti što može utjecati na izbrašnjavanje. Dužina zrna varira od 4,2 do 8,6 mm, širina može biti 1,6 do 4,0 mm, a debljina zrna može biti od 1,5 do 3,8 mm. (Jelača, 1972).

Pšenično zrno sastoji se od omotača ili ljuske, endosperma i klice (Hosenay, 1994).

Omotač se sastoji od sjemene i plodne ovojnice ispod koje je aleuronski sloj. Omotač čini od 6 do 26 % ukupne mase. Endosperm je izgrađen od unutarnjeg dijela ili jezgre (75-85%) i vanjskog dijela ili aleuronskog sloja (6,3-8,9%). Pod endospermom se podrazumijeva sama jezgra koja je bogata škrobom, dok je udio mineralnih tvari, bjelančevina, celuloze, pentozana, enzima i vitamina vrlo nizak (Žeželj, 1982).

Klica čini 1,4-3,8 % zrna pšenice. Sastoji se od embrijske osi i skuteluma (spremišta hrane). Klica sadrži važnu količinu vitamina riboflavina, vitamina E i tiamina. Sadrži 9,45% masti, 1,55% fosfolipida, 0,2 do 3,5% reducirajućih šećera, od 4 do 6% rafinoze. Bogata je linolenskom, oleinskom, linoleinskom, palmitinskom aminokiselinom (Ugarčić-Hardi, 1999).

1.2. Kemijska svojstva pšeničnog zrna

Maseni udjel vode pšenice treba biti u granicama od 10-14%, dok je iznad 16% udjel vode nepovoljan jer se zrna teško čuvaju i podložna su kvarenju. U zrnu pšenice je od 1,5 do 2% masti. Najvećim dijelom masti se nalaze u klici. Klicu odvajamo pri mljevenju kako bi brašno mogli duže čuvati.

Od mineralnih tvari u pšenici su prisutni: fosfor (50%), kalij (20-30%), kalcij, magnezij, silicij, željezo i ostali elementi. Najviše se mineralnih tvari nalazi u sjemenoj ovojnici. Prilikom mljevenja u mlinu odstranjuje se glavnina ovojnice zrna, a s njim i mineralne tvari.

Proteini su najvažniji sastojak zrna pšenice, nazali se u količini od 6-20%. Udio proteina ovisi o puno činitelja, ponajprije vrsti i sorti, klimatskim uvjetima, tipu tla i njegovim kemijskim svojstvima. Ozima pšenica ima manji udjel proteina od jarih sorti, meka pšenice manje od tvrdih, brašnave manje od staklastih. Pšenice iste sorte uzgojene u vlažnom području imaju manji udio proteina nego one uzgojene u suhim područjima.

Celuloza se nalazi u omotaču ploda i sjemena s udjelom oko 2-3%. Kod pšenice koja je uzgojena u vlažnijim krajevima veći je maseni udjel celuloze nego kod onih uzgojenih u suhim krajevima.

Ugljikohidrati čine 64-69% kemijskih sastojaka pšenice. Nalaze se u endospermu. Glavni sastojak ekstraktivnih tvari pšeničnih ugljikohidrata je škrob.

Vitamini se nalaze pretežno u klici zrna. Najviše ima vitamina B skupine i to B1 (tiamin), B2 (riboflavin) te vitamin E i K. O vrsti i sorti pšenice ovisi udio vitamina (Gagro, 1997, Hoseney, 1994).

1.3. Pšenično brašno

Pšenično brašno se dobiva mljevenjem očišćene pšenice, korištenjem odgovarajućih strojeva uz što veće iskorištenje i što manji utrošak energije. Brašno će biti bolje kvalitete što je proces prerade jednostavniji i ekonomičniji, a kakvoća pšenice bolja. Mljevenjem ljuske se dobiju posije, a mljevenjem endosperma brašno (Kljusurić, 2000).

Budući da proces mljevenja nije tako jednostavan dio omotača, aleuronskog sloja i klice se usitni i ode u brašno, a dio završi u mekinjama. Efikasnost razdvajanja ovisi o meljivim karakteristikama pšenice, načinu vođenja tehnološkog procesa te pripremi za meljavu. Prije mljevenja pšenice potrebno ju je očistiti i kondicionirati zrno, pri čemu se odvajaju primjese. Zrna prolaze kroz razna sita s različitom veličinom i oblikom otvora, izdvajače kamena, čistilice, trijere, ribalice i magnete. Sam postupak se sastoji od krupljenja, rastvaranja krupice i okrajaka te izmeljavanja (Krička et al., 2012).

Brašno je po kemijskom sastavu nutritivno vrijedna namirnica bogata ugljikohidratima (65-75%), vitaminima, mineralima, biljnim proteinima, mastima. Pšenično brašno odličan je izvor ugljikohidrata, glavnog izvora energije u ljudskom organizmu. Pšenica je bogatija proteinima od kukuruza i riže. Proizvodi od brašna spadaju u niskomasne namirnice jer sadrži male količine masti. Svojstva brašna, kao i njegov sastav, ovise o načinu mljevenja i osobinama samljevene pšenice. Konzistancija tijesta, sposobnost vezivanja vode, boja brašna i intenzitet djelovanja enzima ovise o veličini čestica brašna. U pekarstvu se koristi brašno koje treba osigurati određenu kvalitetu gotovog proizvoda, uz čim veći prinos, ali i ekonomičnost prerade (Krička et. al., 2012).

Proteini su glavna komponenta za određivanje kakvoće brašna (Kljusurić, 2000). S obzirom na topljivost proteini se dijele u četiri skupine:

- albumini –proteini topljivi u vodi. Njihova topljivost ne zavisi o koncentraciji soli u otopini, koaguliraju na povišenoj temperaturi,
- globulini – proteini netopljivi u čistoj vodi i u koncentriranim otopinama soli, ali topljivi u razrijeđenim otopinama soli (10% NaCl),
- glijadini – proteini topljivi u 70 – 90% alkoholu (etanolu) i
- glutenini – proteini topljivi u razrijeđenim kiselinama i lužinama (Làszitity, 1996).

Najvažniji enzimi u brašnu su dijastaze, proteaze, lipaze, oksidaze i dr. Od vitamina najzastupljeniji su provitamin A, nikotinska kiselina, tiamin (B1), riboflavin (B2) i tokoferol (E) (Đaković, 1980). Enzimi su biokemijski katalizatori koji u vrlo malim količinama utječu na ubrzanje određenih biokemijskih procesa, a da se pri tome sami ne mijenjaju. Pšenica i pšenično brašno sadrže amilolitičke enzime koji sudjeluju u razgradnji škroba, proteolitičke koji sudjeluju u razgradnji proteina i enzim lipoksigenazu koji je aktivator oksidacije (Jelača, 1972).

2. METODE

2.1. Određivanje udjela vode u pšenici

Vlažnost pšenice varira ovisno od stupnja zrelosti, načinu sijetve, vlažnosti zraka u toku i poslije žetve. Pšenica pogodna za dobru preradu u mlinu ima 14-16% vode. Pšenica preko 18% vode smatra se manje vrijednom. Najjednostavnije i najbrže metode određivanja udjela vode u

pšenici su električne metode. Mjerenje traje 1-3 minute s točnošću 0,05-0,3% ovisno o vrsti aparata. U laboratoriju se koristi standardna metoda sušenja ili u vakuumu ili pod normalnim tlakom. Najtočnije rezultate daje sušenje u vakuumu. Udio vode u pšenice može biti pokazatelj profitabilnosti u mljevenju. Pšenica se kupuje po težini, brašno se prodaje po težini. Pšenica s niskim udjelom vode je pogodna za pohranu, prije prodaje joj se dodaje voda kako bi se postigla standardna razina vlage prije mljevenja. Što se doda više vode to je težina veća a s tim je i profitabilnost veća.

2.2. Određivanje udjela pepela u pšenici

Metoda određivanja udjela pepela u pšenici temelji se na spaljivanju uzorka pri 900 ± 20°C i vaganju dobivenog ostatka. Spaljivanjem uzroka sagorjevaju organske, a ostaju mineralne tvari (Kaluđerski i Filipović, 1998). Kada se uzorak spali u pećnici, visoka temperatura ukloni svu vlagu te sagori sav organski materijal (škrob, bjelančevine, ulje) ostavljajući samo pepeo. Pepeo se sastoji od anorganskih mineralnih oksida K, Mg, Na, S, Ca i P i njihov sadržaj u cjeloukupnom zrnu pšenice kreće se od 1,3 do 2,5%. Poznavanje udjela pepela u pšenici i brašnu je važno za mljevenje. Mlinari trebaju znati udio mineralnih tvari u pšenici kako bi se mogla postići željena ili određena razina pepela u brašnu. Količina pepela u brašnu određuje tip brašna. Što je tip brašna veći, brašno sadrži veću količinu mineralnih tvari, odnosno veću količinu pepela i tamnije je boje.

Količina pepela izražava se u postotcima mase prema suhoj tvari i izračunava prema ovoj formuli:

$$količina\ pepela\ (\%) = \frac{masa\ ostatka}{masa\ uzorka} \times 100 \qquad (2.1)$$

2.3. Određivanje udjela proteina (bjelančevina) u pšenici

Na osnovi udjela i kvalitete proteina može se sa zadovoljavajućom točnošću ocijeniti kvaliteta zrna. Količina proteina pšenice određuje se preko udjela dušika oslobođenog tijekom mineralizacije. Rezultat proteinskog sadržaja izražen je u postotku. Udio proteina je povezan s mnogim svojstvima prerade pšenice kao što je apsorpcija vode i čvrstoća glutena. Veći sadržaj

proteina zahtijeva više vode i dulje vrijeme miješanja kako bi se postiglo optimalna konzistencija tijesta. Tekstura i izgled gotovih proizvoda ovise o sadržaju proteina. Poželjan je nizak sadržaj bjelančevina za oštre i nježne proizvode kao što su kolači. Visoki sadržaj proteina poželjan je za proizvode kao što je kruh.

$$\% N = \frac{(a-b) \times N \times f \times 1{,}4007}{m\,(uzorka)} \tag{2.2}$$

gdje je:

a – volumen HCL utrošen za titraciju uzorka u ml
b – volumen HCL utrošen za titraciju slijepe probe u ml
N – molaritet kiseline
g – faktor kiseline
m – masa uzorka u g

$$\% \, bjelančevina = \%N \times F \tag{2.3}$$

Faktor (*F*) za preračunavanje dušika u bjelančevine je 5,7.

2.4. Određivanje sedimentacijske vrijedosti (po Zeleny-u)



Slika 1 Uređaj za određivanje sedimentacijske vrijednosti po Zeleny-u

Koristi se metoda po Zeleny-u (**Slika 1**). Metoda se temelji na sposobnosti proteina glutena da bubre pod utjecajem mliječne kiseline. Ovom metodom se određuje relativna snaga glutena pšeničnog brašna. Sedimentacijska vrijednost, odnosno sedimentacijski volumeni, ovisi o količini i kvaliteti proteina pšenice. Između sedimentacijske vrijednosti i jakosti glutena, kao i

volumena pekarskog proizvoda postoji pozitivna korelacija. Za pšenice s niskim udjelom proteina i sa slabim glutenom vrijednost sedimentacije je mala, a za pšenice s visokim udjelom proteina i jakim glutenom velika.

2.5. Određivanje mase 1000 zrna

Pod apsolutnom masom žitarica podrazumijeva se masa 1000 cijelih zrna žitarica izražena u gramima. Masa 1000 zrna pšenice varira u dosta širokim granicama, što ovisi o sorti pšenice, zemljištu, klimi, obradi i udjelu vode. Da bi dobili usporedne vrijednosti potrebno ih je preračunati na isti udjel vode ili na istu suhu tvar, jer masa 1000 zrna raste s povećanjem udjela vode. Mogućnost izbrašnjavanja povezana je s masom 1000 zrna, a kvaliteta brašna nije.

Masa 1000 zrna izračuna se po formuli:

$$M = \frac{m \times (100 - V)}{100} \tag{2.4}$$

gdje je:

M – masa suhe tvari 1000 zrna žita

m – masa 1000 zrna s prirodnom vlagom, u gramima

V – postotak vlage u zrnu žita.

2.6. Određivanje hektolitarske mase



Slika 2 Shopperova vaga

Pod hektolitarskom masom žitarica podrazumijeva se masa hektolitra žitarica u kg. Jedno od najstarijih mjerila za određivanje mlinarske kvalitete pšenice je hektolitarska masa. S većom hektolitarskom masom raste i količina brašna, koja se može dobiti mljevenjem, ali to nije pravilo. O sortnim svojstvima pšenice, kao i o klimatskim prilikama pojedine godine, masenom udjela vode u pšenici ovisi hektolitarska masa. Uslijed toga ona i kod iste sorte varira u dosta širokom rasponu. Ovisi o gustoći, vlažnosti, krupnoći i obliku zrna te količini i vrsti primjesa. Kod staklastih zrna je veća, kao i kod zrna srednjih i manjih veličina, tanke ljuske i nižeg udjela vlage. Prosječna vrijednost hektolitarske mase je 75,5 kg/hl. (Klauđerski i Filipović, 1998)

Hektolitarsku masu snižavaju: mekana brašnasta zrna, povišen udio vode, velika dugoljasta zrna, debela i hrapava ljuska. Hektolitarsku masu povećavaju: mala zrna i zrna osrednje veličine, kompaktna staklasta zrna, potpuno dozrela zrna, ovalna zrna glatke površine, nizak udio vode, tanka ljuska.

Naime, hl-masa nije jednaka stostrukoj masi jedne litre žita, već je nešto veća te se zbog toga koriste specijalne tablice, priložene uz svaku Schopper-ovu vagu i za svaku vrstu žita.

m = g (dobiveni na Schopper-ovoj vagi (**Slika 2**))

U slučaju pšenice hektolitarsku masu (HLM) možemo još preračunati na vlagu od 13% preko formule:

$$HML(kor) = HML\frac{(HML - 68) \times (13 - w)}{(30 - w)} \qquad (2.5)$$

gdje je:

w – udio vode.

2.7. Izbrašnjavanje

Uzorak pšenice se melje kako bi se ocijenilo iskorištenje pšenice. Rezultati laboratorijskog mljevenja se izražavaju kao masa pojedinih frakcija brašna, krupnih i sitnih posija. Zbroji se svih šest frakcija brašna, kao i sitne i krupne posije te izračuna izbrašnjavanje prema jednadžbi:

$$Izbrašnjavanje\ (\%) = \frac{laboratorijsko\ brašno\ (g)}{laboratorijsko\ brašno\ (g) + \ posije\ (g)} \times 100 \qquad (2.6)$$

Podaci izbrašnjavanja iz laboratorijskih ispitivanja pokazuju svojstva mljevenja na malim uzorcima pšenice, te podatke koriste veliki mlinovi kako bi prilagodili mlin i dobili što bolje iskorištenje pšenice. Dobiveno brašno se koristi za određivanja udjela pepela i protein.

