Klasifikacija zrna ozime pšenice određivanjem geometrijskih značajki zrna računalnom analizom slike

Velikanović, Valentina

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:109:968708

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

Valentina Velikanović

KLASIFIKACIJA ZRNA OZIME PŠENICE ODREĐIVANJEM GEOMETRIJSKIH ZNAČAJKI ZRNA RAČUNALNOM ANALIZOM SLIKE

DIPLOMSKI RAD

Osijek, rujan, 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:	Skladištenje žitarica i proizvodnja brašna
Tema rada	je prihvaćena na IX redovitoj sjednici Fakultetskog vijeća Prehrambeno-tehnološkog fakulteta Osijek u akademskoj godini 2017/2018. održanoj 29. lipnja 2018.
Mentor:	prof. dr. sc. *Daliborka Koceva Komlenić*
Komentor:	doc. dr. sc. *Jasmina Lukinac Čačić*
Pomoć pri izradi:	izv. prof. dr. sc. *Marko Jukić*

Klasifikacija zrna ozime pšenice određivanjem geometrijskih značajki zrna računalnom analizom slike

Valentina Velikanović, 442-DI

Sažetak: Kvaliteta zrna pšenice je složen pojam i uključuje fizičke karakteristike, svježinu zrna, kao i kemijski sastav zrna i druge karakteristike. Zadatak rada bio je primjenom računalne analize slike ispitati različite geometrijske značajke zrna različitih sorti ozime pšenice (površina, opseg, zaokruženost, dužina i širina, prosječna vrijednost sive boje) te utvrditi njihovu povezanost s različitim fizikalnim svojstvima zrna (postotak izbrašnjavanja, apsolutna masa, hektolitarska masa, staklavost zrna).
Na temelju provedenih ispitivanja 54 uzorka zrna ozime pšenice i provedene korelacijske i regresijske analize može se zaključiti da se primjenom računalne analize slike u određivanju geometrijskih značajki pšeničnog zrna vrlo dobro mogu predvidjeti neka fizikalna svojstva zrna.

Ključne riječi: pšenica, kvaliteta, fizikalna svojstva, računalna analiza slike

Rad sadrži:
42 stranica
15 slika
16 tablica
0 priloga
36 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.	izv. prof. dr. sc. *Krešimir Mastanjević*	zamjena člana

Datum obrane: 28. rujna 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

University Josip Juraj Strossmayer in 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: Cereal Storage and Flour Production
Thesis subject was approved by the Faculty of Food Technology Osijek Council at its session no. IX held on June 29, 2018
Mentor: *Daliborka Koceva Komlenić*, PhD, prof.
Co-supervisor *Jasmina Lukinac Čačić*, assistant prof.
Technical assistance: *Marko Jukić,* PhD, prof.

An evaluation of geometric features for winter wheat grain classification using digital image analysis

Valentina Velikanović, 442-DI

Summary: The wheat quality includes wheat physical characteristics, freshness of grains, as well as the chemical composition of grains and other characteristics. The aim of this paper was to examine the different grain geometrical characteristics of different winter wheat varieties (grain surface area, grain perimeter, grain circularity, grain length and width and average grey colour) and to determine their correlation with different physical properties of grain (flour milling yield, 1000 kernel weight, hectolitre mass, grain vitreousness).
The study was conducted on 54 samples of winter wheat variety samples. Based on the obtained results and performed correlation and regression analysis it can be concluded that physical properties of grain can be successfully predicted by using the computer image analysis in determining the geometric characteristics of wheat.

Key words: wheat, quality, physical properties, digital image analysis

Thesis contains:
42 pages
15 figures
16 tables
0 supplements
36 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. *Krešimir Mastanjević*, PhD, associate prof. — stand-in

Defense date: September 28, 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 1

2.1. Porijeklo i značaj pšenice 2

2.2. Pšenično zrno 2

2.3. Kriteriji određivanja kvalitete pšenice 3

2.3.1. Botanička pripadnost 3

2.3.2. Fizikalna svojstva 4

2.4. Računalna analiza slike 8

2.4.1. Koraci u procesu računalne obrade i analize slike 9

2.4.2. Uređaji za digitalizaciju slike 9

2.4.2.1. Skener 10

Skener korišten u diplomskom radu: EPSON Perfection®V500 Photo Color Scanner 11

2.5. Određivanje geometrijskih svojstava zrna analizom slike 13

2.5.1. Program za obradu slike – imagej 13

3. EKSPERIMENTALNI DIO 16

3.1. Zadatak 17

3.2. Materijal i metode 17

4. REZULTATI I RASPRAVA 23

5. ZAKLJUČCI 33

6. LITERATURA 39

Popis tablica

Tablica 1 Tehničke karakteristike skenera 12
Tablica 2 Rezultati određivanja geometrijskih značajki zrna primjenom računalne analize slike 24
Tablica 3 Rezultati ispitivanja fizikalnih svojstava zrna pšenice standardnim metodama 25
Tablica 4 Korelacijska matrica rezultata određivanja geometrijskih značajki i fizikalnih svojstava pšeničnog zrna....26
Tablica 5 Statistički parametri prikladnosti modela predviđanja postotka izbrašnjavanja (IZB)....26
Tablica 6 Analiza varijance 27
Tablica 7 Parametri modela 27
Tablica 8 Statistički parametri prikladnosti modela predviđanja apsolutne mase (AM)....28
Tablica 9 Analiza varijance 28
Tablica 10 Parametri modela 28
Tablica 11 Statistički parametri prikladnosti modela predviđanja hektolitarske mase (HM) 29
Tablica 12 Analiza varijance 29
Tablica 13 Parametri modela 30
Tablica 14 Statistički parametri prikladnosti modela predviđanja staklavosti zrna (ST) 31
Tablica 15 Analiza varijance 31
Tablica 16 Parametri modela 31

Popis slika

Slika 1 Uzdužni presjek zrna pšenice (Kljusurić, 2000)....2
Slika 2 Hektolitarska vaga (Izvor: web1) 5
Slika 3 Vrste pšenice i oblik zrna: Triticum monococcum (a), Triticum durum (b) i Triticum aestivum (c) (Evers i sur., 1990)...6
Slika 4 Određivanje dimenzija zrna pšenice....7
Slika 5 Poprečni presjek staklaste (a) i brašnaste (b) pšenice (Izvor: web2) 8
Slika 6. Skener EPSON Perfection V500 Photo (a), sučelje programa Epson Scan (b)....13
Slika 7 Prikaz glavnog menija programa ImageJ 14
Slika 8 Originalna fotografija pšeničnih zrna i odabrano područje interesa (ROI) pomoću „ImageJ“ programa 18
Slika 9 Originalna fotografija presjeka pšeničnih zrna, odabrano područje interesa (ROI) pomoću „ImageJ“ programa i pripadajući histogram 18
Slika 10 Ortogonalna projekcija zrna (Igathinathane i sur., 2009) 20
Slika 11 Shema mljevenja na Bühler-ovom mlinu (vlastiti izvor) 22
Slika 12 Podudarnost modelom izračunatih vrijednosti postotka izbrašnjavanja (%) i eksperimentalnih podataka 27
Slika 13 Podudarnost modelom izračunatih vrijednosti apsolutne mase (g) i eksperimentalnih podataka 29
Slika 14 Podudarnost modelom izračunatih vrijednosti hektolitarske mase (kg/hl) i eksperimentalnih podataka 30
Slika 15 Podudarnost modelom izračunatih vrijednosti staklavosti zrna (%) i eksperimentalnih podataka....32

Popis oznaka, kratica i simbola

NN Narodne novine

hl-masa hektolitarska masa

NIH National Institutes of Health

1. UVOD

Pšenica je najzastupljeniji ratarski usjev te je njome zasijana otprilike četvrtina obradive površine u svijetu. Najveći proizvođači pšenice su ujedno i površinom najveće zemlje u svijetu poput Kine, Indije, Ruske Federacije, SAD-a, Australije, Njemačke, Francuske. Pšenica potječe iz starog svijeta, iz južne Europe i Azije, odakle se širi na ostale dijelove svijeta. Jedna je od najstarijih kultura, i smatra se da se uzgaja već 10 000 godina. Botanički, pšenica je svrstana u porodicu trava (rod *Triticum*), a sadrži korijen, stabljiku, listove i klas.