2.8. Određivanje udjela vode u brašnu

Udio vode određuje se zagrijavanjem brašna u metalnim posudicama na 130°C i uspoređuje se masa uzorka prije i poslije grijanja. Razlika masa predstavlja udio vode. Rezultat udjela vode prikazuje se kao postotak. Utvrđivanje udjela vode bitan je prvi korak u analizi kvalitete brašna jer se taj podatak koristi za ostale analize. Poznavanje udjela vode bitno je za pohranu. Brašno s visokim sadržajem vlage, iznad 14,5% pogodno je za razvoj plijesni, bakterija i insekte. Brašno

Udio vode iskazuje se u postocima mase uzorka i izračunava se prema formuli:

$$Udio\ vode = \frac{(m0 - m1)}{m0} \times 100\ [\%] \tag{2.7}$$

mo – masa uzorka prije sušenja u gramima

m1 – masa uzorka nakon sušenja u gramima

2.9. Određivanje udjela vlažnog glutena

O kvaliteti vlažnog lijepka ovise najvažnije osobine tijesta kao što su: rastezljivost, sposobnost zadržavanja plina, elastičnost. Od brašna i otopine kuhinjske soli pripremi se tijesto iz kojeg se ispiranjem škroba dobiva vlažni lijepak. Netopljive bjelančevine imaju sposobnost da izgrađuju lijepak u vodi. Stoga su od primarnog značaja za ocjenu tehnološke kvalitete pšeničnog brašna. Što je količina bjelančevina u brašnu veća više lijepka može iz njega isprati. Vlažni lijepak formiraju bjelančevine gliadin i glutenin u određenom odnosu. Kao najpovoljniji odnos smatra se jedan dio glutenina prema tri dijela gliadina (Kaluđerski i Filipović, 1998).

$$\% = \frac{vlažni\ gluten \times 100}{10} \tag{2.8}$$

Udio suhog glutena se odredi tako da se 1g vlažnog glutena izvaže na papirić, suši u sušnici na 130°C cca 3-4 sata i izvaže.

$$\%\ suhog\ glutena = \frac{\%\ vlažnog\ glutena\ \times masa\ suhog\ glutena}{masa\ vlažnog\ glutena\ za\ analizu} \quad (2.9)$$

2.10. Određivanje reoloških svojstava farinografom



Slika 3 Farinograf

Farinograf (**Slika 3**) je uređaj kojim se određuju svojstva i ponašanje tijesta pri miješanju. Princip rada farinografa temelji se na mjerenju otpora koje pruža tijesto pri miješanju u vremenu od trenutka formiranja tijesta do punog razvoja i tijekom daljnjeg miješanja do zaustavljanja miješalice. Analiza traje 15 minuta i počinje zamjesom tijesta, za to vrijeme uređaj ispisuje graf (farinogram) analize tijesta. Do podataka se dolazi očitanjem farinograma. Podaci koje dobijemo su sposobnost upijanja, razvoj tijesta, stabilnost tijesta, otpor tijesta, stupanj omekšanja te elastičnosti i rastezljivosti tijesta, te se izračunavanjem površine koju zatvara farinografska krivulja te konzinstencija od 500 FJ može odrediti kvalitetni broj i kvalitetna skupina (Hosenay, 1994, Kaluđerski i Filipović, 1998).

Moć upijanja vode je količina vode iskazana u postocima, koja je potrebna za postizanje konzistencije tijesta od 500 FJ.

$$moć\ upijanja\ vode\ (\%) = \frac{V}{3} \quad (2.10)$$

gdje je V – broj milimetara vode za konzistenciju tijesta 500 FJ načinjenog od 300g.

- Razvoj tijesta, u minutama, je vrijeme u minutama koje protekne od početka miješanja do postizanja maksimum krivulje.

- Stabilnost tijesta, u minutama, je vrijeme od maksimuma krivulje do njezina padanja za 10 FJ.
- Rezistencija, u minutama, je zbroj razvoja tijesta i stabilnosti tijesta.
- Stupanj omekšanja tijesta, u FJ, je odstupanje krajnje točke srednje linije farinografa od linije konzistencije.

Kvalitetni broj, na dobivenom farinogramu planimetrira se površina trokuta što je zatvaraju: linija središnjica, koja se ucrtava u krivulju počevši od njezina maksimuma do završetka farinogramu 15 minuta, linija konzistencije postignuta u rasponu od 490 FJ do 510 FJ i okomica koja spaja liniju središnjicu sa linijom konzistencije. Za utvrđenu površinu trokuta, izraženu u cm2 , u tablici po Hankoczyu pročita se kvalitetni broj brašna a tom broju odgovara određena grupa kvalitete (A1, A2, B1, B2, C1, C2).

2.11. Određivanje reoloških svojstava ekstenzografom



Slika 4 Ekstenzograf

Ekstenzograf (**Slika 4**) je uređaj koji mjeri otpor kojeg pruža tijesto tijekom razvlačenja do kidanja. Otpor koji tijesto pruža djelovanjem sile zabilježi se na ekstenzogramu. Tijesto se prethodno zamjesi na farinografu 5 minuta. Oblikuje se i stavlja u kalupe pa ostavlja na odmaranju 45 minuta. Nakon 45 minuta se provodi mjerenje (razvlačenje komada tijesta pomoću kuke ekstezografa do pucanja). Zatim se tijesto odmara još 45 minuta i ponovi se postupak. Iz grafa se očitavaju slijedeće vrijednost: otpor, maksimalni otpor, energija, rastezljivost, te se iz očitanih vrijednosti izračunava odnos otpor/rastezljivost i odnos maksimalan otpor/rastezljivost (Hosenay, 1994, Kaluđerski i Filipović, 1998).

Prikaz rezultata:

- Energija (E), je srednja vrijednost površine što je formira krivulja opisana 135 min nakon zamjesivanja. Određuje se planimetriranjem i iskazuje se u centimetrima kvadratnim, zaokruženo na cijeli broj.
- Rastezljivost (R), je srednja udaljenost što je prijeđe dijagramski papir od početka rastezanja do trenutka kada se tijesto prekine. Registrira se na krivulji opisanoj 135 min nakon zamjesivanja. Iskazuje se u milimetrima.
- Otpor predstavlja visinu krivulje na 5 cm od početka krivulje, izražava se u ekstenziografskim jedinicama (E).
- Maksimalni otpor (0 max) jest srednja vrijednost maksimalne visine krivulja opisanih 135 minuta nakon zamjesivanja, zaokružena na 5 EJ. Iskazuje se u ekstenzografskim jedinicama.
- Omjer (O/R), odnos otpornosti rastezanja prema rastezljivost, jest neimenovani broj i predstavlja količnik brojčane vrijednosti otpornosti na petom centimetru rastezanja i brojčane vrijednosti rastezljivosti.

2.12. Određivanje amilografom



Slika 5 Amilograf

Amilograf (Slika 5) je rotacijski viskozimetar. Metoda se temelji na kontinuiranom praćenju viskoziteta suspenzije voda – brašno, zagrijavanjem uz stalni porast temperature do 96°C. Iz grafa koji uređaj oblikuje tijekom mjerenja može se pratiti tijek želatinizacije, ali najvažniji podatak koji se očitava je maksimalna viskoznost izražena amilolitičkim jedinicama (AJ) (Đaković, 1997, Kaluđerski i Filipović, 1998).

Početak bubrenja izračunava se prema ovoj formuli i izražava u °C:

$$tpk = 25 + m1 \times 1{,}5 \tag{2.11}$$

m1 – vrijeme, u minutama, koje protekne od trenutka uključivanja grijača do registriranja porasta viskoziteta.

Temperatura maksimuma izračunava se prema ovoj formuli i iskazuje u °C:

$$tzk = 25 + m2 \times 1{,}5 \tag{2.12}$$

m2 – vrijeme, u minutama, koje protekne od trenutka uključivanja grijača do trenutka kad krivulja dosegne maksimum.

Vrijeme tvorbe ljepila izražava se u minutama. Maksimalna viskoznost jest visina sredine krivulje u maksimumu i izražava se u amilografskim jedinicama (Aj).

2.13. Određivanje „broja padanja“



Slika 6 Uređaj za određivanje FN po Hagberg-Pertenu

Metoda se temelji na kontinuiranom praćenju viskoziteta suspenzije voda-brašno, zagrijavanjem na temperaturu od 100 °C. Porastom temperature, mehaničkim djelovanjem poput mućkanja i amilolitičkim djelovanjem α-amilaze dolazi do porasta viskoziteta koji prati klajsterizaciju škroba (Kaluđerski i Filipović, 1998).

Visoki broj padanja (iznad 300 sekundi) označava minimalnu aktivnost enzima i kvalitetu brašna. Nizak broj padanja (ispod 250 sekundi) ukazuje na značajnu aktivnost enzima. Razina enzimske aktivnosti utječe na kvalitetu proizvoda. Na primjer, kvasac u krušnom tijestu zahtijeva da se šećeri razviju na odgovarajući način i zato trebaju određenu razinu enzimske aktivnosti u tijestu. Previše enzimske aktivnosti znači da postoji previše šećera i premalo škroba koji je odgovoran za teksturu kruha. Prevelika aktivnost rezultira ljepljivim tijestom tijekom prerade i slabom teksturom u gotovom proizvodu.

Aktivnost a-amilaze određuje se na temelju broja padanja. Određeno je da sve:

- ispod 150 sekundi je visoka aktivnost α-amilaze
- od 200 – 250 sekundi je srednja
- više od 300 sekundi je niska aktivnost α-amilaze

3. MULTIVARIJANTNA ANALIZA PODATAKA (engl. *Multivariate analysis*)

Jedno od temeljnih znanstvenih istraživanja je načelo o međusobnoj povezanosti pojava, u utvrđivanjem povezanosti moguće je predvidjeti promjene zbivanja u pojavama koje su s prvom povezane. U literaturi se može naći obilje modela za analizu prirodnih situacija. To su u pravilu multivarijatne analize podataka (MVA).

Analitičke postupke kojima analiziramo više varijabli istovremeno nazivamo multivarijantnim ili multidimenzionalnim analitičkim postupcima (metodama, tehnikama). MVA grana je statistike koja se bavi analizom višestrukih izmjera većeg broja varijabli na jednom ili više uzoraka jedinki. Primjenjuje se u svim situacijama gdje se u istraživanjima promatra velik broj varijabli koje su u međusobnim odnosima, te gdje se zahtijeva utvrđivanje osnovnih odnosa među podacima. (Mathias, 2007).

Da bi se što točnije utvrdile veze između raznih pojava, kao i prirodu takvih veza, danas se sve više pristupa poboljšanim tehnikama i stvaranju novih tehnika multivarijatne analize. Podaci dobiveni mjerenjem promjena na pojavama koje se promatraju nazivaju se varijable. Međusobna povezanost između varijabli izražava s nekim od brojnih indikatora kao stupanj takve povezanosti. Takvi indikatori zovu se koeficijenti korelacije. Utvrđivanjem koeficijenata korelacije između promatranih varijabli utvrđujemo stupanj međusobne povezanosti između promatranim pojavama (Einax i sur., 1997). Postoje brojni statistički načini obrade podataka, kao i brojni statistički programski jezici za obradu tih istih podataka.

Metode MVA možemo kategorizirati na slijedeći način (Cooley and Lohnes, 1973):

- Analize **zavisnosti** varijabli - metode koje pretpostavljaju postojanje **jednog** skupa varijabli, a odnose se na probleme proučavanja strukture tog skupa varijabli odnosno entiteta koji su opisani tim varijablama (npr. regresija, *t*-test, višestruka regresija, ANOVA, MANOVA, …)
- Analize **međuzavisnosti** varijabli - metode koje pretpostavljaju postojanje **najmanje dvaju** skupova varijabli, a odnose se na probleme proučavanja povezanosti i razlika među tim skupovima varijabli (npr. jednostavna korelacija, analiza glavnih komponenata, faktorska analiza, dvosmjerna tablica kontigencije, loglinearni modeli, višesmjerna tablica kontigencije, analiza korespodencije)

- Metode za analizu **promjena** nekog skupa varijabli ili entiteta (npr. vremenske serije)

Najčešće korištene metode MVA su faktorska analiza i analiza glavnih komponenti. Koraci u ovim analizama uključuju odabir i mjerenje skupa varijabli, pripremu korelacijske matrice (za izvođenje bilo faktorske, bilo analize glavnih komponenti), ekstrakciju skupa faktora iz korelacijske matrice, određivanje broja faktora, rotiranje faktora kako bi se povećala interpretabilnost te, konačno, interpretacija rezultata. Iako se pri svakom od ovih koraka u obzir uzimaju važni statistički uvjeti, važan test analize također je njena interpretabilnost.

Razlike između te dvije analize su:

1. Faktorska analiza zahtjeva početne pretpostavke, a druga ne.
2. Faktorska je orijentirana prema maksimizaciji korelacije između polaznih varijabli, dok Analiza glavnih komponenata maksimizira njihovu varijancu.
3. Faktorska razlaže varijancu na zajedničku i specifičnu, dok druga metoda koristi ukupnu varijancu.
4. U Faktorskoj su polazne varijable prikazane pomoću faktora, dok u drugom slučaju su glavne komponente prikazani pomoću polaznih.

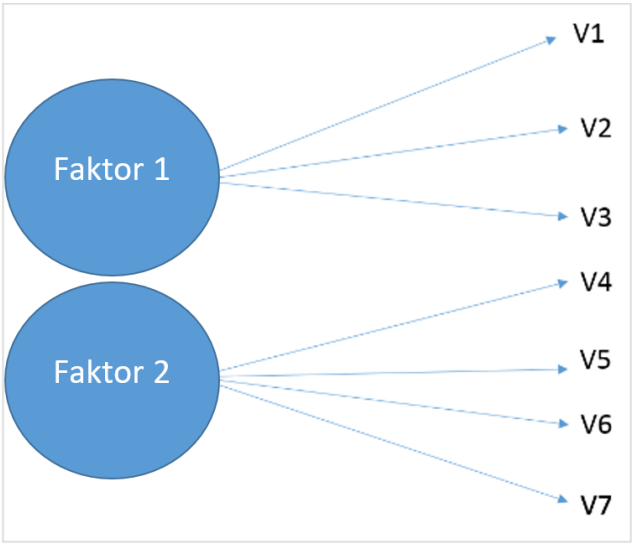
3.1. Faktorska analiza (engl. *Factor analysis*)

Faktorska analiza (FA) je temelj multivarijatnih metoda kojoj je glavna primjena u znanosti postizanje zakona štednje (engl. *law of parsimony*) odnosno da se što veći broj varijabli objasniti pomoću što manjeg broja varijabli. Ubraja se među najpoznatije tehnike za analizu varijabli koje imaju veliku međuzavisnost. Njezin osnivač je Charles Spearman, a razvila se u psihologiji početkom 20. stoljeća. Za povezanost statistike i FA najzaslužniji je Pearson. Značajan povijesni iskorak za FA su sedamdesete godine 20. stoljeća, kada razvoj računala omogućuje primjenu analize na mnogo varijabli i na velikim uzorcima.