Plod pšenice je zrno (*caryopsis*), a može biti različite krupnoće (krupno, srednje i sitno) ovisno o vrsti i sorti. Zrno se sastoji od omotača, klice (najmanji, ali biološki najvažniji dio, jer se u njoj nalaze svi budući organi biljke) te endosperma. Zrno pšenice sadrži malu količinu esencijalnih aminokiselina, osobito lizina, lako probavljivi škrob, bjelančevine, minerale, vitamine i mast. Prema morfološkim i biološkim karakteristikama te prema načinu uzgoja pšenica spada u prave žitarice. Postoji veliki broj kultivara i varijeteta pšenice, što je posljedica izraženog polimorfizma i širokog areala rasprostranjenosti. Prema osnovnoj podjeli pšenice razlikujemo ozimu (meka) i jaru (tvrda) pšenica. Za proizvodnju brašna značajne su tri vrste: *Triticum Aestivum* i *Triticum Compactum* te *Triticum durum*. Mljevenjem pšenice dobiva se brašno, pa je njena najveća primjena u mlinarstvu i prehrambenoj industriji. Kvaliteta zrna pšenice određuje se različitim parametrima na temelju kojih je razvrstana u tri skupine: osnovne sorte, krušne sorte i sorte poboljšivači.

Kvaliteta zrna pšenice je složen pojam i uključuje fizičke karakteristike, zdravstveno stanje i svježinu zrna, kao i kemijski sastav zrna i druge karakteristike. Što se tiče kemijskog sastava zrna pšenice, osnovne tvari koje određuju hranjivu vrijednost zrna pšenice su bjelančevine i škrob, može se reći da je najvažnije mjerilo kvalitete pšenice količina i kvaliteta proteina. Fizikalna svojstva zrna pšenice određuju se mjerenjem hektolitarske mase, apsolutne mase, veličine i oblika zrna, tvrdoće i staklavosti (brašnavosti) zrna, gustoće te boje zrna. Poželjno je da zrna imaju okrugli oblik i da su što krupnija, zato što krupnija zrna imaju manji udio omotača i klice. Zadatak ovog diplomskog rada bio je odrediti fizikalna svojstva zrna ozime pšenice različitih kultivara standardnim metodama i računalnom analizom slike.

2. TEORIJSKI DIO

2.1. PORIJEKLO I ZNAČAJ PŠENICE

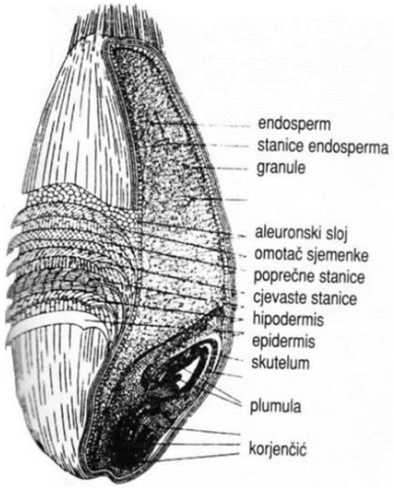
Žitarice su biljne vrste iz porodice trava (Poaceae) u koje se ubraja: pšenica (uključujući krupnik/pir i khorasan), raž, ječam, zob, kukuruz, riža, proso, sirak i pšenoraž (tritikale) te heljda iz porodice dvornika (Polygonaceae) (Pravilnik o žitaricama i proizvodima od žitarica, NN 81/16).

Pšenica je najstarija i najrasprostranjenija žitarica na svijetu. Smatra se da je uzgojena kao hrana oko 10000-8000 godina prije Krista. Pšenica, kao i druge žitarice, uzrok je prelaska ljudi s nomadskog na sjedilački način života (Diamond, 1997). Glavna karakteristika domestikacije pšenice je želja za povećanjem veličine zrna, što je dovelo do spontane selekcije. Pronađeni su dokazi na području „Plodnog polumjeseca“ koji ukazuju da je prijelaz s uzgoja divlje jednozrne (diploidne) pšenice na tetraploidine vrste bio uzrokovan povećanjem veličine zrna pšenice (Feldman, 2001; Fuller, 2007).

Prema podacima FAO, u 2017. godini proizvedeno je 743 milijuna tona pšenice.

2.2. PŠENIČNO ZRNO

Zrno pšenice je ovalnog oblika sa uzdužnom brazdicom koja zrno dijeli na dva jednaka dijela i prodire do samog središta zrna (**Slika 1**). Na vrhu zrna nalazi se bradica koja se sastoji od dlačica (Khan i Shewry, 2009). Ovisno o sorti, zrno je različite veličine što može utjecati na izbrašnjavanje. Dužina zrna pšenice varira od 4,2 do 8,6 mm, širina može biti od 1,6 do 4,0 mm, a debljina zrna može biti od 1,5 do 3,8 mm. Zrno se sastoji od tri osnovna dijela: ovojnice ili ljuske, endosperma i klice (Žeželj, 1982).



Slika 1 Uzdužni presjek zrna pšenice (Kljusurić, 2000)

2.3. KRITERIJI ODREĐIVANJA KVALITETE PŠENICE

O kvaliteti pšenice ovisi njena uporabna vrijednost kao sirovine za preradu u mlinske proizvode za ljudsku prehranu (Đaković, 1980). Kvaliteta pšenice ovisi o vrsti pšenice, te o uvjetima uzgoja poput klimatskih uvjeta, tla i primjeni agrotehničkih mjera (Kent i Evers, 1994).

Kvalitetu žitarica i prerađevina od žitarica određuje:

- botanička pripadnost,
- senzorska svojstva,
- količina i vrsta stranih primjesa,
- udio vode,
- kemijska svojstva,
- fizikalna svojstva,
- prisutnost štetočina, mikroorganizama i njihovih štetnih metabolita i
- prisutnost ostataka pesticida i drugih otrovnih tvari (Koceva Komlenić i Jukić, 2016).

2.3.1. Botanička pripadnost

Poznato je 27 vrsta pšenice, od kojih su tri značajne za proizvodnju brašna namijenjenog ljudskoj prehrani:

- obična ili meka pšenica (*Triticum aestivum*),
- patuljasta pšenica (*Triticum compactum*) i
- tvrda pšenica (*Triticum durum*).

Od ukupne proizvodnje pšenice u svijetu, 90% se proizvode sorte mekih vrsta. Većina sorti pšenica pripadaju vrsti *Triticum aestivum*, to je meka pšenica koja se uglavnom koristi za dobivanje brašna za kruh, a djelomično i u konditorskoj industriji, te za proizvodnju tjestenine. Patuljasta pšenica je meka, brašnasta pšenica, krupnog zrna, s malim udjelom proteina. Nije pogodna za proizvodnju kruha, a koristi se za proizvodnju keksa, lisnatog tijesta i vafla. Tvrda pšenica spada u pšenice staklaste strukture i velike tvrdoće, a pogodna je u proizvodnji tjestenine (Kljusurić, 2000).

Prema vremenu sjetve pšenice se mogu podijeliti na:

- zimska (ozima) pšenica koja se sije u području umjerene klime i to u kasno ljeto ili ranu jesen da bi pšenica proklijala i razvila mladu biljku prije zime kada uspori svoj razvoj, a u proljeće se nastavlja intenzivno razvijati. Ovakve pšenice imaju nešto manji udio proteina i
- proljetna (jara) pšenica se sije u proljeće jer su osjetljive na klimatske uvjete. Obično daju manje prinose, ali imaju nešto veći udio proteina i bolju tehnološku kakvoću.

2.3.2. Fizikalna svojstva

Apsolutna masa žitarica podrazumijeva masu 1000 cijelih zrna žitarica izraženu u gramima. Masa 1000 zrna žitarica varira u dosta širokim granicama, što ovisi o sorti pšenice, zemljištu, klimi, obradi i udjelu vode (Kaluđerski i Filipović, 1998). Masa 1000 zrna naših različitih vrsta pšenica kreće se između 30 i 40 g (Ugarčić i sur., 2016). Da bi se dobile usporedne vrijednosti potrebno ih je proračunati na isti udio vode ili na istu suhu tvar jer masa 1000 zrna raste s povećanjem udjela vode. Mogućnost izbrašnjavanja povezana je s masom 1000 zrna ali kvaliteta brašna nije (Kaluđerski i Filipović, 1998).

Masa 1000 zrna izražava se u gramima, a izračunava se prema formuli:

$$M = \mathrm{m} + \frac{(100-\mathrm{w})}{100} \qquad \textbf{(1)}$$

gdje je: *M* – masa suhe tvari 1000 zrna žitarica (g)

m – izmjerena masa 1000 cijelih zrna žitarica (g)

w – udio vode u zrnu žitarica (%) (Ugarčić i sur., 2016).

Hektolitarska masa je masa volumena 100 litara zrna izražena u kilogramima. Hl-masa je jedno od najstarijih mjerila za određivanje mlinarske kakvoće žitarica. Pod jednakim uvjetima žitarice s većom hl-masom imaju prednost jer je endosperm kompaktniji. S većom hl-masom raste i količina brašna, koja se može izmljeti, ali to nije pravilo. Ovo svojstvo zrna povezano je s ispunjenošću zrna, oblikom i veličinom, sadržajem primjesa, vlagom zrna te apsolutnom masom. Primjese mogu smanjivati, ali i povećavati hektolitarsku masu.

Povećanjem vlage smanjuje se hektolitarska masa zato što se povećava volumen zrna, tj. zrno postaje specifično lakše, jer voda ima manju masu od tvari zrna. Ponovnim sušenjem povećava se hektolitarska masa, ali se ne može dosegnuti prvobitna vrijednost prije vlaženja zbog razgradnje suhe tvari.

Hl-masu povisuju kompaktna staklasta zrna, potpuno dozrela, mala zrna i zrna osrednje veličine, ovalna zrna glatke površine, nizak maseni udio vode, te debela i hrapava ljuska. Hektolitarska masa kod pšenice iznosi 74-85 kg/hl.

Za određivanje hl-mase koriste se „hektolitarske vage“ (**Slika** 2) raznih veličina, obično ¼ ili 1 litra. Najčešće su to vage tipa Schopper (Rapčan, 2014; Ugarčić i sur., 2016).



Slika 2 Hektolitarska vaga (Izvor: web1)

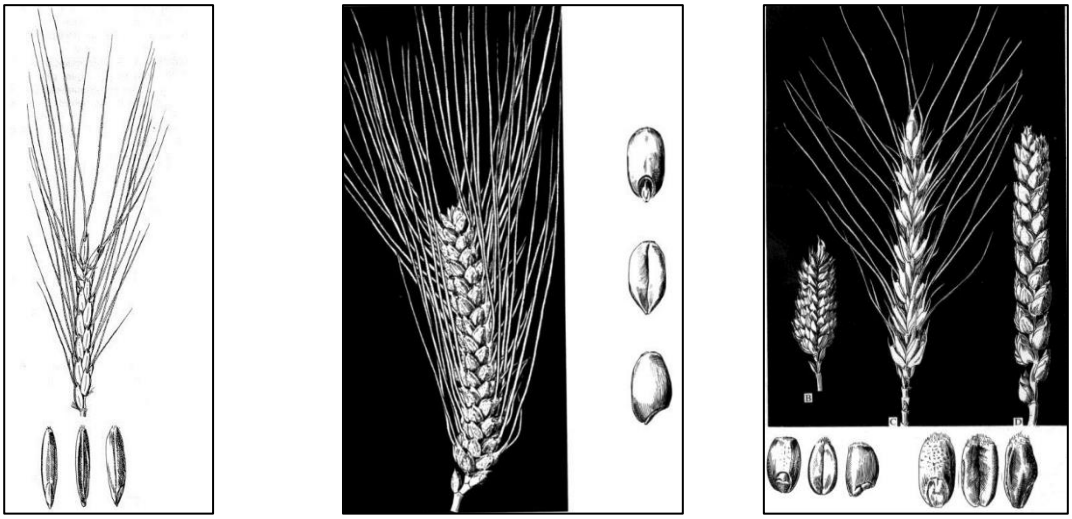
Hektolitarska masa jedna je od najstarijih pokazatelja ocjenjivanja kvalitete žitarica, a značajna je za mlinarsku industriju. Općenito vrijedi pravilo po kojem niska hektolitarska masa upućuje na nisku tehnološku kvalitetu zrnastih ratarskih proizvoda, napose žitarica. Pa je time i iskorištenje žitarica u procesu meljave manje. Nisku hektolitarsku masu pokazuju kompaktna i staklasta zrna, potpuno dozrela zrna, mala zrna i zrna osrednje veličine, ovalna zrna glatke površine, zrna s niskim sadržajem vode te s tankom ljuskom.

Gustoća zrna je masa jedinice volumena zrna (kg/m3, kh/l, g/cm3). Dijelovi zrna se razdvajaju tijekom mljevenja na osnovu različite gustoće anatomskih dijelova zrna. Najveću gustoću ima endosperm, zatim omotač, te klica. Gustoća ovisi o vrsti žitarice, sorti, prisustvu pljevice,

ispunjenosti i strukturi zrna te vlažnosti. Zrna s endospermom staklaste strukture su veće gustoće od brašnastih (Koceva Komlenić i Jukić, 2016).

Veličina zrna je proporcionalna s masom zrna. Krupnoća zrna i masa 1000 zrna pokazatelji su stupnja razvoja zrna. Na osnovu veličine zrna mogu se kalibriranjem razdvojiti različite frakcije što se utvrđuje prosijavanjem kroz sita različitih veličina otvora. Za svaku kulturu postoje odgovarajuća sita za krupno, srednje i sitno zrno. Za precizno utvrđivanje veličine zrna služi mikrometar (Rapčan, 2014).

Zrno je evoluiralo iz dugog i tankog primitivnog zrna na mnogo šire i kraće zrno (**Slika 3**) (Dvorak i sur., 2006). Zbog utjecaja na prinos, povećanje zrna je i dalje cilj uzgoja suvremenih tetraploida (*Triticum durum*) i heksaploida (*Triticum aestivum*) (Kovach i sur., 2007).

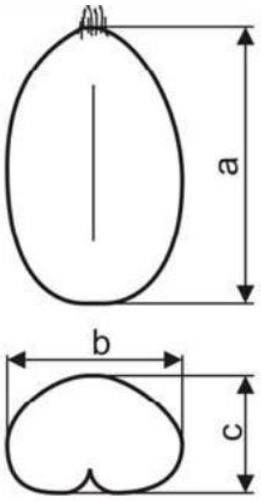


a b c

Slika 3 Vrste pšenice i oblik zrna: *Triticum monococcum* (a), *Triticum durum* (b) i *Triticum aestivum* (c) (Evers i sur., 1990)

Oblik zrna pšenice određuju se mjerenjem dužine (*a*), širine (*b*) i debljine ili visine (*c*) zrna (**Slika 4**). Osnovni oblik zrna pšenice određuje se deskriptivno, a zrno se opisuje izrazima poput okruglast (sferičan, kuglast), izdužen, duguljast, stožast (koničan), jajolik, eliptičan (oblik elipsoida), iskrivljen, zaobljen, izbrazdan i sl.

Oblik, veličina, gustoća i ujednačenost su važni za određivanje tržišne vrijednosti zrna budući da utječu na izbrašnjavanje. Smatra se da se prinos izbrašnjavanja može povećati optimiziranjem veličine zrna s velikim i sferičnim zrnima (Evers i sur., 1990).

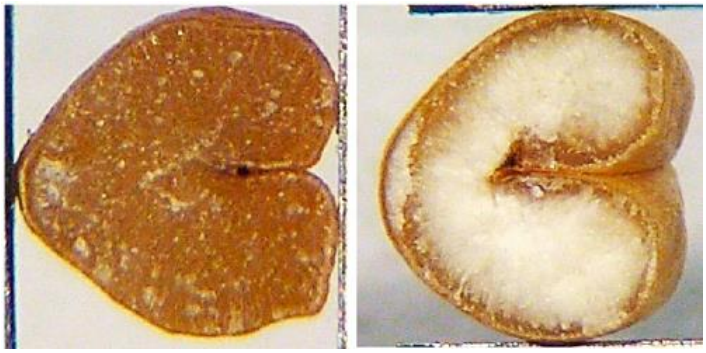


Slika 4 Određivanje dimenzija zrna pšenice

Tvrdoća zrna se odnosi na silu koja je potrebna kako bi se zdrobilo zrno. Tako razlikujemo „meke“ pšenice koje su brašnaste, imaju mekši endosperm, te „tvrde“ pšenice koje su staklaste, a endosperm im je kompaktniji (Delcour i Hoseney, 2010).