Cilj FA je veliku količinu informacija svesti na manji broj faktora (**Slika 7**), te tako poboljšati razumijevanje između varijabli uz minimalan gubitak informacija. Ovdje se ne radi o uzročno-posljedičnoj povezanosti, već o paralelnim pomacima u jednoj i drugoj promatranoj varijabli. Konačan produkt faktorske analize su faktori koji su linearne kombinacije početnih varijabli, te

se nazivaju latentnim (prikrivenim) varijablama jer ih tek treba otkriti ovom analizom. Faktori se mogu smatrati uzorkom početnih varijabli jer oni daju objašnjenje za povezanost pojava koje ispituju početne varijable. Prema tome, faktori otkrivaju potencijalne uzorke povezanosti pojava.

Prije postupka FA potrebno je: definirati problem, utvrditi koje i koliko varijabli će se analizirati, utvrditi metrička svojstva, odabrati veličinu uzorka, te ispitati prikladnost podataka za analizu. Važno je ne odabrati prevelik broj varijabli koje će ispitivati samo jednu ideju. Općenito se uzima da omjer varijabli i veličina uzorka budu barem 1:5, a poželjno je 1:10. Podaci su dobri za analizu ako su koeficijenti korelacije barem 0.30 ili manji od -0.30. Ako je taj koeficijent pozitivan, to pokazuje koliki je doprinos određene varijable faktoru, a obrnuto ako je koeficijent negativan. Nakon nabrojanih postupaka slijedi izlučivanje i interpretacija izlučenih faktora, te ako je potrebno rotacija i ponovna interpretacija faktora.



Slika 7 Faktorska analiza podataka

U faktorskoj analizi varijable su prikazane kao linearna kombinacija faktora:

$$\begin{aligned} X_1 - \mu_1 &= l_{11}F_1 + l_{12}F_2 + \cdots l_{1m}F_m + e_1 \\ X_2 - \mu_2 &= l_{21}F_1 + l_{22}F_2 + \cdots l_{2m}F_m + e_2 \\ &\vdots \\ X_p - \mu_p &= l_{p1}F_1 + l_{p2}F_2 + \cdots l_{pm}F_m + e_p \end{aligned} \tag{3.1}$$

ili matrično zapisano:

$$X - \mu = LF + e \tag{3.2}$$

gdje su

$F_j, j = 1, \dots, m$ zajednički faktori,

X_i polazne varijable,

$e_i, i = 1, \dots, p$ specifični faktori,

l_{ij} koeficijenti korelacije između X_i i F_j ili faktorska opterećenja,

μ_i očekivanje.

Broj faktora je manji od broja varijabli (*m* < *p*).

Pretpostavke modela su:

$$E(F) = 0$$

$$E(e) = 0$$

$$cov(F) = I$$

$$Cov(e) = \Psi = \mathrm{diag}(\psi_1, \dots, \psi_p)$$

$$Cov(e, F) = 0$$

Ovakav model se naziva ortogonalni faktorski model s ***m*** zajedničkih faktora, gdje su ***e*** i ***F*** hipotetski slučajni vektori. Zajednički faktori su međusobno ortogonalni i nekorelirani. Specifični faktori su također nekorelirani. Nema povezanosti između zajedničkih i specifičnih faktora.

Korištenjem danih pretpostavki dobivamo matricu varijanci i kovarijanci za matricu ***X*** (jed. 3.3)

$$\Sigma = cov(X) = E(X - \mu)(X - \mu)' = LL' + \Psi$$

$$\sigma_{ii} = Var(X_i) = l_{i1}^2 + l_{i2}^2 + \cdots + l_{im}^2 + \psi_i$$

$$Cov(X_i, X_k) = l_{i1}l_{k1} + l_{i2}l_{k2} + \cdots + l_{im}l_{km} \tag{3.3}$$

$$Cov(X, F) = L$$

$$Cov(X_i, F_j) = l_{ij}$$

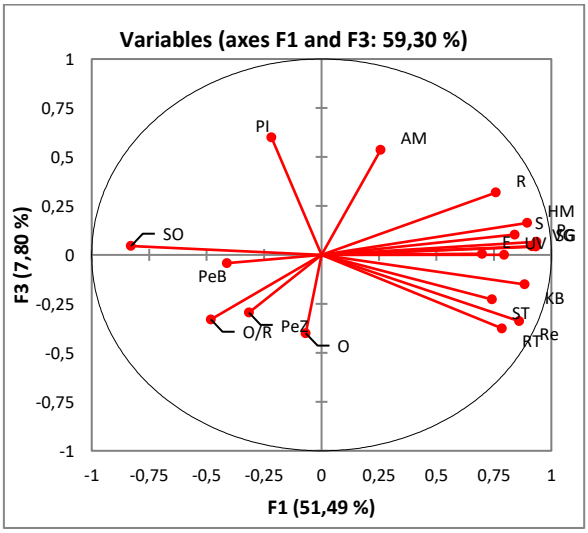
Suma kvadrata faktorskih opterećenja naziva se komunlitet. Zbog linearnosti modela varijanca je rastavljena na zajedničku i specifičnu varijancu. Specifična je doprinos ukupnoj varijanci od

svake pojedine varijable, a zajednička je rezultat veze sa drugim varijablama. Dvije su osnovne metode za rotaciju faktora: ortogonalan i kosokutna rotacija, čija je svrha pojednostavniti interpretaciju faktora.

3.2. Analiza glavnih komponenata (engl. *Principal Component Analysis*)

Analiza glavnih komponenata (PCA) je najjednostavnija metoda multivarijantne statistike koja se u literaturi naziva još i Karhunen-Loèveom ekspanzijom te Karhunen-Loèveom transformacijom. Ovu tehniku prvi je opisao Karl Pearson 1901. godine primjenjujući ju na svega dvije ili tri varijable, vjerujući da ju je moguće primijeniti za rješavanje kompleksnijeg problema s više od dvije ispitivane varijable. Daljnje razvijanje ove metode nastavio je Hotelling, te je 1933. godine dao opis njenog načina izračunavanja. Razvoj informatičkih tehnologija i računala omogućio je brojnim znanstvenicima primjenu ove metode u svojim istraživanjima, olakšavajući dugotrajan i kompliciran postupak izračuna, te je ova metoda razvojem računala dobila i široku primjenu u brojnim granama znanosti.

PCA analiza predstavlja jednu od najjednostavnijih tehnika MVA podataka. Primjenjuje se u slučajevima opsežnog broja varijabli. PCA definiramo kao statistički postupak za reduciranje dimenzije podataka. PCA koristimo za smanjenje dimenzionalnosti podatkovnog skupa, uz zadržavanje onih karakteristika podataka koje najviše doprinose varijanci (Kim, 2002). Prikaz izdvojenih glavnih komponenti dan je na **Slici 8.**



Slika 8 Analiza glavnih komponenti – geometrijski prikaz glavnih komponenti F1 i F3

Osnovni ciljevi PCA su redukcija podataka te njihova interpretacija:

- Redukcija dimenzionalnosti podataka podrazumijeva smanjenje broja izvornih varijabli na mali broj indeksa koji su linearna kombinacija izvornih varijabli i koji se zovu glavne komponente
- U interpretaciji podataka glavne komponente objašnjavaju varijabilnost podataka na najkoncizniji način, na taj način pokazuje neke skrivene povezanosti, međuodnose podataka.

Može se reći da je PCA je svojevrsna transformacija podataka na način da bira novi koordinatni sustav za skup podataka, takav da najveća varijanca bilo koje projekcije skupa podataka leži na prvoj osi (prva glavna komponenta), druga najveća varijanca na drugoj osi itd. Podaci se prikazuju na način koji nije uobičajen, ali sadrži mnogo bitnih informacija o skupu izvornih podataka. U interpretaciji novo dobivenih varijabli (glavne komponente) služimo se matricom strukture čiji su elementi linearne korelacije originalnih varijabli i novo dobivenih varijabli ili faktora.

Da bi se reducirao broj varijabli potrebno je pronaći kriterij za zadržavanje onih varijabli koje nose najveći dio informacija sadržanih u polaznom sustavu varijabli.

Postoji niz kriterija a neki od njih su:

- *Kaiserov kriterij* prema kojemu se uzimaju samo one glavne komponente kojima odgovaraju svojstvene vrijednosti veće od 1;
- uzimaju se samo one glavne komponente kojima odgovaraju svojstvene vrijednosti *veće od prosjeka* svih svojstvenih vrijednosti;
- uzimaju se samo one glavne komponente koje nose (svaka posebno) *unaprijed zadani dio informacija*;
- uzimaju se samo one glavne komponente koje nose odnosno zadržavaju (*ukupno* kao sustav) unaprijed zadani dio informacija;
- broj komponenata se određuje proizvoljno.

Glavne komponente se računaju rješavanjem složenog sustava linearnih jednadžbi (jed. 3.4). Pomoću vektora izračunavaju se glavne komponente. Normalan položaj vektora je vertikalan, odnosno kao kolona brojeva. Množenje reda vektora s kolonom vektora predstavlja produkt

vektora koji kao rezultat daje jedan broj. Elementi vektora koeficijenti su glavnih komponenata.

Algebarski, glavne komponente su linearne kombinacije *p* slučajnih varijabli (jed. 3.4).

$$\begin{aligned} F_1 &= a_{11}X_1 + a_{12}X_2 + \cdots a_{1p}X_p \\ F_2 &= a_{21}X_1 + a_{22}X_2 + \cdots a_{2p}X_p \\ &\vdots \\ F_p &= a_{p1}X_1 + a_{p2}X_2 + \cdots a_{pp}X_p \end{aligned} \tag{3.4}$$

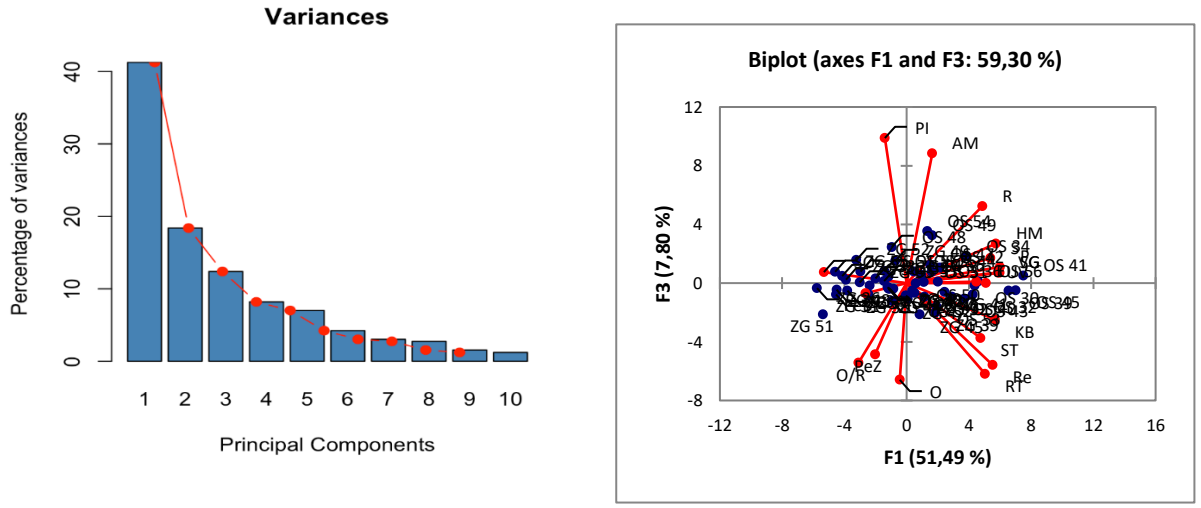
gdje su

X promatrane varijable,

F glavne komponente,

a su težinski koeficijenti

Sustav jednadžbi može se prikazati i riješiti kao produkt matrice i vektora. Ulazni podaci za analizu glavnih komponenata čine ***p*** varijabli i ***n*** opažaja (individua) i imaju oblik matrice ***p*** x ***n***. Geometrijski su te linearne kombinacije koordinatne osi novog koordinatnog sustava dobivenog rotacijom oko starog s glavnim komponentama kao koordinatnim osima (**Slika 9b)**. (Jednačak i sur., 2013)



a) Prikaz svojstvenih vrijednosti i proporcije objašnjene varijance

b) Biplot glavnih komponenata F1 i F3

Slika 9 Geometrijski prikaz rješenje PCA metodom

Pri donošenju odluke o broju glavnih komponenata koje treba zadržati pomoć pruža *scree*- dijagram (**Slika 9a**). To je dijagram koji dužinama povezuje točke u ravnini, čija je apscisa jednaka rednom broju svojstvene vrijednosti, a ordinata njenoj veličini.

S obzirom da su svojstvene vrijednosti poredane u padajući niz, dobivena izlomljena linija je padajuća. Smatra se da je broj glavnih komponenata koje ostaju određen točkom na pregibu iza koje su svojstvene vrijednosti male i koje se značajno ne razlikuju.

Analiza glavnih komponenata se izvodi u sljedećim koracima:

1. Provodi se standardizacija originalnih podataka

2. Izračunava se matrica kovarijanci ***C***

3. Izračunavaju se **svojstvene vrijednosti** (Eigenvalue), $\lambda_1, \lambda_2, \lambda_3, \ldots + \lambda_p$, te odgovarajući **svojstveni vektori** (Eigenvector), $a_1, a_2, a_3, \ldots, a_p$.

4. **Eliminacija komponenata** modela koje sadrže mali udio varijacija podataka (npr. u slučaju da se prvim dvjema komponentama objašnjava 95% ukupne varijance, tada se sve ostale eliminiraju, a prve dvije komponente postaju glavne komponente promatranog sustava).

Tablica 1 Ulazni podatci u analizi PCA

Redni. br.	$\boldsymbol{X_1}$	$\boldsymbol{X_2}$	$\boldsymbol{X_3}$	$\cdots$	$\boldsymbol{X_p}$
1	x_{11}	x_{12}	x_{13}	$\cdots$	x_{1p}
2	x_{21}	x_{22}	x_{23}	$\cdots$	x_{2p}
3	x_{31}	x_{32}	x_{33}	$\cdots$	x_{3p}
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\cdots$	$\vdots$
n	x_{n1}	x_{n2}	x_{n3}	$\cdots$	x_{np}

Cilj metode PCA je analiza matrice početnih varijabli prikazane **Tablicom 1**. Analiza započinje s podacima o ***p*** varijabli za ***n*** broja mjerenja (opažaja) pomoću ***k*** glavnih komponenata (***k*** < ***p***), bez gubitka informacija o sustavu.