Staklavost zrna podrazumijeva izgled poprečnog presjeka zrna (**Slika 5**), odnosno izgled endosperma. Endosperm zrna može u prerezu biti ili sasvim bijele boje, takvo zrno nazivamo „brašnasto“ ili može imati poluproziran izgled, takvo zrno nazivamo „staklastim“ (Ugarčić i sur., 2016). Brašnaste pšenice imaju zračne prostore koji lome i raspršuju svjetlost. Tvrde pšenice su kompaktnije pa se svjetlost raspršuje s površine zrna, te prolazi kroz zrno (Delcour i Hoseney, 2010). Među ovim krajnjim ekstremima nalaze se svi mogući prijelazi.

Brašnaste i pretežno brašnaste pšenice nazivaju se i „mekanim“ pšenicama, a one druge „tvrdim“, što nije identično sa pšenicama vrste *Triticum durum*. Struktura pšenice je rezultat klime i sorte pšenice. Brašnaste pšenice imaju obično manji udio bjelančevina od tvrdih. Za mljevenje je pogodnija tvrda pšenica, koja daje uz to i brašno bolje pecivosti. Kod ostalih žitarica pitanje strukture endosperma nije od tolike važnosti kao kod pšenice. Endosperm staklastih pšenica je kompaktniji i teži, te stoga staklaste pšenice imaju obično veću hektolitarsku i specifičnu masu (Ugarčić i sur., 2016).



a b

Slika 5 Poprečni presjek staklaste (a) i brašnaste (b) pšenice (Izvor: web2)

Boja zrna određena je pigmentima koji se nalaze u omotaču zrna i mora odgovarati vrsti žitarice. Boja varira od bijele do crveno-smeđe, ovisno o sortnim svojstvima pšenice. Crvene pšenice s tamnom nijansom imaju više proteina od pšenica svjetlijih nijansi crvene i žute boje. Promjene u bojama povezane su sa klimatskim uvjetima i uvjetima uzgoja (Koceva Komlenić i Jukić, 2016).

2.4. RAČUNALNA ANALIZA SLIKE

Razvojem tehnologije primjena računala zauzima sve veći prostor u prehrambenoj industriji, kako u regulaciji procesa proizvodnje, tako i u senzorici (poput računalnog vida). Računalna analiza slike predstavlja objektivan, jednostavan, brz i precizan način ocjenjivanja kvalitete proizvoda. Najveće prednosti računalnog vida u odnosu na ljudsko oko su objektivnost i mogućnost pohranjivanja podataka. Objektivnost ljudskog oka je narušena ograničenjem vidljivog područja na valne duljine u rasponu od 400 do 700 nm s optimumom kod 550 nm. Također je ograničen i dinamički opseg pa ljudsko oko može razlikovati manje od 100 sivih nijansi, za razliku od računalnog sustava koji razlikuje 16,7 milijuna boja i 256 sivih nijansi (Jain, 1989). Sustav za računalnu analizu slike, boju uzorka registrira s tri senzora boje, a sastoji se od tri najvažnija elementa: rasvjete, digitalne kamere ili skenera i računala (Lukinac Čačić, 2012). Primjena metode moguća je gotovo u svim područjima prehrambene industrije. Neovisno o vrsti uzorka analiza se provodi u nekoliko koraka: digitalizacija, pred procesiranje, segmentacije, post procesiranje i izdvajanje značajki.

Obrada i analiza slike se prvenstveno fokusira na proces digitalizacije (akvizicije) slike, te analize zbog izdvajanja slikovnih podataka (boja uzorka, morfološke karakteristike: oblik, tekstura, površina). Analiza slike se primjenjuje na način da bude objektivna, jednostavna za korištenje, ponovljiva i brzo izvediva.

2.4.1. Koraci u procesu računalne obrade i analize slike

1. DIGITALIZACIJA - digitalna slika je proizvedena od jednog ili više senzora. Ovisno o tipu senzora, slikovni podatak je obični 2D prikaz, 3D volumen ili slijed slika u različitim formatima (JPEG, TIFF).
2. PRETPROCESIRANJE - podrazumijeva ispravljanje eventualnih grešaka nastalih prilikom snimanja digitalne slike te evaluacija kvalitete slike, pretprocesiranje je priprema za segmentaciju slike.
3. SEGMENTACIJA - pri analizi objekata na slici neophodno je razgraničiti „objekte od interesa“ od ostatka slike. Segmentacija objekata, pojedinačnih površina ili dijelova objekata vrši se klasifikacijom svakog piksela (osnovnog slikovnog elementa), odnosno računalo provjerava pripada li ili ne pojedini piksel grupi odnosno objektu.
4. POSTPROCESIRANJE - u osnovi je vezano na dvije metode kojima se poboljšavaju rezultati dobiveni segmentacijom. Prva metoda bazirana je na morfološkim operacijama kojima je cilj popraviti rezultat segmentacije, a druga na mjerenju segmentiranih objekata čime se razdvajaju objekti spojeni segmentacijom. Operacije mjerenja dolaze nakon što slika prođe kroz proces pretprocesiranja, segmentacije i postprocesiranja.
5. IZDVAJANJE ZNAČAJKI - značajke slike na različitim razinama složenosti su izlučene iz slikovnih podataka. Tipični primjeri takvih značajki: linije i rubovi, lokalizirane točke kao što su kutovi, mrlje ili točke, dok složenija obilježja mogu biti povezana s teksturom, oblicima ili pokretima. (Strgar Kurečić, 2015)

2.4.2. Uređaji za digitalizaciju slike

Digitalizacija slike je postupak dobivanja slike putem digitalnog uređaja. Dobra kvaliteta digitalne slike je osnovni uvjet za analizu slike, a uređaji koji se koriste za digitalizaciju su fotoaparat ili skener (Shahin i Symons, 2005).

2.4.2.1. Skener

Skener (eng. scanner) je uređaj koji služi za digitalizaciju fotografija, crteža i transparentnih medija, a skeniranje je postupak kojim se slika ili tekst pretvara u digitalni zapis u različitim formatima (PDF, JPG, TIFF) s ciljem obrade, čuvanja ili prijenosa na računalo. Tri osnovne vrste skenera su ručni, plošni i rotacijski.

Senzori kod skenera mogu biti:

- CCD-tehnologija ima veliki raspon boja, veliku rezoluciju bez promjene boje, veća dubinska oštrina i brzina. Nedostatak je česta potreba za kalibracijom, geometrijska distorzija i cijena i
- CIS-tehnologija ima senzore i LED izvor svjetla postavljene blizu objekta koji se skenira. Imaju stabilan iluminacijski sustav, te je potrebna mala kalibracija. Nedostatak je manji raspon boje, ograničena dubinska oštrina te relativno niska stvarna rezolucija.

Način skeniranja je najvažnija značajka skenera i izražava se brojem točaka po palcu. Razlučivost ovisi samo o preciznosti mehanizma za pomicanje bubnja. Horizontalna razlučivost (razlučivost „oko bubnja“) ovisi o brzini rotacije, a vertikalna razlučivost ovisi o preciznosti pomicanja bubnja u smjeru osi rotacije.

Dvije su različite razlučivosti:

- Interpolirana razlučivost je ona koju skener ili upravljački program postiže interpoliranjem, odnosno umetanjem dodatnih točaka između skeniranih točaka, tako da se njihova boja izračunava na osnovi susjednih točaka i
- Optička razlučivost je stvarna razlučivost skenera i jedina je bitna za kvalitetu skenera. Što je razlučivost veća, to je rezultat skeniranja bolji.

Dubina boje je broj bita kojima je opisana informacija o boji jednog piksela. Više bitova znači i točniju informaciju o stvarnom intenzitetu svjetla, slika će sadržavati veći broj tonova i točniji prikaz boja. Boja piksela na slici s dubinom boje od 1 bita može imati samo dvije vrijednosti, crnu ili bijelu. Boja piksela na slici s dubinom boje od 8 bita može imati jednu od mogućih 256 vrijednosti.

Tonska gustoća ili dinamički raspon skenera je logaritam omjera između maksimalne svjetlosti koju fotoosjetljivi elementi detektiraju i minimalne svjetlosti (tame) koju

fotoosjetljivi elementi detektiraju. Što se skeniranjem može dobiti više sivih nijansi ili boja to je dinamički raspon skenera veći. Uobičajeni plošni skeneri imaju dinamički raspon od 2.4, što odgovara nižoj kvaliteti skeniranja. Kvalitetniji skeneri imaju dinamički raspon 3.0. Skeneri za film i mikrooblike obično imaju veći dinamički raspon, a rotacijski skeneri dostižu vrijednosti do 3.8.

Rezolucija je mjera za kakvoću slike, a veličina digitalne slike je definirana pikselima. Broj piksela je apsolutna vrijednost, ali oni ovise o uređaju na kojem se prikazuju. Što je rezolucija veća, oku je vidljivo više detalja.

Plošni (stolni) skeneri su najpopularniji, mogu biti crno-bijeli ili u boji, najčešćeg formata A4 ili rjeđe A3 te razlučivosti do 1200 točaka po palcu. Plošni skener je građen od kućišta, poklopca s bijelom ili crnom podlogom za što bolju refleksiju, ili poklopca, u koji je ugrađeno svjetlo za transmisijsko snimanje. Površina skenera je staklena ploča na koju se postavlja objekt koji će se skenirati. U kućištu skenera se duž cijele širine staklene ploče nalazi izvor svjetla te optički sustav sastavljen od leća i zrcala koji pomažu usmjeravanju svjetlosti prema senzoru. Kada svjetlost padne na objekt ona se reflektira i putem optičkog sustava, zrcala i leća, dolazi do fotosenzora koji stvaraju električni signal. Taj električni signal se tada posebnim sustavom pretvara u digitalnu informaciju i šalje u računalo. Dobivena slika se pri tom postupku dijeli u točke ili piksele (što je više točaka to će slika biti veće kvalitete ili veće rezolucije). Svaki piksel ima svoju brojčanu vrijednost koja predstavlja indeks boje ili sive nijanse. Slike uzoraka pohranjuju se najčešće u RGB modelu s 256 boja (8-bitna boja; 28=256). Računalna analiza slike olakšava vizualno ocjenjivanje i opisivanje pojedinih značajki uzoraka (Gonzalez i Woods, 1992).

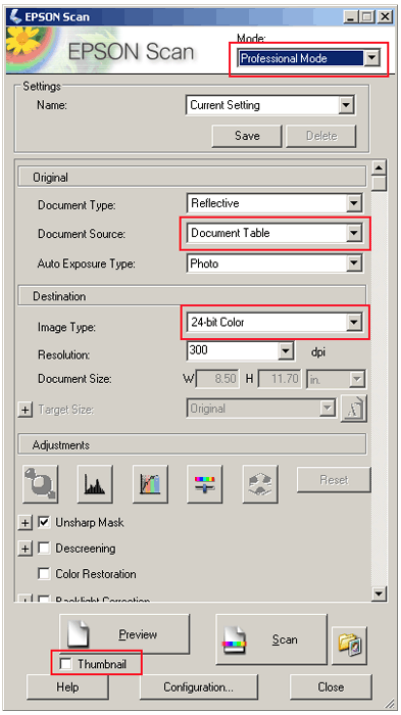
Skener korišten u diplomskom radu: EPSON Perfection®V500 Photo Color Scanner

Skeniranje je postupak kojim se slika pretvara u digitalni oblik pogodan za obradu, pohranu i prijenos računalom. Karakteristike skenera dane su u **Tablici 1**, a izgled skenera te sučelje programa korištenog za akviziciju slika prikazani su na **Slici 6**.

Tablica 1 Tehničke karakteristike skenera

Model	*Epson Perfection V500 Photo*
Vrsta skenera	Stolni skenere (Flatbed color image scanner)
Optički senzor	Epson MatrixCCD® 12-line, color sensor
Način skeniranje	Transmisija: siva skala, puna boja Refleksija: jednotonski, siva skala, puna boja
Razlučivost	Horizontalna: 6400 dpi
	Vertikalna: 9600 dpi
	Optička rezolucija: 6400 dpi (max)
	Interpolirana rezolucija: 12,800 x 12,800 dpi (max)
Dubina boja (ulaz/izlaz)	24-48 bit boja (u boji) 8-16 bit (siva skala)
Dinamički raspon	3,4 Dmax
Rezolucija (efektivni pikseli)	54,400 x 74,880 (6400 dpi)
Izvor svjetla	Bijela LED lampa s ReadyScan™ LED tehnologijom
Model boja	sRGB, RGB
Brzina skeniranja	4800 dpi High-speed Mode 16,98 msec/line (jednotonski/puna boja)
Raspon skeniranja (max)	216 x 297 mm
Način rada skenera	Refleksija i transmisija
Izlazni format slike	BITMAP, JPEG, TIFF, Multi-TIFF, PDF, PICT
Priključci	USB 2.0 tipa B
Programska podrška	Epson Scan





a b

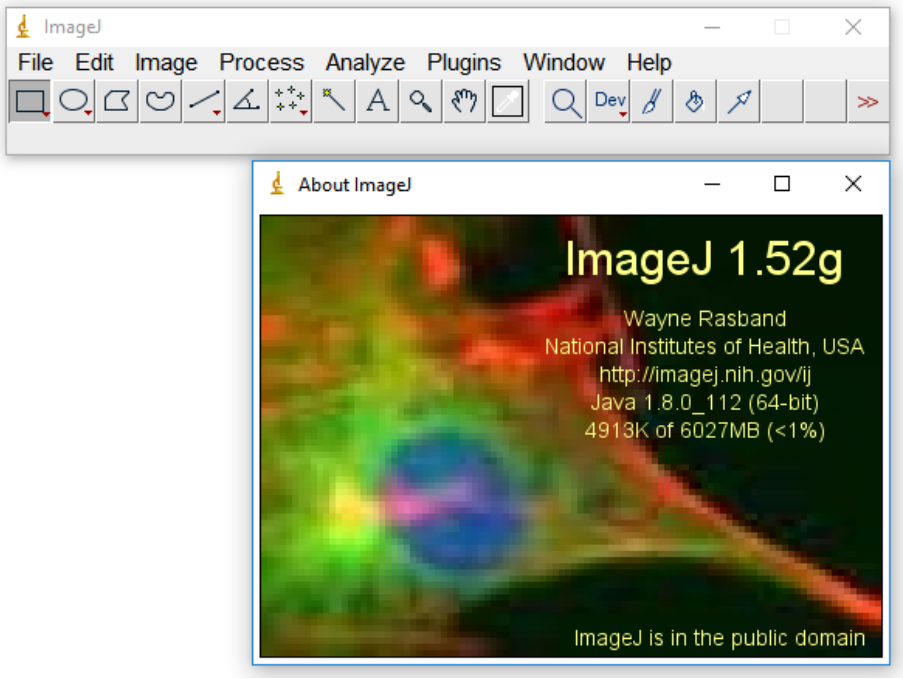
Slika 6. Skener EPSON Perfection V500 Photo (a), sučelje programa Epson Scan (b)

2.5. ODREĐIVANJE GEOMETRIJSKIH SVOJSTAVA ZRNA ANALIZOM SLIKE

Analiza slike učinkovita je metoda za određivanje geometrijskih svojstava zrna (oblik, dimenzije, boja), omogućuje poboljšanje slike, kao i identifikaciju i automatsku izolaciju uzoraka za daljnje proučavanje. Osim toga, riječ je o brzoj i objektivnoj metodi kojom se uštedi vrijeme potrebno za analizu (Gonzalez i Woods, 1992; Dougherty, 1994; Russ, 1995).

2.5.1. Program za obradu slike – ImageJ

ImageJ je program otvorenog koda (opensource) napisan u Javi. Program radi kao online aplikacija ili se može preuzeti na bilo koje računalo koje ima instaliranu Java 1.4 ili noviju verziju (**Slika 7**).



Slika 7 Prikaz glavnog menija programa ImageJ

Obzirom da je otvorenog koda nudi mogućnost nadogradnje i proširenja pomoću skripti i plugin-a. Program nudi automatizirane, reproducibilne tijekove rada preko skripti i makronaredbi (Collins, 2018). ImageJ ima korisničko sučelje s funkcijama za učitavanje, prikazivanje, analiziranje, spremanje i ispis 8, 16 i 32 bitne slike raznih formata: TIFF, GIF, JPEG, BMP i DICOM. Podržava i serije slika koje dijele jedan prozor (multithread), te se time omogućava čitanje slika i paralelno korištenje drugih operacija (Rasband, 2012).

Mogućnosti koje nudi program su osim standardne obrade slike i određivanje morfoloških karakteristika objekata (površina, volumen, deskriptori oblika), izračunati broj piksela, izmjeriti udaljenosti i kutove, a sadrži i opcije za podešavanje kontrasta, izoštravanje, poravnavanje, lokalizaciju, registraciju, segmentaciju, praćenje, vizualizaciju i još mnogo toga. Program omogućuje geometrijske transformacije poput rotacije i skaliranja. Slika se može povećati do 32:1 i smanjiti do 1:32. Podržava neograničen broj otvorenih prozora istovremeno, ograničen je jedino dostupnom memorijom računala.