Prva glavna komponenta ***F*** je linearna kombinacija originalnih varijabli (X_1, X_2, …, X_p):

$$F_1 = a_{11}X_1 + a_{12}X_2 + \cdots + a_{1p}X_p \tag{3.5}$$

Koje međusobno variraju što je više moguće, pod uvjetom da je zadovoljen slijedeći uvjet:

$$a_{11}^2 + a_{12}^2 + \cdots + a_{1p}^2 = 1 \tag{3.6}$$

Zbog postavljenog uvjeta varijanca prve izvedene varijable $Var(F_1)$, je maksimalna.

Druga glavna komponenta, F_2, izračunava se na slijedeći način:

$$F_2 = a_{21}X_1 + a_{22}X_2 + \cdots + a_{2p}X_p \tag{3.7}$$

Također, varijanca druge glavne komponente $Var(F_2)$, ima maksimalnu vrijednost jer je definiran slijedeći uvjet:

$$a_{21}^2 + a_{22}^2 + \cdots + a_{2p}^2 = 1 \tag{3.8}$$

Ako postoji *p* varijabli u promatranom sustava, tada će postojati i *p* glavnih komponenti. Analiza PCA podrazumijeva pronalaženje svojstvenih vrijednosti matrice kovarijanci uzoraka.

Suma varijanci svih izvornih varijabli je ukupna varijanca. Dio ukupne varijance objašnjen jednom glavnom komponentom naziva se svojstvena vrijednost ili latentni korijen. Svojstvena vrijednost najveća je u prvoj komponenti i u svakoj sljedećoj njena vrijednost je manja. Suma svih svojstvenih vrijednosti jednaka je ukupnoj varijanci. Ako je veliki dio varijance (80-90%) protumačen jednom, dvije ili tri glavne komponente, tada te komponente mogu zamijeniti početnih *p* varijabli bez većeg gubitka informacija.

Svojstvene vrijednosti, λ_i, (Eigenvalues, latentne vrijednosti) su varijance glavnih komponenata matrice ***C*** pri čemu postoji *p* svojstvenih vrijednosti od kojih su neke nula. Svojstvene vrijednosti ne mogu biti negativne u matrici kovarijanci.

$$\lambda_i = Var(F_i) \tag{3.9}$$

Važno svojstvo svojstvenih vrijednosti je da je njihov zbroj jednak zbroju elemenata na dijagonali ***C*** :

$$\lambda_1 + \lambda_2 + \lambda_3 + \cdots + \lambda_i = c_{11} + c_{22} + c_{33} + \cdots + c_{pp} \tag{3.10}$$

Matrica kovarijanci simetrična je i ima oblik:

$$C = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1p} \\ c_{21} & c_{22} & \cdots & c_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ c_{p1} & c_{p2} & \cdots & c_{pp} \end{bmatrix} \tag{3.11}$$

U matrici dijagonalni elementi c_{ij} predstavljaju varijancu originalne varijable X_i, dok ostali elementi van dijagonale predstavljaju kovarijance originalnih varijabli X_i i X_j.

Kako se ne bi dogodila situacija u kojoj neka od ulaznih varijabli ima prejak utjecaj na glavne komponente, provodi se postupak standardizacije vrijednosti ulaznih varijabli (kodiranje) i to tako da aritmetička sredina varijabli ima vrijednost nula, a varijancu jednaku jedinici. Nakon postupka standardizacije ulaznih varijabli, matrica ***C*** tada ima oblik:

$$C = \begin{bmatrix} 1 & c_{12} & \cdots & c_{1p} \\ c_{21} & 1 & \cdots & c_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ c_{p1} & c_{p2} & \cdots & 1 \end{bmatrix} \tag{3.12}$$

U ovoj matrici vrijedi $c_{ij} = c_{ji}$, odnosno analiza PCA je provedena na korelacijskoj matrici. U tom slučaju suma dijagonalnih elemenata i time suma svojstvenih vektora (Eigenvector), jednaka je broju ulaznih varijabli p.

Osnovnu za interpretaciju glavnih komponenata čine svojstveni vektor. Njihove vrijednosti su u prvoj glavnoj komponenti relativno ravnomjerno raspoređene po svim izvornim varijablama, a u drugoj glavnoj komponenti dolazi do njihove veće disproporcije. To omogućava izdvajanje izvorne varijable (ili tek nekoliko njih) i pomaže u objašnjavanju i sažimanju ukupne varijabilnosti.

3.3. Višestruka regresija (engl. *Multiple Regression*)

Višestruka regresija (VR) statistička je metoda za analizu povezanosti kvantitativnih varijabli i to: između jedne zavisne i više nezavisnih varijabli. Može se opisati modelom:

$$y = f(x_1, x_2, x_3, \dots, x_i, \dots, x_k) + \varepsilon \tag{3.13}$$

gdje je

y zavisna varijabla
x nezavisna varijabla
ε odstupanje od funkcionalnog odnosa

3.4. Klaster analiza (engl. *Cluster analysis*)

Klaster analiza je grupa multivarijantnih tehnika čiji je primarni cilj klasificiranje ili klasteriranje opažaja u skupine, grupe ili klastere (Pecina, 2006). Multivarijantnost označava svojstvo klaster analize da više varijabli analizira istovremeno i zajedno kao dio jedne cjeline. Najčešće su objekti predmet klaster, a ne varijable kao što je to slučaj kod faktorske analize. Osobine objekata se definiraju pomoću varijabli koje samim time ulaze u proces klaster analize. Klaster analiza varijable ne procjenjuje empirijski, već koristi one varijable koje su zadane od strane samog istraživača (Devčić, 2012).

Klaster analiza je vrsta multivarijantne statističke analize koja spada u metode klasificiranja. Temelji se na matematički formuliranim mjerama sličnosti i obuhvaća različite postupke, algoritme i metode grupiranja podataka. Osnovni problem s kojim se istraživači susreću u praksi je na koji način najprije organizirati sakupljene podatke, a zatim koji algoritam najbolje upotrijebiti. Klaster analiza spada u istraživačke analize čiji je osnovni cilj sortirati različite podatke u grupe na način da se maksimizira stupanj sličnosti unutar grupe uz uvjet da je sličnost s drugim grupama minimalna.

Matrica podataka može se zapisati u obliku:

$$Y = y_1', y_2', y_3', \dots, y_n' = y(1), y(2), y(3), \dots, y(p) \tag{3.14}$$

3.5. Regresijska analiza metodom najmanjih kvadrata (engl. *Partial least squares method*)

Regresijska analiza metodom najmanjih kvadrata (PLS) je metoda zasnovana na višestrukoj regresiji i analizi glavnih komponenata. To je zapravo proširenje višestruke regresije jer u svom najjednostavnijem obliku linearni model određuje (linearni) odnos između zavisne varijable *Y* i skupa varijabli prediktora – *X*. Može se koristiti na multikolinearnim podacima, može uključivati veliki skup nezavisnih varijabli, a osim toga nekoliko zavisnih varijabli može se modelirati istovremeno (Piggot, 1986). Najdjelotvornija je kod predviđanja. Cilj korištenja ove metode je predviđanje budućih vrijednosti zavisne varijable kao reakcije na promjene vrijednosti nekoliko nezavisnih varijabli.

Varijanca i standardna devijacija spadaju u grupu mjera raspršenosti podataka. One karakteriziraju raspršenost podataka oko aritmetičke sredine.

Varijanca niza izmjerenih vrijednosti $x_1,x_2,...,x_n$ varijable X definirana je izrazom:

$$\bar{S}_n^2 = \frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x}_n)^2$$

gdje je: $\bar{S}_n^2$ varijanca, $\sum_{i=1}^{n}(xi - \bar{x}_n)^2$ suma svih kvadrata razlike podataka i srednje vrijednosti.

Standardna devijacija je kvadratni korijen varijance, tj.

$$\bar{S}_n\sqrt{\bar{S}_n^2} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x}_n)^2}$$

gdje je: $\bar{S}_n$ standardna devijacija.

Koeficijent varijabilnosti izračunava se kao udio standardne devijacije u srednjoj vrijednosti

$$\frac{\bar{S}_n}{x_n} x100\ [\%]$$

i objašnjava koliko je odstupanje minimalne i maksimalne vrijednosti u skupu podataka od srednje vrijednosti (Benšić i Šuvak, 2013).

3. EKSPERIMENTALNI DIO

3.1. ZADATAK

U radu je analizirano 27 sorti ozime pšenice roda 2017. godine, zasijanih na dvije različite lokacije. Kvaliteta pšenice analizirana je mjerenjem fizikalno-kemijskih, te reoloških svojstava zrna i brašna uzoraka ozime pšenice zasijane na lokacijama osječkog i zagrebačkog područja. Provedena je analiza podataka primjenom kemometrijske metode glavnih komponenata (PCA).

3.2. MATERIJALI

U radu su analizirana 54 uzorka ozime pšenice roda 2017. godine (27 sorti zasijanih na dvije različite lokacije: osječko i zagrebačko područje).

3.3. METODE

3.3.1. Određivanje kvalitete uzoraka pšenice

3.3.1.1. Fizička svojstva zrna

Hektolitarska masa i masa 1000 zrna određena je prema metodi ISO 7971-2

3.3.1.2. Kemijsko–tehnološka svojstva zrna i brašna

- **Udio vode** u uzorcima pšenice određen je prema metodi HRN ISO 712
- Udio mineralnih tvari (**pepela**) određen je prema metodi HRN ISO 2171-2
- Udio **proteina** određen je prema metodi ISO 20483, sedimentacijska vrijednost i razred kakvoće određeni su metodom ISO 5529
- Ukupno **izbrašnjavanje** i udio mineralnih tvari (pepela) u brašnu određen je prema metodi AACC, Meth. 26-10/A, 26-21A, 26-31
- Količina **vlažnog glutena** određena je metodom ISO 5531

3.3.1.3. Reološki pokazatelji kvalitete

- Rezultati reoloških ispitivanja farinogramom određeni su metodom ICC standard 115/1
- Rezultati reoloških ispitivanja ekstenzogramom (90') određeni su metodom ICC standard 114/1
- Rezultati reoloških ispitivanja amilogramom te broj padanja metodom određeni su metodom ICC standard 126/1 i ICC standard 107/1

3.3.2. Analiza obrada podataka primjenom metode glavnih komponenata

3.3.2.1. Osnovna statistička analiza pokazatelja kvalitete pšenice

Na osnovu provedenih mjerenja fizikalno-kemijskih, te reoloških pokazatelja kvalitete ozime pšenice najprije je provedena je osnovna statistička analiza pokazatelja kvalitete pšenice.

Procjena i modeliranje pokazatelja kvalitete ozime pšenice provedena je na temelju skupa podataka koji obuhvaća 18 parametara kvalitete 27 sorti ozime pšenice određenih u uzorcima prikupljenim sa dvije lokacije.

Prije provođenja PCA analize, preliminarno je izrađena matrica podataka koje je uključivala grupiranje i transformiranje podataka, svi podaci su normalizirani kako bi se eliminirao utjecaj različitih mjernih jedinca za pojedine parametre. Određene varijable uklonjeni su iz daljnje analize, obzirom da su njihove vrijednosti slabo korelirale s ostalim promatranim varijablama.

Baza podataka za daljnju analizu uključivala je slijedeće varijable: PeZ (udio pepela u zrnu), P (količina proteina), S (sedimentacijska vrijednost), AM (masa 1000 zrna), HM (hektolitarska masa žita), PI (izbrašnjavanje bez otresivača), PeB (pepeo u brašnu), VG (vlažni gluten), SG (suhi gluten), UV (upijanje vode), RT (razvoj tijesta), ST (stablinost), Re (rezistencija), SO (stupanj omekšanja), KB (kvalitetni broj), E (energija), R (rastezljivost), O (otpor), O/R (omjer otpora i rastezljivosti).

Za opis pouzdanosti dobivenih rezultata poslužila je prethodno određena razina signifikantnosti rezultata, *p*. Odabrana razina signifikantnosti u svim provedenim statističkim analizama jest $p \leq 0,05$, što se inače smatra graničnom vrijednošću za pouzdanost rezultata. To zapravo znači da postoji 5% vjerojatnosti pogreške da je nađeni odnos između varijabli uistinu takav i u stvarnom sustavu.

Na podacima je izvršena PCA analiza kako bi se utvrdilo je li moguće promatrane ulazne varijable prikazati pomoću što manje glavnih komponenti. Pri odabiru relevantnih varijabli za daljnju analizu PCA metodom poslužila je korelacijska matrica pokazatelja kvalitete ozime pšenice po pojedinim lokacijama. Pearson-ov koeficijent korelacije je korišten kako bi se ispitala korelacija između pojedinih varijabli. Odabrana razina signifikantnosti u svim provedenim statističkim analizama jest $p \leq 0,05$.

Za provedbu svih analiza korištena je računalna podrška programa MS Excel te ugrađenog dodatka XLStat (ver. 2014.5.03), te program Statistica (ver 13.1).

4. REZULTATI I RASPRAVA

4.1. Rezultati mjerenja fizikalno-kemijskih i reoloških analiza brašna i tijesta

Tablica 2 Utjecaj lokacije na kvalitetu ozime pšenice roda 2017. godine

		Lokacija OSIJEK	Lokacija Zagreb	t-test*
		Sr. vr. ± SD	Sr. vr. ± SD	*p*
PŠENICA	Udio vode (%)	10,1 ± 0,2	9,9 ± 0,2	**0,0255**
	Suha tvar (%)	89,9 ± 0,2	90,1 ± 0,2	**0,0255**
	Udio pepela (% na ST)	1,64 ± 0,0	1,74 ± 0,1	**< 0,0001**
	Udio proteina (% na ST)	12,8 ± 1,0	11,1 ± 0,8	**< 0,0001**
	Sedimentacijska vrijednost (cm^3 na 14% vlage)	32,8 ± 9,7	24,0 ± 6,2	**0,0003**
	Masa 1000 zrna (g na ST)	37,5 ± 3,0	33,8 ± 2,9	**< 0,0001**
	Hektolitarska masa žita (kg/hl)	80,0 ± 1,8	76,5 ± 2,2	**< 0,0001**
	Hektolitarska masa žita (kg/hl na 14% vlage)	77,6 ± 1,5	74,8 ± 1,8	**< 0,0001**
	Izbrašnjavanje bez otresivača (%)	70,6 ± 2,1	70,2 ± 2,7	0,4822
BRAŠNO	Udio vode (%)	13,1 ± 0,6	12,7 ± 0,4	**0,0104**
	Udio pepela (% na ST)	0,45 ± 0,0	0,47 ± 0,0	**< 0,0001**
	Udio vlažnog glutena (% na 14% vlage)	24,6 ± 3,7	18,8 ± 3,5	**< 0,0001**
	Udio suhog glutena (%)	8,9 ± 1,4	6,7 ± 1,4	**< 0,0001**

*podebljane vrijednosti ukazuju na statistički značajnu razliku u svojstvima sorti u odnosu na različitu lokaciju prema t-testu razlike (p<0,05)

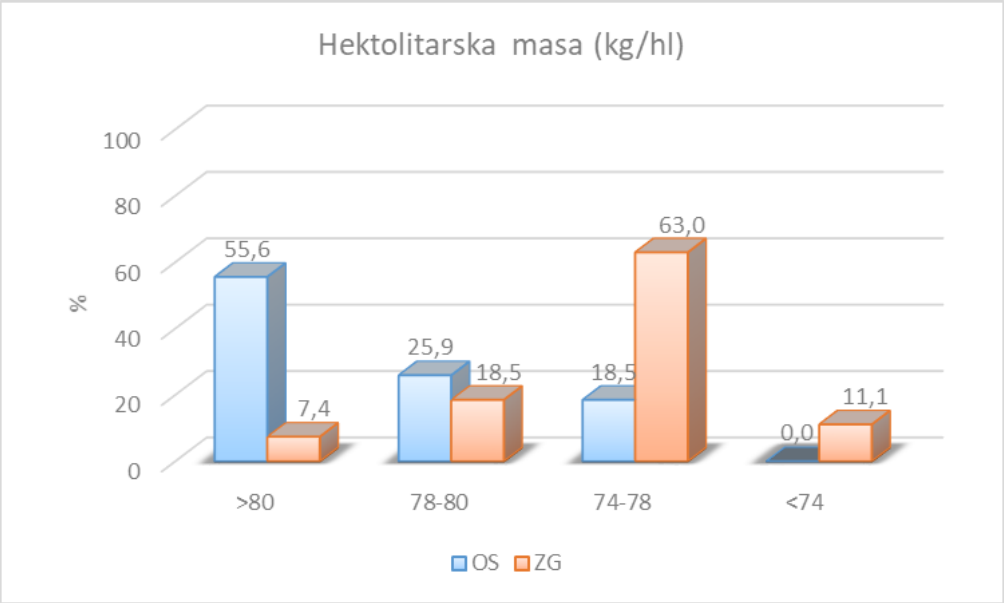
Tablica 3 Utjecaj lokacije na reološka svojstva ozime pšenice roda 2017. godine

		Lokacija OSIJEK	Lokacija Zagreb	t-test*
		Sr. vr. ± SD	Sr. vr. ± SD	*p*
FARINOGRAM	Upijanje vode (%)	60,9 ± 3,3	58,8 ± 2,6	**0,0162**
	Razvoj tijesta (min)	1,5 ± 0,3	1,2 ± 0,2	**0,0025**
	Stabilnost (min)	0,8 ± 0,3	0,6 ± 0,2	**0,0082**
	Rezistencija (min)	2,2 ± 0,5	1,8 ± 0,3	**0,0009**
	Stupanj omekšanja (FJ)	99,8 ± 22,7	129,3 ± 18,6	**< 0,0001**
	Kvalitetni broj	45,5 ± 8,3	36,5 ± 6,1	**< 0,0001**
EKSTENZOGRAM (45')	Energija (cm^2)	72,5 ± 18,0	54,8 ± 15,7	**0,0004**
	Rastezljivost (mm)	123,2 ± 15,4	109,8 ± 14,1	**0,0019**
	Otpor (EJ)	362,4 ± 89,3	339,6 ± 66,2	0,3008
	Maksimalni otpor (EJ)	450,2 ± 96,6	388,0 ± 79,4	**0,0142**
	Omjer (EJ/mm)	3,0 ± 0,9	3,2 ± 0,8	0,6430
EKSTENZOGRAM (90')	Energija (cm^2)	90,5 ± 24,4	69,1 ± 21,5	**0,0015**
	Rastezljivost (mm)	112,3 ± 16,9	100,3 ± 14,2	**0,0078**
	Otpor (EJ)	511,9 ± 130,5	483,1 ± 106,1	0,3882
	Maksimalni otpor (EJ)	621,9 ± 151,7	538,9 ± 124,9	**0,0360**
	Omjer (EJ/mm)	4,7 ± 1,6	4,9 ± 1,4	0,5916
AMILOGRAM	Početak bubrenja (°C)	59,8 ± 3,0	61,6 ± 2,7	**0,0326**
	Temperatura maks. (°C)	88,5 ± 6,5	89,5 ± 5,9	0,5601
	Vrijeme tvorbe ljepila (min)	19,2 ± 3,1	18,6 ± 3,2	0,5553
	Maksimalna viskoznost (AJ)	1702,4 ± 547,9	1765,9 ± 671,8	0,7102
FN	Broj padanja (s)	359,5 ± 66,5	340,6 ± 56,6	0,2764

* podebljane vrijednosti ukazuju na statistički značajnu razliku u svojstvima sorti u odnosu na različitu lokaciju prema t-testu razlike (p<0,05)

Fizička svojstva zrna

Hektolitarska masa: Prosječna hektolitarska masa sorti s osječke lokacije (80,0 ± 1,8 kg/hl) bila je značajno veća od hektolitarske mase sorti s zagrebačkog područja (76,5 ± 2,2 kg/hl). Na osječkoj lokaciji 15 sorti (55,6%) imalo je hektolitarsku masu veću od 80 kg/hl, za razliku od samo 2 sorte (7,4%) sa zagrebačke lokacije koje su većinom (63%) imale hektolitarsku masu od 74 - 78 kg/hl (**Slika 10**). Najveću hektolitarsku masu na obje lokacije imala je sorta br. 45 (OS 45 - 83,00 kg/hl; ZG 45 - 80,50 kg/hl), najnižu na osječkoj lokaciji sorta OS 38 (76,02 kg/hl), a na zagrebačkoj sorta ZG 48 (72,70 kg/hl).



Slika 10 Vrijednosti hektolitarske mase ispitivanih uzoraka pšenice

Masa 1000 zrna: Razlike u masi 1000 zrna za sorte zasijane na dvije lokacije bile su statistički značajne (**Tablica 2**). Masa 1000 zrna za sorte s osječke lokacije iznosila je u prosjeku 37,5 ± 3,0 g, a sa zagrebačke 33,8 ± 2,9 g. Najveću masu 1000 zrna na obje lokacije imala je sorta br. 56 (OS 56 - 42,9 g; ZG 56 - 39,6 g), a najnižu sorta br. 38 (OS 38 - 29,5 g; ZG 38 - 28,4 g).

Kemijsko–tehnološka svojstva zrna i brašna

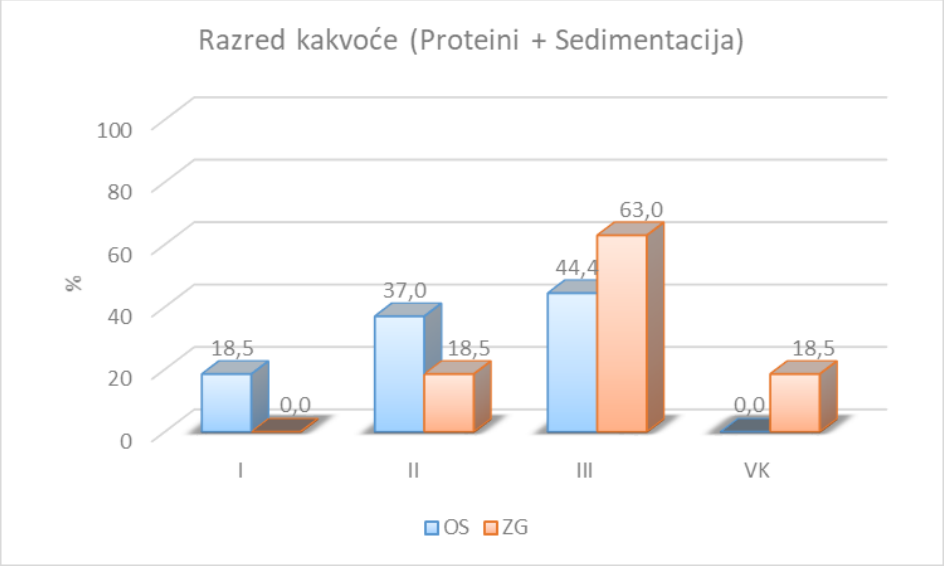
Udio vode: Udio vode u sortama zasijanim na osječkoj lokaciji iznosio je u prosjeku 10,1 ± 0,2%. Najnižu vrijednost imala je sorta OS 44 (9,6%), a najvišu sorta OS 33 (10,41%).

Udio vode za sorte sa zagrebačke lokacije iznosio je u prosjeku 9,9 ± 0,2%, a kretao se od 9,52% (ZG 51) do 10,28% (ZG 55). Razlike u udjelu vode između dvije lokacije bile su statistički značajne (**Tablica 2**).

Udio mineralnih tvari (pepela): Udio pepela u sortama na lokaciji Osijek kretao se od 1,55% za OS 31, do 1,75% za sortu OS 41, a u prosjeku je iznosio 1,64 ± 0,05%. Za sorte na zagrebačkoj lokaciji prosjek je bio značajno veći i iznosio je 1,74 ± 0,1%, a udio pepela kretao se od 1,60% za ZG 50, do 1,87% za sortu ZG 41 (**Tablica 2**).

Udio proteina, sedimentacijska vrijednost i razred kakvoće: Udio proteina na lokaciji Osijek iznosio je u prosjeku 12,8 ± 1,0%, dok je na zagrebačkoj lokaciji bio značajno manji, 11,1 ± 0,8% (**Tablica 2**). Na osječkoj lokaciji najveći udio proteina imala je sorta OS 41 (14,5%), a najmanji OS 33 (11,1%). Na zagrebačkom području najveći udio proteina je također imala sorta br. 41 (12,5%), a najmanji ZG 46 (9,8%).

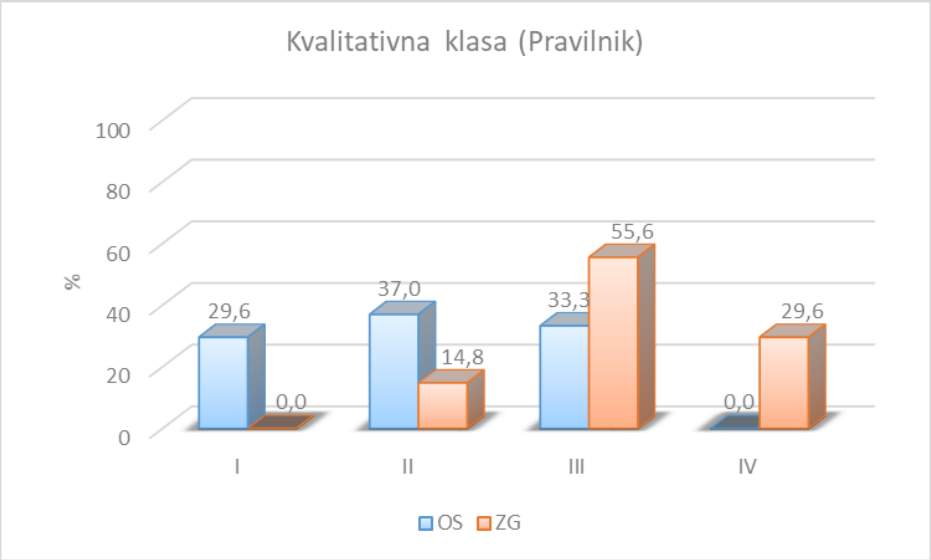
Sedimentacijska vrijednost na lokaciji Osijek iznosila je u prosjeku 32,8 ± 9,7 cm^3 što je značajno veće od prosječne vrijednosti na lokaciji Zagreb (24,0 ± 6,2 cm^3) (**Tablica 2**).



Slika 11 Raspodjela ispitivanih uzoraka pšenice prema udjelu proteina i sedimentacijskoj vrijednosti

Na osnovi razvrstavanja u razrede kakvoće prema udjelu proteina i sedimentacijskoj vrijednosti po Zeleny-u na osječkoj lokaciji 5 sorti (18,5%) svrstano je u prvu klasu, 10 sorti (37,0%) u drugu te 12 sorti (44,4%) u treću klasu (**Slika 11**). Na zagrebačkoj lokaciji niti jedna

sorta nije svrstana u prvu klasu, 5 sorti (18,5%) svrstano je u drugu klasu, 17 sorti (63,0%) u treću, a 5 sorti (18,5%) kategorizirano je kao sorte izvan klase (**Slika 12**).

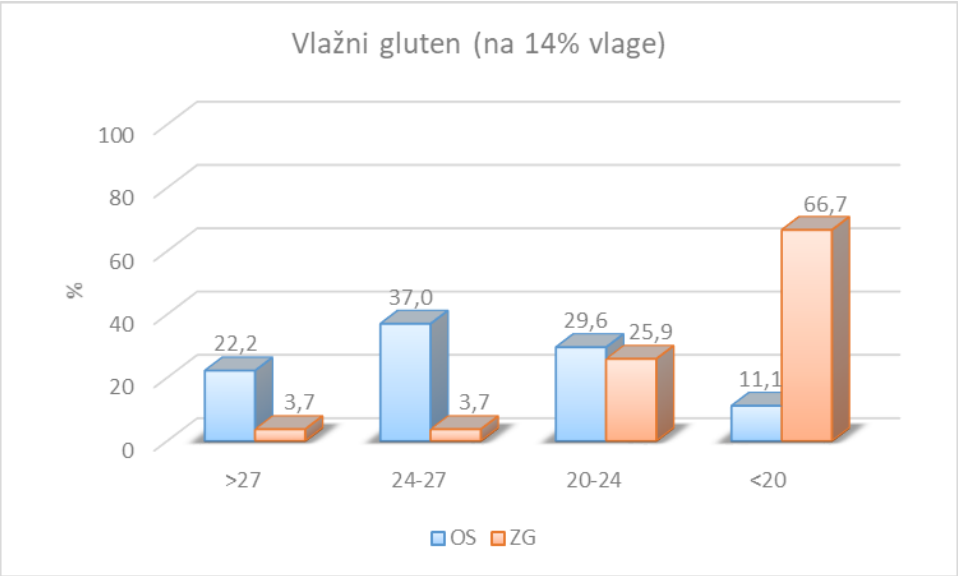


Slika 12 Raspodjela ispitivanih uzoraka pšenice prema razredima kakvoće

Na osnovi razvrstavanja u kvalitativne klase prema Pravilniku o parametrima kvalitete i kvalitativnim klasama pšenice u otkupu pšenice roda 2017. godine (NN 64/2017), odnosno prema udjelu proteina i hektolitarskoj masi, na osječkoj lokaciji 8 sorti (29,6%) svrstano je u prvu klasu, 10 sorti (37,0%) u drugu te 9 sorti (33,3%) u treću klasu. Na zagrebačkoj lokaciji niti jedna sorta nije svrstana u prvu klasu, 4 sorte (14,8%) svrstano je u drugu klasu, 15 sorti (55,6%) u treću, a 8 sorti (29,6%) u četvrtu klasu.