Naredba za analiziranje šupljina mjeri objekte u binarnim ili „threshold“ slikama, a radi na principu skeniranja slike sve dok se ne pronađe rub objekta. Prag (eng. threshold) odnosno primjena razdjelne vrijednosti je najjednostavnija metoda podjele slike u segmente, koja se bazira na pretvorbi slike sa različitim nijansama boja u binarnu sliku. Nakon toga, u izborniku

se može odabrati raspon za veličinu i okruglost šupljina koja će se uzeti u obzir, pri čemu će sve izvan tog raspona biti zanemareno.

Program omogućuje primjenu algoritma poput ColorHistogram za mjerenje boja na slici. Ovom naredbom program prikazuje histograme RGB vrijednosti i prosječne vrijednosti piksela svakog kanala boje u tablici rezultata (Results). ColorHistogram algoritam se može primijeniti na čitavu sliku ili na definirano područje interesa (ROI).

Kako bi se ubrzala obrada slika, te omogućilo automatizirano izvođenje potrebnih operacija nad njima, koriste se makronaredbe. Makronaredbe (eng. macros) su nizovi naredbi, odnosno jednostavni programi koji omogućavaju automatizirano izvođenje funkcija. Zapisani su u .txt datoteci kao „običan“ tekst, u makro jeziku (baziran na Javi) koji se interpretira u ImageJ-u, te omogućuju implementaciju automatiziranih naredbi povezivanjem postojećih funkcija u ImageJ-u (Collins, 2018).

3. EKSPERIMENTALNI DIO

3.1. ZADATAK

Zadatak rada bio je primjenom računalne analize slike ispitati različite geometrijske značajke zrna različitih sorti ozime pšenice (površina, opseg, zaokruženost, dužina i širina, prosječna vrijednost sive boje) te utvrditi njihovu povezanost s različitim fizikalnim svojstvima zrna (postotak izbrašnjavanja, apsolutna masa, hektolitarska masa, staklavost zrna).

3.2. MATERIJALI

U istraživanju je korišteno 54 uzorka različitih sorti ozime pšenice roda 2017. godine zasijanih na dvije lokacije: osječko i zagrebačko područje.

3.2.1. METODE

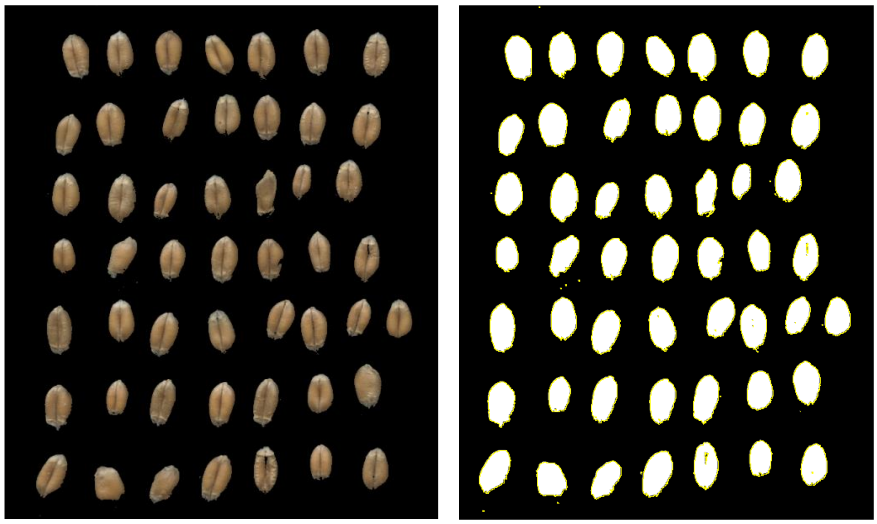
3.2.1.1. Određivanje geometrijskih značajki pšeničnog zrna primjenom računalne analize slike

Geometrijska svojstva zrna određena su računalnom analizom 2D slike. Sustav za analizu slike obuhvaća slijedeće elemente:

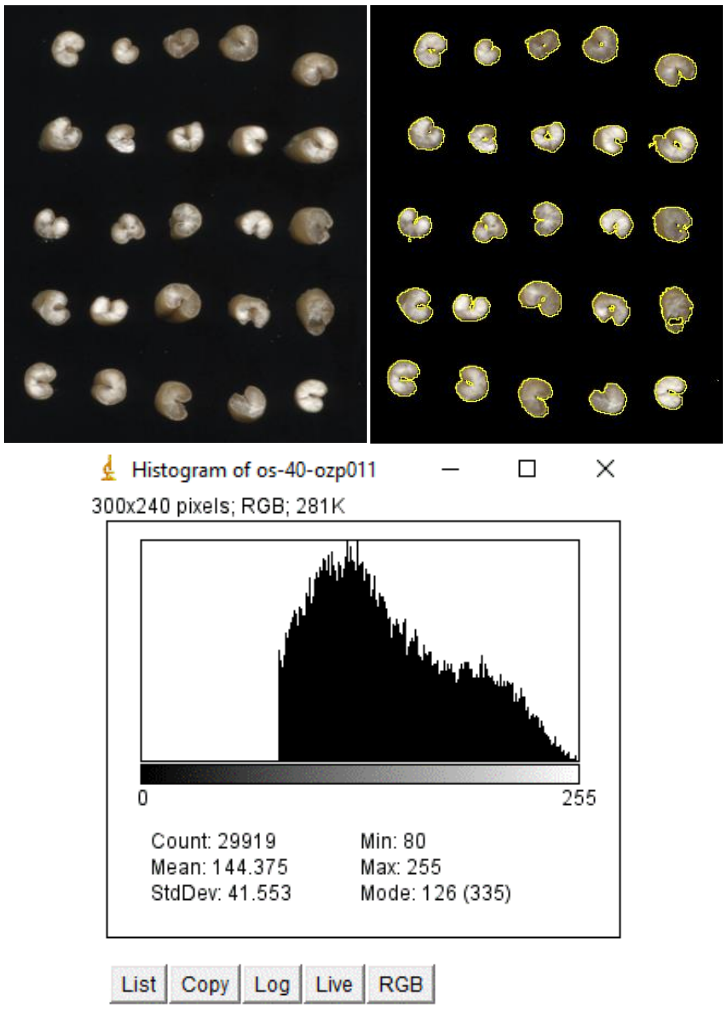
- Skener (Epson V500 Photo)
- Tamna komora
- Računalo i računalna podrška za akviziciju, obradu i analizu slike

Koraci u analizi i obradi slike su slijedeći:

- ✓ PRIHVAT I DIGITALIZACIJA - uzorci su skenirani stolnim skenerom EPSON Perfection V500 Photo (Epson America Inc., CA, USA) pri rezoluciji 600 dpi, dubini boje od 24 bit u sRGB modelu boja i TIFF formatu. Ova vrsta skenera omogućava ravnomjerno osvjetljenje uzorka, čime se umanjuje nastanak šuma/greške prilikom skeniranja. Za svaku sortu pšenice nasumično je odabrano 60 zrna koji su položeni na staklo skenera, vodeći računa da se uzorci međusobno ne dodiruju (**Slika 8**). Radi eliminacije utjecaja vanjske svjetlosti (obzirom da se skeniranje provodi bez poklopca skenera) te kontroliranja uvjeta skeniranja (ujednačene pozadine koja je u kontrastu s bojom analiziranih uzoraka radi lakše analize), skener je smješten u tamnu komoru.



Slika 8 Originalna fotografija pšeničnih zrna i odabrano područje interesa (ROI) pomoću „ImageJ“ programa



Slika 9 Originalna fotografija presjeka pšeničnih zrna, odabrano područje interesa (ROI) pomoću „ImageJ“ programa i pripadajući histogram

Nakon skeniranja primijenjena je analiza slike pomoću besplatnog programa otvorenog koda ImageJ (verzija 1.59g, Wayne Rasband, NIMH, Maryland, USA).

- ✓ OBRADA I ANALIZA SLIKE – nakon postupka digitalizacije fotografije potrebno je napraviti korak PREDOBRADBE slike koji uključuju pretvaranje 24-bitne u 8-bitnu fotografiju, te nakon toga definirati područje interesa na slici (ROI). Definiranje ROI-a podrazumijeva selektiranje uzorka zrna pšenice i izdvajanje od pozadine (**Slika 8 i 9**).