Ukupno izbrašnjavanje i udio mineralnih tvari (pepela) u brašnu: Prosječno izbrašnjavanje na osječkoj lokaciji bilo je 70,6 ± 2,1% i nije se statistički značajno razlikovalo od izbrašnjavanja prilikom mljevenja sorti pšenice sa zagrebačkoig područja (70,2 ± 2,7%) (**Tablica 2**). Prosječne vrijednosti udjela pepela na osječkoj lokaciji iznosile su 0,45 ± 0,02%, a na zagrebačkom području 0,47 ± 0,02%.

Količina vlažnog glutena: Za sorte s osječke lokacije količina vlažnog glutena iznosila je u prosjeku 24,6 ± 3,7% dok je na zagrebačkoj lokaciji prosjek bio značajno manji (18,8 ± 3,5%) (**Slika 13**).



Slika 13 Vrijednosti vlažnog glutena ispitivanih uzoraka pšenice

Na osječkoj lokaciji 6 sorti (22,2%) imalo je vrlo dobru količinu vlažnog glutena (>27%), 10 sorti (37,0%) dobru (24-27%), 8 sorti (29,6%) zadovoljavajuću te 3 sorte (11,1%) malu količinu glutena (<20%). Na zagrebačkoj lokaciji po jedna sorta je imala vrlo dobru i dobru, 7 sorti zadovoljavajuću, a 18 (66,7%) malu količinu glutena.

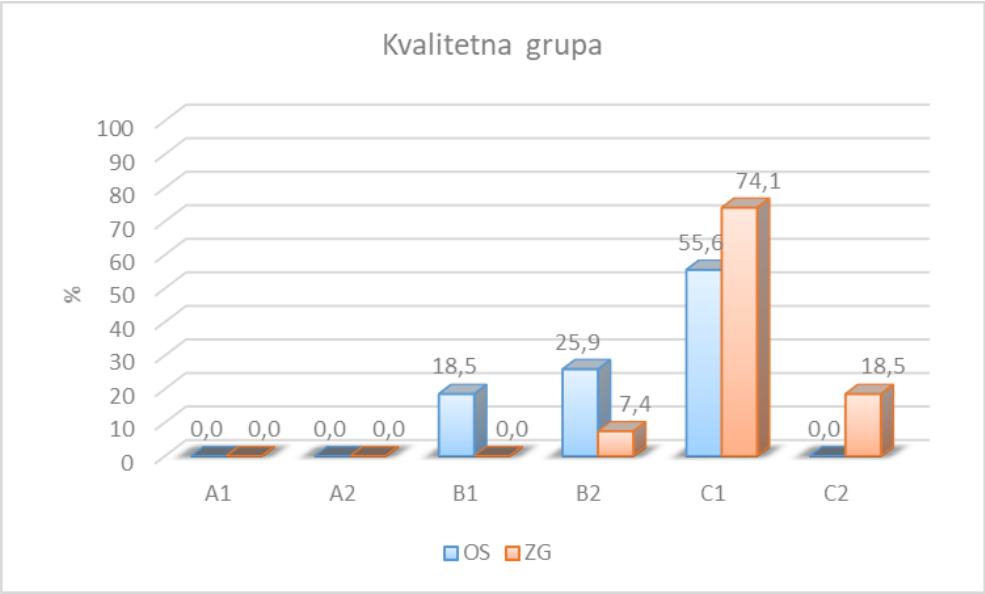
Količina suhog glutena: Količina suhog glutena iznosila je u prosjeku 8,9 ± 1,4% na lokaciji Osijek, dok je prosjek na zagrebačkoj lokaciji bio značajno manji (6,7 ± 1,4%) (**Tablica 2**).

Reološki pokazatelji kvalitete

Farinogram: Ukupno su sorte sa osječke lokacije imale značajno bolje farinografske pokazatelje kakvoće od sorti sa zagrebačkog područja (**Tablica 3**). Srednja vrijednost za upijanje vode za sorte s osječke lokacije iznosila je 60,9 ± 3,3%, a za sorte s lokacije Zagreb 58,8 ± 2,6%.

Prosječne vrijednosti stupnja omekšanja sorti sa zagrebačkog područja (129,3 ± 18,6 FJ) bile su značajno veće od vrijednosti s Osječke lokacije (99,8 ± 22,7 FJ) (**Tablica 3**).

Prosječni kvalitetni broj brašna sorti s osječkog područja (45,5 ± 8,3) bio je značajno veći od prosječnog kvalitetnog broja određeno za sorte na lokaciji Zagreb (36,5 ± 6,1) (**Slika 14**).



Slika 14 Raspodjela ispitivanih sorti pšenice na kvalitetne grupe

Prema farinografskim pokazateljima niti jedna sorta nije kategorizirana kao A1 i A2 kvalitetna grupa. Na osječkoj lokaciji 5 sorti (18,5%) svrstano je u B1 grupu, 7 sorti (25,9%) i 15 (55,6%) u C1 grupu.

2 sorte (7,4%) sa zagrebačkog područja svrstane su u B2 grupu, 20 sorti u C1 grupu te 5 (18,5%) u najslabiju C2 grupu.

Ekstenzogram (90'): Sorte s osječke lokacije prosječno su imale značajno veće vrijednosti za energiju (90,5 ± 24,4 cm^2) i rastezljivost (112,3 ± 16,9 mm) u odnosu na sorte s lokacije Zagreb (69,1 ± 21,5 cm^2 i 100,3 ± 14,2 mm). Vrijednosti $otpora_{50\ mm}$ prosječno su bile nešto veće na lokaciji Osijek (511,9 ± 130,5 EJ) nego na zagrebačkom području (483,1 ± 106,1 EJ), ali nije utvrđena statistički značajna razlika. Zbog velikog otpora u odnosu na rastezljivost rezultirale su i velikim omjerom O/R, 4,7 ± 1,6 za sorte s osječkog i 4,9 ± 1,4 sa zagrebačkog područja (**Tablica 3**).

Amilogram i broj padanja: Prosječno nije bilo značajne razlike između sorti s obje lokacije u pogledu broja padanja i većine amilografskih pokazatelja (**Tablica 3**).

4.2. Obrada rezultata fizikalno-kemijskih i reoloških analiza brašna i tijesta primjenom metode PCA

Koraci u analizi glavnih komponenata bili su slijedeći:

- ✓ **standardizirati** promatrane varijable (tako da im je prosjek 0, a varijanca 1) kako bi sve bile na jednakoj razini u analizi,
- ✓ izračunati **matrice korelacija** između svih izvornih standardiziranih varijabli,
- ✓ pronaći **svojstvene vrijednosti** glavnih komponenata,
- ✓ **odbaciti** one komponente koje su nositelji proporcionalno malog udjela varijance

Tablica 4 Deskriptivna statistika pokazatelja kvalitete 27 sorti ozime pšenice na dvije lokacije: Osijek i Zagreb

Varijable	*N*	Minimum	Maksimum	Mod	Standardna devijacija
P	54	9,800	14,600	11,948	1,239
S	54	14,000	55,000	28,417	9,323
HM	54	71,630	83,000	78,233	2,694
VG	54	10,837	33,582	21,699	4,624
SG	54	3,600	11,800	7,783	1,768
UV	54	52,500	65,800	59,826	3,177
RT	54	0,400	1,900	1,333	0,306
ST	54	0,300	1,300	0,663	0,252
Re	54	0,900	3,200	1,998	0,481
SO	54	50,000	155,000	114,537	25,684
KB	54	27,200	65,200	41,007	8,606
E	54	17,000	130,000	79,778	25,618
R	54	77,000	152,000	106,296	16,894
O	54	140,000	800,000	497,500	120,908
O/R	54	1,430	8,250	4,823	1,502

N – veličina uzorka (broj opažaja)

Vrijednosti u **Tablici 4** pokazuju rezultate provedene deskriptivne statistike nad 54 mjerena opažaja 15 varijabli fizikalno-kemijskih, te reoloških pokazatelja kvalitete ozime pšenice. Prema dobivenim vrijednostima vidljivo je da su najveće vrijednosti standardne devijacije zabilježene kod mjerenja reološkog pokazatelja Otpora (120,908).

Tablica 5 Pearson-ova korelacijska matrica pokazatelja kvalitete ozime pšenice

Varijable	PeZ	P	S	AM	HM	PI	PeB	VG	SG	UV	RT	ST	Re	SO	KB	E	R	O	O/R
PeZ	**1**	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P	-0,320	**1**	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
S	-0,224	**0,760**	**1**	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
AM	-0,425	0,264	0,260	**1**	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HM	-0,452	**0,848**	**0,729**	0,405	**1**	-	-	-	-	-	-	-	-	-	-	-	-	-	-
PI	-0,192	-0,164	-0,096	0,093	-0,176	**1**	-	-	-	-	-	-	-	-	-	-	-	-	-
PeB	0,501	-0,365	-0,319	-0,467	-0,394	0,088	**1**	-	-	-	-	-	-	-	-	-	-	-	-
VG	-0,264	**0,901**	**0,686**	0,186	**0,808**	-0,173	-0,326	**1**		-	-	-	-	-	-	-	-	-	-
SG	-0,290	**0,910**	**0,770**	0,208	**0,823**	-0,186	-0,356	**0,971**	**1**		-	-	-	-	-	-	-	-	-
UV	-0,090	**0,747**	**0,639**	0,157	**0,775**	-0,258	-0,250	**0,745**	**0,722**	**1**	-	-	-	-	-	-	-	-	-
RT	-0,119	**0,721**	0,536	0,048	**0,644**	-0,259	-0,286	**0,717**	**0,692**	**0,661**	**1**	-	-	-	-	-	-	-	-
ST	-0,112	**0,631**	0,503	0,042	0,572	-0,255	-0,247	**0,673**	**0,643**	0,525	0,598	**1**	-	-	-	-	-	-	-
Re	-0,162	**0,768**	**0,602**	0,055	**0,696**	-0,281	-0,309	**0,776**	**0,748**	**0,678**	**0,919**	**0,843**	**1**	-	-	-	-	-	-
SO	0,375	**-0,730**	**-0,768**	-0,169	**-0,691**	0,080	0,396	**-0,678**	**-0,750**	-0,499	**-0,600**	-0,542	**-0,653**	**1**	-	-	-	-	-
KB	-0,274	**0,815**	**0,670**	0,099	**0,734**	-0,211	-0,396	**0,794**	**0,802**	**0,677**	**0,746**	**0,665**	**0,786**	**-0,877**	**1**	-	-	-	-
E	-0,317	**0,603**	**0,855**	0,265	**0,626**	-0,081	-0,271	0,506	**0,607**	0,386	0,440	0,412	0,501	**-0,735**	0,523	**1**	-	-	-
R	-0,091	**0,682**	**0,792**	0,199	**0,668**	-0,085	-0,110	**0,636**	**0,685**	0,555	0,401	0,533	0,514	**-0,609**	0,546	**0,684**	**1**	-	-
O	-0,336	-0,097	0,114	0,105	-0,046	-0,032	-0,281	-0,204	-0,106	-0,243	0,025	-0,118	-0,028	-0,142	-0,061	0,401	-0,257	**1**	-
O/R	-0,236	-0,469	-0,304	0,071	-0,393	0,057	-0,165	-0,540	-0,460	-0,526	-0,296	-0,449	-0,389	0,200	-0,383	-0,025	**-0,671**	**0,837**	**1**

Tablica 6 Pearson-ova korelacijska matrica pokazatelja kvalitete ozime pšenice na različitim lokacijama nakon selekcije varijabli koje su pokazale visoku korelaciju

Varijabla	P	S	HM	VG	SG	UV	RT	ST	Re	SO	KB	E	R	O	O/R
P	**1**	-	-	-	-	-	-	-	-	-	-	-	-	-	-
S	**0,803**	**1**	-	-	-	-	-	-	-	-	-	-	-	-	-
HM	**0,815**	**0,721**	**1**	-	-	-	-	-	-	-	-	-	-	-	-
VG	**0,890**	**0,724**	**0,766**	**1**	-	-	-	-	-	-	-	-	-	-	-
SG	**0,896**	**0,814**	**0,783**	**0,962**	**1**	-	-	-	-	-	-	-	-	-	-
UV	**0,737**	**0,662**	**0,764**	**0,747**	**0,721**	**1**	-	-	-	-	-	-	-	-	-
RT	**0,606**	0,484	0,565	**0,627**	**0,601**	0,544	**1**	-	-	-	-	-	-	-	-
ST	**0,671**	**0,674**	**0,606**	**0,660**	**0,661**	0,551	0,496	**1**	-	-	-	-	-	-	-
Re	**0,733**	**0,657**	**0,670**	**0,740**	**0,724**	**0,631**	**0,891**	**0,835**	**1**	-	-	-	-	-	-
SO	**-0,763**	**-0,734**	**-0,689**	**-0,674**	**-0,751**	-0,510	-0,525	**-0,605**	**-0,644**	**1**	-	-	-	-	-
KB	**0,823**	**0,688**	**0,735**	**0,780**	**0,788**	**0,645**	**0,640**	**0,670**	**0,752**	**-0,896**	**1**	-	-	-	-
E	0,531	**0,785**	0,540	0,388	0,546	0,293	0,293	0,445	0,415	**-0,707**	0,482	**1**	-	-	-
R	**0,744**	**0,838**	**0,654**	**0,702**	**0,767**	0,582	0,363	**0,681**	0,584	**-0,611**	0,564	**0,659**	**1**	-	-
O	-0,152	0,108	-0,020	-0,298	-0,133	-0,289	-0,086	-0,155	-0,137	-0,198	-0,055	0,587	-0,181	**1**	-
O/R	-0,472	-0,281	-0,328	-0,576	-0,472	-0,517	-0,250	-0,435	-0,386	0,138	-0,316	0,163	**-0,601**	**0,881**	**1**

Nakon provedene standardizacije ulaznih varijabli, napravljena je korelacijska matrica svih pokazatelja kvalitete promatranih sorti ozime pšenice (**Tablica 5**). Prema dobivenim vrijednostima korelacije među varijablama, određene varijable odbačene su iz daljine analize (**Tablica 6** prikazuje varijable koje su uzete u nastavku analize). Varijable koje su imale vrijednosti manje od 0,6 izostavljene su iz daljnje analize (PeZ, AM, PI i PeB)

U **Tablici 6** prikazane su vrijednosti korelacijske matrice iz kojih je vidljiva dobra korelacija među promatranim varijablama (visoke vrijednosti korelacija). Negativna vrijednosti korelacija u najvećem broju zabilježene su kod varijable Stupnja omekšanja (SO), dok je u ostalim promatranim slučajevima korelacija među varijablama bila pozitivna.