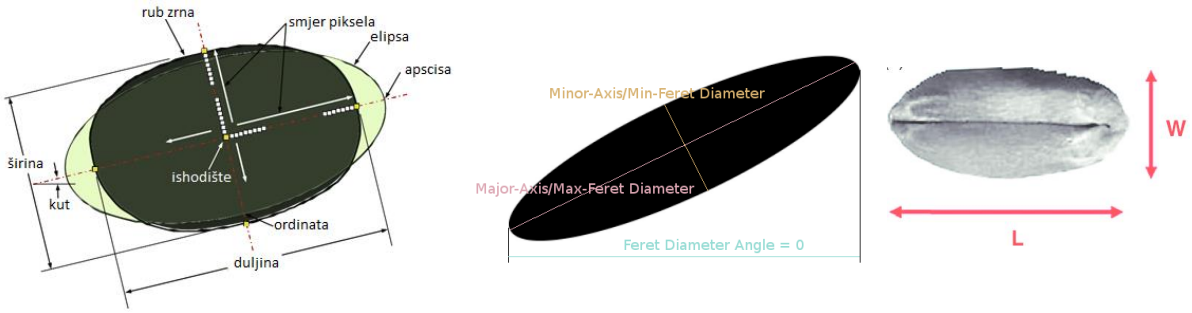
- ✓ Nakon definiranja ROI-a, primjenom slijeda različitih algoritama slijedi IZDVAJANJE GEOMETRIJSKIH SVOJSTAVA ZRNA. Geometrijska svojstva zrna mjerena računalnom analizom slike dobivena su primjenom odgovarajućih algoritama u programu ImageJ (površina, opseg, duljina i širina zrna), a neka su dobivena preračunavanjem (zaokruženost i GV_{AVG}):

  - **Površina** (*Area*), *P* – predstavlja površinu zrna izraženu u mm^2

  - **Opseg** (*Perimeter*) – predstavlja izmjerenu vrijednost opsega zrna izraženu u mm.

  - **Duljina,** *L* (max Feret diameter) i **širina,** *W* (min Feret diameter) zrna izražena pomoću Feretovog dijametra.

Slika je 2D numerički prikaz zrna pšenice, odnosno 2D funkcija $f(x, y)$, gdje su x i y planarne koordinate, dok je f na bilo kojoj poziciji koordinata (x, y) intenzitet slike u toj točci (Gonzalez i sur., 2009). Pomoću plugina-a integriranog u ImageJ program izravno se mjeri stvarna duljina i širina zrna nakon određivanja ruba pšeničnog zrna. Zrna koja su složena na način da se međusobno ne dodiruju, pojednostavljuju analizu. Pretpostavlja se da se duljina i širina zrna presijecaju u središtu. Na taj način, polazeći iz ishodišta, dobivaju se koordinate apscisa i ordinata (**Slika 10**). Iz tih koordinata, korištenjem formule određuje se dužina i širina zrna (Igathinathane i sur., 2009; Shahin i Symons, 2005)



Slika 10 Ortogonalna projekcija zrna (Igathinathane i sur., 2009)

- **Zaokruženost, *Circ*** (*Circularity*) – određuje oblik zrna u odnosu na savršeni krug. Vrijednosti su u rasponu 0-1, što su vrijednosti bliže 1 to uzorak ima oblik savršenog kruga

$$Circ = \frac{4\pi(P)}{(O)^2}$$

Gdje je:

P – površina zrna izražena u mm^2
O – opseg zrna izražen u mm

- **Prosječna vrijednost sive nijanse,** GV_{AVG} (*Mean gray value*) – prosječna vrijednost sive nijanse selektiranog područja podijeljena s brojem piksela

$$GV_{AVG} = \frac{R + G + B}{3} = 0{,}299 \cdot R + 0.587 \cdot G + 0{,}114 \cdot B$$

Gdje je:

R – dobivena vrijednost crvene boje

G – dobivena vrijednost crvene boje

B – dobivena vrijednost plave boje

Dobiveni rezultati mjerenja geometrijskih svojstava zrna pretvaraju se iz piksela u milimetre obzirom na poznate vrijednosti razlučivosti skenera u dpi jedinicama.

3.2.1.2. Određivanje fizikalnih svojstava zrna standardnim metodama

Određivanje apsolutne mase žita (mase 100 zrna)

Apsolutna masa određena je prema standardnoj metodi ISO 520. Od prosječnog uzorka se izbroji (bez odabiranja) 500 cijelih zrna i izvaže, te rezultat pomnoži s 2 i preračuna na suhu tvar.

Određivanje nasipne gustoće (hektolitarske mase) žita

Hektolitarska masa određena je prema standardnoj metodi ISO 7971-2. Korištena je Schopperova vaga, volumena 1 l, s pripadajućim dijelovima i opremom. Hektolitarska masa se preračunava na vlagu od 14%, preko faktora za korekciju. Faktor za korekciju može se očitati iz tablice ili izračunati. Izražava se u kg/hl.

Određivanje staklavosti pšeničnog zrna

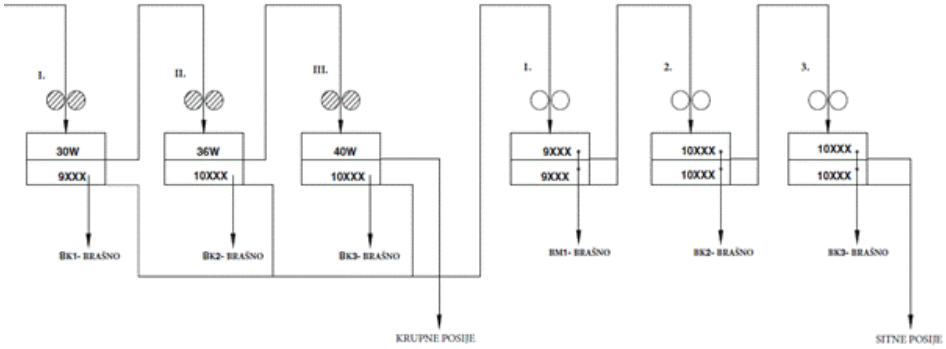
Određivanje staklavosti provedeno je rezanjem 100 zrna pomoću farinotoma te brojanjem potpuno (A), ¾ (B) i ½ (C) staklastih zrna.

Staklavost se izračunava prema formuli:

$$S = A + B + 1/2\ C\ \ (\%)$$

Laboratorijsko mljevenje pšenice

Laboratorijsko mljevenje uzoraka pšenice provedeno je na laboratorijskom mlinu MLU-202 (Bühler, Švicarska) prema metodama AACC 26-10A, 26-21A, 26-31. Mljevenje očišćene i navlažene pšenice (15% vlage) provedeno je prema shemi prikazanoj na **Slici 11**.



Slika 11 Shema mljevenja na Bühler-ovom mlinu (vlastiti izvor)
(BK – Brašno krupljenja, BM – Brašno izmeljavanja, W-žičana presvlaka, XXX-svila)

4. REZULTATI

4.1. REZULTATI ISPITIVANJA GEOMETRIJSKIH ZNAČAJKI I FIZIKALNIH SVOJSTAVA ZRNA PŠENICE

Tablica 2 Rezultati određivanja geometrijskih značajki zrna primjenom računalne analize slike