4.2.1. Procjena broja glavnih komponenti

Broj glavnih komponenti koji se uzimaju u nastavku PCA analize procijenjena ja dvjema tehnikama ekstrakcije: prema Kasier-Gutmanovom pravilu (**Tablica 7**) te prema Cattellovom *scree* - testu (**Slika 15**). Da bi glavna komponenta bila značajna, treba imati varijancu koja je približno jednaka varijanci pojedine početne varijable.

Tablica 7 Matrica kovarijanci za standardizirane vrijednost (korelacijska matrica)

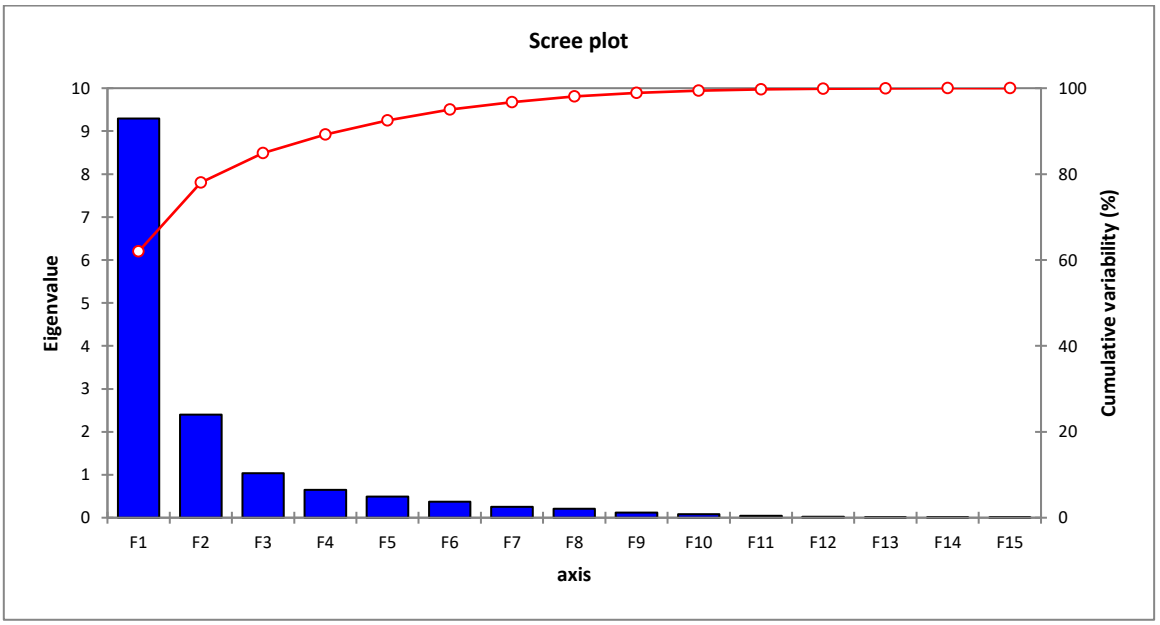
Glavna komponenta	Svojstvena vrijednost	Ukupna varijanca %	Kumulativna vrijednost varijance %
F1	**9,297**	**61,977**	**61,977**
F2	**2,403**	**16,023**	**78,001**
F3	**1,038**	**6,919**	**84,919**
F4	0,650	4,330	89,250
F5	0,490	3,269	92,519
F6	0,374	2,494	95,013
F7	0,256	1,710	96,722
F8	0,208	1,388	98,110
F9	0,116	0,776	98,887
F10	0,080	0,533	99,419
F11	0,043	0,284	99,703
F12	0,026	0,171	99,874
F13	0,011	0,076	99,951
F14	0,007	0,047	99,997
F15	0,000	0,003	100,000

U **Tablici 7** prikazane su vrijednosti svih glavnih komponenti te njihov doprinos u ukupnoj varijanci. Prema Kasier-Gutmanovom pravilu napravljena se selekcija glavnih komponenti koje će biti uključene u daljnjoj analizi. Prema ovom pravilu glavne komponente (*F*) koje imaju vrijednost veću od 1 zadržavaju se u analizi.

Prema vrijednostima iz **Tablice 7** vidljivo je da su zadržane tri glavne komponente (F1, F2 i F3). Dakle, analizirane pokazatelje kvalitete pšenice moguće je opisati pomoću samo tri glavne komponete. Može se vidjeti da je prvom komponentom objašnjeno 61,98% varijance, drugom komponentom 16,02% varijance te trećom komponentom 6,92% varijance.

Slika 15 prikazuje *scree* test za procjenu broja glavnih komponenti koje će se zadržati u analizi. Cattellov *scree*-test je grafička metoda gdje je posljednja značajna glavna komponenta ona nakon koje dolazi do naglog smanjenja u opadanju svojstvenih vrijednosti (F). Iz slike je vidljivo kako su glavne komponente silaznim rasporedom složene duž apscise prema padajućim vrijednostima udjela u ukupnoj varijanci. Odnosno, svojstvene vrijednosti s najvećim

doprinosom u ukupnoj varijanci imaju najmanji broj (F1). Iz grafičkog prikaza svojstvenih vrijednosti (vrijednosti veće od 1) vidljivo je da se u nastavku analize treba zadržati tri glavne komponente: F1, F2 i F3.



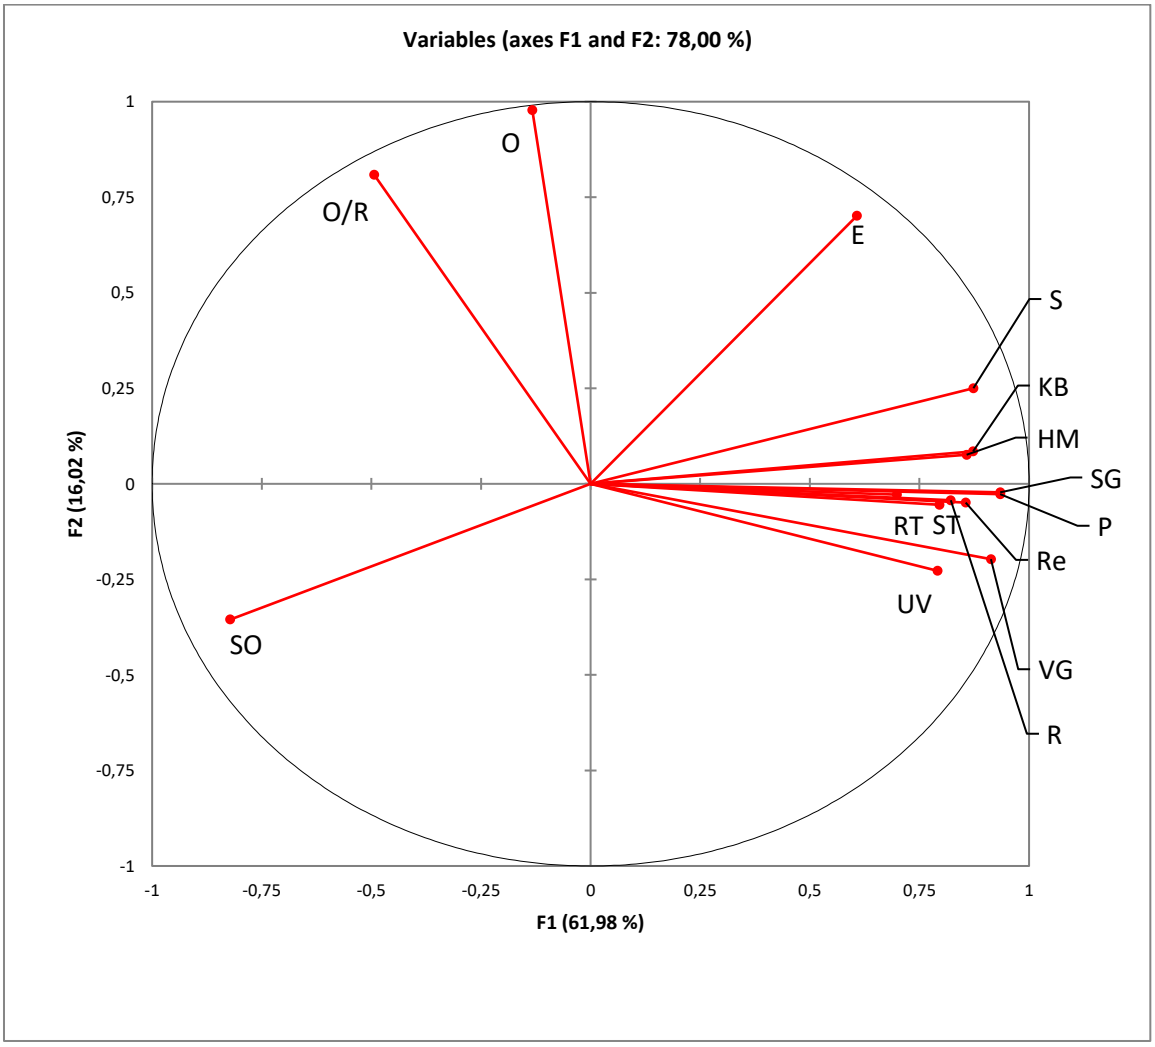
Slika 15 *Scree* test svojstvenih vrijednosti po glavnim komponentama

Tablica 8 Vrijednosti svojstvenih vektora u prve tri glavne komponente

	Svojstveni vektori		
Varijable	**F1**	**F2**	**F3**
P	0,306	-0,017	-0,038
S	0,286	0,161	-0,259
HM	0,281	0,049	0,008
VG	0,299	-0,127	0,011
SG	0,306	-0,014	-0,071
UV	0,260	-0,147	0,022
RT	0,229	-0,018	0,601
ST	0,261	-0,035	0,020
Re	0,281	-0,032	0,391
SO	-0,270	-0,229	-0,043
KB	0,286	0,055	0,206
E	0,199	0,452	-0,285
R	0,269	-0,028	-0,472
O	-0,044	0,631	0,054
O/R	-0,162	0,522	0,246

Osnovu za interpretaciju glavnih komponenata čine svojstveni vektori (**Tablica 8**). Njihove vrijednosti su u prvoj glavnoj komponenti, relativno ravnomjerno raspoređene po svim izvornim varijablama. U drugoj i trećoj glavnoj komponenti dolazi do njihove veće disproporcije, što omogućava izdvajanje izvorne varijable (ili tek nekoliko njih) sa jačim učešćem i pomaže u objašnjavanju i sažimanju ukupne varijabilnosti.

U **Tablici 9** dane su vrijednosti koeficijenata varijabli za sve glavne komponente. Rezultati pokazuju da su najveće vrijednosti većine promatranih varijabli kod glavne komponente F1, a nekolicina kod glavne komponente F2.



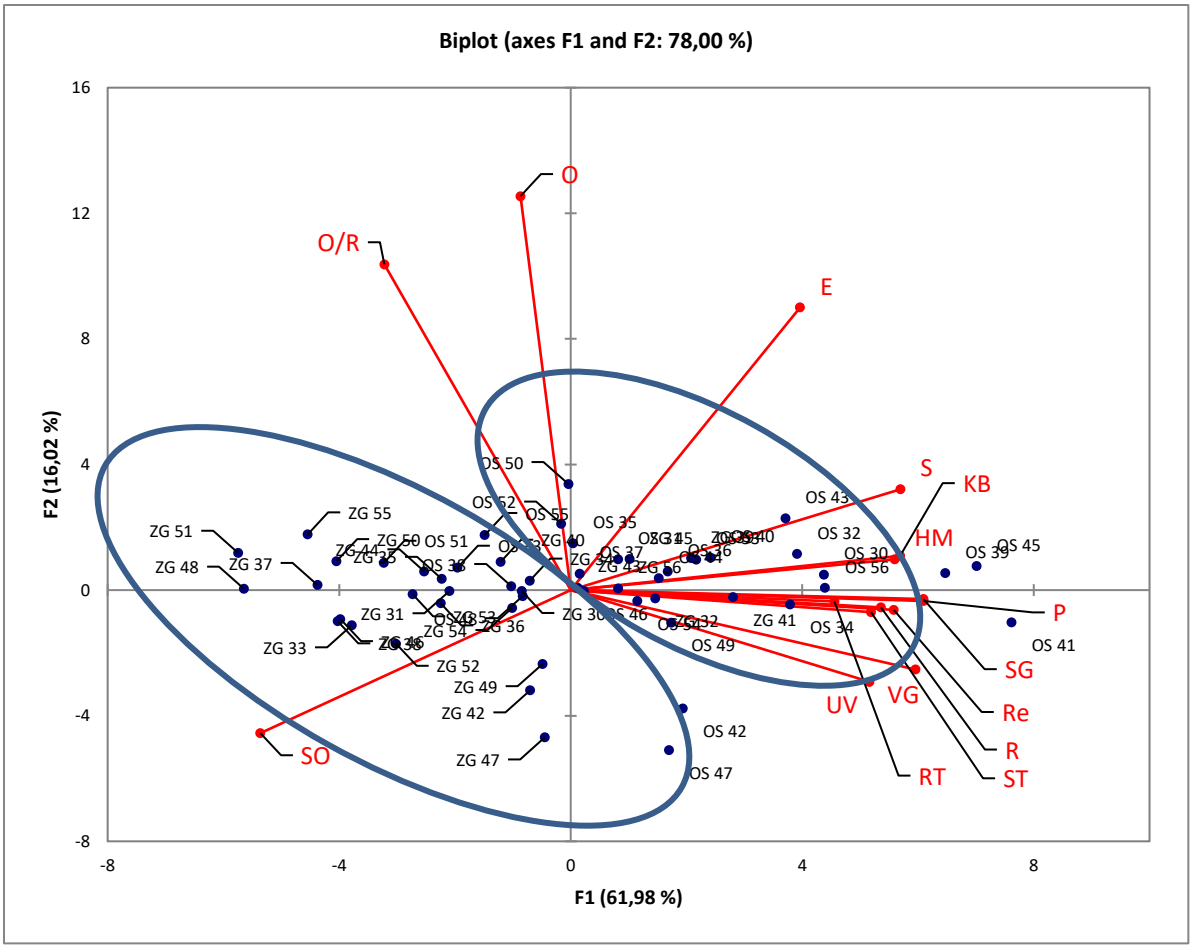
Slika 16 Prikaz pojedinih pokazatelja kvalitete pšenice prema glavnim komponentama F1 i F2

Tablica 9 Korelacija promatranih varijabli i glavnih komponenti

Varijable	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10	F11	F12	F13	F14	F15
P	**0,934**	-0,027	-0,039	-0,156	-0,056	-0,055	0,077	0,029	0,267	-0,128	-0,005	-0,010	-0,003	-0,001	0,000
S	**0,873**	0,250	-0,264	0,060	0,139	-0,035	-0,019	-0,178	0,112	0,185	-0,048	0,007	-0,003	0,014	0,000
HM	**0,858**	0,076	0,008	-0,256	0,171	0,200	-0,007	0,342	-0,008	0,079	-0,019	0,003	-0,004	0,001	0,000
VG	**0,913**	-0,197	0,011	-0,167	-0,050	-0,136	0,250	-0,023	-0,080	0,001	0,014	0,079	0,050	0,015	0,000
SG	**0,934**	-0,022	-0,073	-0,146	-0,036	-0,164	0,224	-0,041	-0,107	0,012	-0,008	-0,075	-0,050	-0,019	0,000
UV	**0,791**	-0,228	0,022	-0,295	0,315	0,256	-0,117	-0,212	-0,065	-0,084	0,005	-0,005	0,005	-0,004	0,000
RT	0,698	-0,028	0,612	0,112	0,201	-0,263	-0,118	0,025	-0,001	0,004	-0,004	-0,006	0,002	0,000	-0,010
ST	**0,795**	-0,055	0,020	0,464	-0,083	0,337	0,166	-0,010	-0,007	-0,023	-0,010	0,001	-0,004	-0,002	-0,008
Re	**0,856**	-0,049	0,398	0,315	0,086	0,008	0,013	0,007	-0,002	-0,009	-0,006	0,000	-0,001	0,001	0,016
SO	**-0,822**	-0,355	-0,044	0,082	0,371	-0,008	0,171	0,010	0,071	0,039	0,127	0,008	-0,015	-0,005	0,000
KB	**0,872**	0,085	0,210	-0,129	-0,349	0,091	-0,121	-0,049	0,018	0,074	0,136	-0,001	-0,007	-0,002	0,000
E	0,607	**0,701**	-0,290	0,124	0,086	-0,094	-0,084	0,025	-0,040	-0,062	0,028	0,087	-0,036	-0,026	0,000
R	**0,822**	-0,043	-0,481	0,212	0,069	-0,115	-0,110	0,072	-0,035	-0,022	0,050	-0,066	0,055	-0,008	0,000
O	-0,133	**0,978**	0,056	-0,021	0,087	0,022	0,072	-0,002	-0,031	-0,053	0,038	-0,035	-0,001	0,055	0,000
O/R	-0,494	**0,809**	0,251	-0,094	0,045	0,074	0,119	-0,048	0,034	0,032	-0,006	-0,020	0,043	-0,049	0,000

Grupiranje analiziranih varijabli oko pojedine glavne komponente prikazano je na **Slici 16** i **Tablici 9** iz kojih je vidljivo kako je većina analiziranih pokazatelja kvalitete pšenice objašnjena glavnom komponentom F1 (visoka korelacija promatranih varijabli i glavne komponente F1). Visoka pozitivna korelacija vidljiva je kod slijedećih varijabli: P (0,934), S (0, 873), HM (0,858), VG (0,913), SG (0, 934), UV (0,795), Re (0,856), KB (0,872), R (0,822) te negativna korelacija kod SO (-0,822). Dok su parametri kvalitete (O/R i O) grupirani oko F2.

Na **Slici 17** može se vidjeti da je došlo do razdvajanja uzoraka s osječkog i zagrebačkog područja koji su raspodijeljeni u sva četiri kvadranta. Uzorci sa zagrebačkog područja pokazali su prema svim parametrima kvalitete lošije rezultate te su svi uzorci prema PCA analizi grupirani s lijeve strane dijagrama (u trećem i četvrtom kvadrantu), nasuprot uzorcima osječkog područja koji su pokazali veću kvalitetu te su grupirani uglavnom u prvom kvadrantu.



Slika 17 PCA analiza pokazatelja kvalitete pšenice na temelju vrijednosti dvije glavne komponente

Primjenom PCA analize možemo odrediti koji od parametara imaju značajan utjecaj na raspodjelu uzoraka te na osnovu dobivenih podataka u prvoj glavnoj komponenti, koja objašnjava 61,98 % svih interakcija u promatranom skupu podataka, glavni utjecaj pripada fizikalno-kemijskim (SG, P i VG, S) te farinografskim (KB, Re, R, ST, UV i SO) pokazateljima kvalitete pšenice. Druga glavna komponenta doprinosi s 16,02 % pojašnjenju varijanci u promatranom skupu podataka, a tu dominiraju ekstenzografski pokazatelji kvalitete pšenice (O i O/R).

Ukupno se može pojasniti 78% varijacije u promatranom skupu podataka.

5. ZAKLJUČCI

Na temelju provedenih mjerenja fizičkih svojstva zrna, kemijsko–tehnološka svojstva zrna i brašna te reološki pokazatelji kvalitete promatranih sorti pšenice moguće je zaključiti slijedeće:

- rezultati većine *fizičkih svojstava* zrna (prosječna hektolitarska masa, masa 1000 zrna) bili su bolji za sorte pšenice zasijane na osječkom području
- rezultati *kemijsko–tehnoloških svojstva* zrna i brašna:
    - razlike u udjelu vode sorti zasijanih na dvije različite lokacije bile su statistički značajne, te je udio vode u sortama zasijanim na osječkoj lokaciji bio veći (u prosjeku 10,1 ± 0,2%) u odnosu na sorte sa zagrebačke lokacije (u prosjeku 9,9 ± 0,2%.)
    - udio pepela u sortama na lokaciji Osijek u prosjeku je iznosio 1,64 ± 0,05%, za sorte na zagrebačkoj lokaciji prosjek je bio značajno veći i iznosio je 1,74 ± 0,1%.
    - udio proteina na lokaciji Osijek iznosio je u prosjeku 12,8 ± 1,0%, dok je na zagrebačkoj lokaciji bio značajno manji, 11,1 ± 0,8%
    - sedimentacijska vrijednost na lokaciji Osijek iznosila je u prosjeku 32,8 ± 9,7 cm^3 što je značajno veće od prosječne vrijednosti na lokaciji Zagreb (24,0 ± 6,2 cm^3)
    - na osnovi razvrstavanja u razrede kakvoće prema udjelu proteina i sedimentacijskoj vrijednosti po Zeleny-u na osječkoj lokaciji 5 sorti (18,5%) svrstano je u prvu klasu, 10 sorti (37,0%) u drugu te 12 sorti (44,4%) u treću klasu. Na zagrebačkoj lokaciji niti jedna sorta nije svrstana u prvu klasu, 5 sorti (18,5%) svrstano je u drugu klasu, 17 sorti (63,0%) u treću, a 5 sorti (18,5%) kategorizirano je kao sorte izvan klase.
    - na osnovi razvrstavanja u kvalitativne klase prema Pravilniku o parametrima kvalitete i kvalitativnim klasama pšenice u otkupu pšenice roda 2017. godine (NN 64/2017), odnosno prema udjelu proteina i hektolitarskoj masi, na osječkoj lokaciji 8 sorti (29,6%) svrstano je u prvu klasu, 10 sorti, na zagrebačkoj lokaciji niti jedna sorta nije svrstana u prvu klasu
    - prosječno izbrašnjavanje na osječkoj lokaciji iznosilo je 0,45 ± 0,02%, a na zagrebačkom području 0,47 ± 0,02%.

- za sorte s osječke lokacije količina vlažnog glutena iznosila je u prosjeku 24,6 ± 3,7% dok je na zagrebačkoj lokaciji prosjek bio značajno manji (18,8 ± 3,5%). Količina suhog glutena iznosila je u prosjeku 8,9 ± 1,4% na lokaciji Osijek, dok je prosjek na zagrebačkoj lokaciji bio značajno manji (6,7 ± 1,4%).

- *reološki* pokazatelji kvalitete

  - ukupno su sorte sa osječke lokacije imale značajno bolje farinografske pokazatelje kakvoće od sorti sa zagrebačkog područja

  - sorte s osječke lokacije prosječno su imale značajno veće vrijednosti za energiju (90,5 ± 24,4 cm^2) i rastezljivost (112,3 ± 16,9 mm) u odnosu na sorte s lokacije Zagreb (69,1 ± 21,5 cm^2 i 100,3 ± 14,2 mm)

  - prosječno nije bilo značajne razlike između sorti s obje lokacije u pogledu broja padanja i većine amilografskih pokazatelja

Glavni aspekti analize glavnih komponenata je analiza linearne povezanosti većeg broja multivarijatno distribuiranih, kvantitativnih, međusobno koreliranih varijabli u smislu njihove kondenzacije u manji broj komponenti, novih varijabli, međusobno nekoreliranih, sa minimalnim gubitkom informacija. U radu je analizirano 27 sorti ozime pšenice roda 2017. godine, zasijanih na dvije različite lokacije. Kvaliteta pšenice analizirana je mjerenjem fizikalno-kemijskih, te reoloških svojstava zrna i brašna uzoraka ozime pšenice zasijane na lokacijama osječkog i zagrebačkog područja. Provedena je analiza podataka primjenom kemometrijske metode glavnih komponenata (PCA).

  - provedenom PCA analizom moguće je objasniti 78% varijacije u promatranom skupu podataka koja je pojašnjena pomoću dvije glavne komponete

  - fizikalno-kemijski te ekstenzografski pokazatelji kvalitete pšenice najveći utjecaj na raspodjelu kvalitete promatranih sorti pšenice imali su u komponenti F1, koja objašnjava oko 62% varijabilnosti uzoraka

  - druga glavna komponenta doprinosi s 16,02 % pojašnjenju varijanci u promatranom skupu podataka, a tu dominiraju ekstenzografski pokazatelji kvalitete pšenice (O i O/R).

6. LITERATURA

AACC 26-10A: Experimental Milling: Introduction, Equipment, Sample Preparation, and Tempering. Approved Methods of the American Association of Cereal Chemists, 10th ed. AACC, St. Paul, MN, 2000.

AACC 26-21A: Experimental Milling—Bühler Method for Hard Wheat. Approved Methods of the American Association of Cereal Chemists, 10th ed. AACC, St. Paul, MN, 2000.

AACC 26-31: Experimental Milling—Bühler Method for Soft Wheat Straight-Grade Flour. Approved Methods of the American Association of Cereal Chemists, 10th ed. AACC, St. Paul, MN, 2000.

Belak i suradnici, Tehnologija hrane – Šibenik, 2005.

Benšić M, Šuvak N: Primijenjena statistika. Sveučilište J.J. Strossmayera, Odjel za matematiku, Osijek, 2013.

Cooley, W.W., Lohnes, P.R.: Multivariate Data Analysis, John Wiley & Sons Inc., New York, 1973.

Devčić, K, Tonković Pražić, I, Župan, Ž (2012.): Klaster analiza: primjena u marketinškim istraživanjima. Zbornik radova Međimurskog veleučilišta u Čakovcu, 3(1)

Diamond, J., Guns, Germs, and Steel. The Fates of Human Societies. W. W. Norton and Co., New York, 1997.

Đaković, Lj. Pšenično brašno, Tehnološki fakultet, Zavod za izdavanje udžbenika, Novi Sad, 1997.

Einax, J.W., Zwanziger, H.W., Geiß, S.: Chemometrics in enviromental analysis, 1997.

Gagro, M.: Ratarstvo obiteljskog gospodarstva, Žitarice i zrnate mahunarke, Zagreb, 1997.

Heywood, V. H., Flowering Plants of the World. Oxford University Press, Oxford, UK., 1993.

Hoseney, R. C. Principles of cereal science and technology second edition, The American Association of Cereal Chemists, Inc. St. Paul, Minnesota; USA, 1994.

ICC standard 107/1, Standard Methods of the International Association for Cereal Science and Technology no 107/1 Determination of the "Falling Number" according to Hagberg - as a Measure of the Degree of Alpha-Amylase Activity in Grain and Flour, Vienna, Austria, 1995.

ICC standard 114/1, Standard Methods of the International Association for Cereal Science and Technology no 114/1 Method for using the Brabender Extensograph, Vienna, Austria, 1992.

ICC standard 115/1, Standard Methods of the International Association for Cereal Science and Technology no 115/1 Method for using the Brabender Farinograph, Vienna, Austria, 1992.

ICC standard 126/1, Standard Methods of the International Association for Cereal Science and Technology no 126/1 Method for using the Brabender Amylograph, Vienna, Austria, 1992.

ISO 20483: Cereals and pulses - Determination of the nitrogen content and calculation of the crude protein content – Kjeldahl method. International Organization for Standardization Geneva, Switzerland, 2006.

ISO 2171-2: Cereals, pulses and by-products -Determination of ash yield by incineration. . International Organization for Standardization Geneva, Switzerland, 2007.

ISO 5529: Wheat - Determination of the sedimentation index - Zeleny test. International Organization for Standardization Geneva, Switzerland, 2007.

ISO 712: Cereals and cereals products - Determination of moisture content – Routine reference method. International Organization for Standardization Geneva, Switzerland, 2001.

ISO 7971-2: Cereals - Determination of bulk density, called mass per hectolitre. International Organization for Standardization Geneva, Switzerland, 2009.

Jednačak, T., Novak P. (2013) Procesne analitičke tehnike temeljene na vibracijskoj spektroskopiji in-line i primjena u industriji. Kemija u Industriji. 62: 71-80.

Jelača S: Hemija i tehnologija pšenice. Zavod za tehnologiju žita i brašna, Novi Sad, 1972.

Jurišić, M. AgBase – Priručnik za uzgoj bilja i tehnologija (agrotehnika) važnijih ratarskih kultura, VIP projekt, Studija MPŠVG, Osijek, 2008.

Kaluđerski, G. i Filipović, N. Metode ispitivanja kvalitete žita, brašna i gotovih proizvoda; Tehnološki fakultet Novi Sad, 1998.

Kim, K. (2001) Face Recognition using Principle Component Analysis. IEEE Signal Processing Letters, 9: 40-42.

Kljusurić S: Uvod u tehnologiju mljevenja pšenice. Metković, 2000.

Krička, T. et. al. Tehnologija mlinarstva - Udžbenik, Osijek, 2012.

Làsztity R: The Chemistry of Cereal Proteins. CRC Press, INC, Florida, USA, 1996.

Mathias O: Chemometrics. Wiley – VCH Verlang GmbH & KgaA, Weinheim, 2007.

Morrison, L. A., and Wrigley, C. W., Taxonomic classification of grain species. Pages 271-280 in: Encyclopedia of Grain Science, Vol. 3. C. Wrigley, C. Walker, and H. Corke, Eds. Elsevier Ltd., Oxford, UK., 2004.

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

Piggot J.R: Statistical procedures in food research. Elsevier Applies Science, London, 1986.

Pravilnik žitaricama i proizvodima od žitarica, Ministarstvo poljoprivrede RH, Narodne novine 81/2016.

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

Žeželj M: Tehnologija i oprema za preradu žita. NIRO „Zadruga“, Beograd, 1982.