UZ	P (mm^2)	O (mm)	ZO	F_{max} (mm)	F_{min} (mm)	PVSB	UZ	P (mm^2)	O (mm)	ZO	F_{max} (mm)	F_{min} (mm)	PVSB
1	14,1	16,0	0,68	6,3	3,0	138,3	**30**	13,8	15,6	0,71	5,9	3,2	157,4
2	14,6	16,1	0,71	6,3	3,2	165,0	**31**	16,5	18,5	0,61	6,8	3,2	178,6
3	13,9	15,6	0,72	5,9	3,2	130,5	**32**	16,8	17,3	0,70	6,6	3,4	164,2
4	14,3	16,1	0,68	6,2	3,1	165,5	**33**	15,3	16,6	0,70	6,1	3,4	172,3
5	16,0	17,0	0,69	6,5	3,3	144,7	**34**	15,8	17,5	0,65	6,7	3,2	177,3
6	16,3	17,2	0,69	6,4	3,5	147,5	**35**	14,1	16,3	0,66	6,3	3,1	173,2
7	15,5	17,0	0,67	6,7	3,2	152,3	**36**	13,4	15,8	0,67	6,0	3,1	177,5
8	14,6	16,4	0,68	6,3	3,2	143,2	**37**	14,5	16,6	0,66	6,3	3,2	161,4
9	13,2	16,0	0,64	6,1	2,9	154,8	**38**	14,7	16,6	0,67	6,4	3,2	176,1
10	14,9	16,6	0,67	6,4	3,2	135,9	**39**	14,6	15,6	0,75	5,7	3,4	146,1
11	15,9	17,0	0,69	6,6	3,3	144,4	**40**	15,6	16,7	0,70	6,2	3,4	153,8
12	15,1	16,1	0,73	5,8	3,5	128,2	**41**	14,4	15,8	0,72	6,0	3,3	167,8
13	15,6	16,9	0,68	6,3	3,4	133,7	**42**	14,0	15,8	0,70	5,8	3,2	177,1
14	13,6	15,9	0,68	5,9	3,2	141,0	**43**	14,4	16,0	0,71	6,0	3,3	152,3
15	13,4	15,5	0,69	5,9	3,1	162,4	**44**	16,4	17,4	0,68	6,6	3,4	175,5
16	13,9	15,8	0,70	5,9	3,2	124,7	**45**	15,2	16,5	0,70	6,4	3,3	157,3
17	15,2	16,7	0,68	6,5	3,3	146,7	**46**	16,4	17,6	0,66	6,7	3,3	179,0
18	15,1	16,7	0,68	6,4	3,2	132,1	**47**	16,2	17,0	0,70	6,2	3,5	174,2
19	16,9	17,9	0,66	6,8	3,4	151,4	**48**	17,3	17,8	0,68	6,8	3,4	167,2
20	15,8	16,6	0,72	6,1	3,5	150,2	**49**	16,8	17,7	0,68	6,8	3,5	192,1
21	17,3	17,8	0,69	6,8	3,4	149,7	**50**	17,2	17,7	0,69	6,7	3,5	183,5
22	16,5	17,5	0,68	6,7	3,4	170,2	**51**	14,0	16,3	0,66	6,1	3,1	176,2
23	17,0	17,6	0,68	6,7	3,5	146,1	**52**	14,8	16,5	0,68	6,5	3,2	172,3
24	14,2	16,1	0,68	6,1	3,1	138,1	**53**	16,1	17,1	0,69	6,4	3,4	170,7
25	17,0	17,6	0,69	6,7	3,5	144,8	**54**	17,1	17,4	0,71	6,6	3,5	149,0
26	14,6	16,3	0,68	6,2	3,2	152,1	**MIN**	13,2	15,5	0,64	5,8	2,9	124,7
27	17,4	17,7	0,70	6,7	3,6	135,6	**MAX**	17,4	17,9	0,73	6,8	3,6	183,5
28	14,1	16,0	0,70	5,9	3,3	170,0	$\bar{x}$	15,2	16,6	0,69	6,3	3,3	147,7
29	13,6	16,0	0,67	5,9	3,2	183,5							

UZ-uzorak, P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje

Tablica 3 Rezultati ispitivanja fizikalnih svojstava zrna pšenice standardnim metodama

UZ	IZB (%)	AM (g)	HM (kg/hl)	ST (%)	UZ	IZB (%)	AM (g)	HM (kg/hl)	ST (%)
1	72,0	35,4	80,5	70	**30**	69,7	32,1	80,4	28
2	73,1	33,4	80,1	38	**31**	72,3	32,5	71,6	20
3	67,4	35,0	82,8	76	**32**	70,6	34,7	78,1	40
4	68,6	38,6	77,6	40	**33**	72,2	36,0	75,2	36
5	72,1	39,5	81,4	72	**34**	73,8	32,0	75,4	34
6	70,5	39,3	78,3	52	**35**	71,0	35,2	74,6	30
7	72,5	38,1	81,1	42	**36**	70,8	28,4	73,9	26
8	69,5	37,1	78,4	60	**37**	67,4	31,5	78,7	44
9	71,4	29,5	76,0	34	**38**	70,5	33,2	75,7	26
10	67,9	36,4	82,0	70	**39**	67,9	36,1	78,9	54
11	67,9	37,2	79,8	60	**40**	69,3	30,2	76,3	46
12	70,4	39,1	81,3	86	**41**	70,4	32,6	77,9	20
13	69,5	38,6	79,6	74	**42**	68,3	30,9	76,8	20
14	72,3	35,5	80,9	76	**43**	63,7	32,0	80,5	46
15	72,4	37,3	80,0	54	**44**	68,1	34,9	76,6	16
16	67,2	34,8	83,0	78	**45**	66,8	29,9	77,1	44
17	67,9	37,6	79,9	52	**46**	70,0	35,6	72,7	16
18	72,1	35,5	81,0	68	**47**	70,6	35,7	78,9	20
19	74,6	40,0	79,5	60	**48**	71,5	38,6	77,8	28
20	73,5	40,3	81,6	54	**49**	63,0	37,8	74,4	6
21	70,2	42,6	81,4	48	**50**	72,3	38,0	74,7	14
22	70,4	40,3	77,6	32	**51**	71,4	32,5	75,9	22
23	71,1	40,8	77,6	60	**52**	71,7	35,3	77,9	30
24	70,8	32,2	78,1	56	**53**	75,0	36,0	74,0	30
25	71,7	39,9	81,0	62	**54**	72,3	39,6	79,5	58
26	73,8	35,6	76,6	42	**MIN**	63,0	28,4	71,6	6
27	66,7	42,9	81,7	76	**MAX**	75,0	42,9	83,0	86
28	71,4	31,8	76,7	24	$\bar{x}$	70,4	35,6	78,2	44
29	72,6	29,0	75,5	16					

UZ-uzorak, IZB-izbrašnjavanje, AM-apsolutna masa, HM-hektolitarska masa, ST-staklavost

4.2. KORELACIJSKA MATRICA DOBIVENIH REZULTATA ISPITIVANJA

Tablica 4 Korelacijska matrica rezultata određivanja geometrijskih značajki i fizikalnih svojstava pšeničnog zrna

	P (mm2)	O (mm)	ZO	Fmax (mm)	Fmin (mm)	PVSB	IZB (%)	AM (g)	HM (kg/hl)	ST (%)
P (mm^2)	-	**0,922**	-0,042	**0,829**	**0,830**	0,068	0,046	**0,650**	-0,048	-0,029
O (mm)	**0,922**	-	**-0,419**	**0,928**	**0,609**	0,203	0,135	**0,506**	-0,245	-0,151
ZO	-0,042	**-0,419**	-	**-0,483**	**0,400**	**-0,332**	-0,225	0,151	**0,476**	**0,285**
Fmax (mm)	**0,829**	**0,928**	**-0,483**	-	**0,408**	0,151	0,097	**0,485**	-0,163	-0,106
Fmin (mm)	**0,830**	**0,609**	**0,400**	**0,408**	-	-0,022	-0,057	**0,574**	0,074	0,054
PVSB	0,068	0,203	**-0,332**	0,151	-0,022	-	0,128	**-0,358**	**-0,804**	**-0,945**
IZB (%)	0,046	0,135	-0,225	0,097	-0,057	0,128	-	0,070	-0,167	-0,059
AM (g)	**0,650**	**0,506**	0,151	**0,485**	**0,574**	**-0,358**	0,070	-	**0,428**	**0,429**
HM (kg/hl)	-0,048	-0,245	**0,476**	-0,163	0,074	**-0,804**	-0,167	**0,428**	-	**0,779**
ST (%)	-0,029	-0,151	**0,285**	-0,106	0,054	**-0,945**	-0,059	**0,429**	**0,779**	-

UZ-uzorak, P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje, UZ-uzorak, IZB-izbrašnjavanje, AM-apsolutna masa, HM-hektolitarska masa, ST-staklavost

*podebljani koeficijenti korelacije (*r*) su statistički značajne (*p*<0,05)

4.3. REZULTATI VIŠESTRUKE LINEARNE REGRESIJE

Tablica 5 Statistički parametri prikladnosti modela predviđanja postotka izbrašnjavanja (IZB)

Red. br. varijable	Varijable	MSE	R^2	Korigirani R^2
1	ZO	5,875	0,050	0,032
2	P (mm^2) / O (mm)	5,939	0,059	0,022
3	**P (mm^2) / F_{max} (mm) / F_{min} (mm)**	**5,863**	**0,089**	**0,034**
4	P (mm^2) / ZO / F_{max} (mm) / F_{min} (mm)	5,952	0,094	0,020
5	O (mm) / ZO / F_{max} (mm) / F_{min} (mm) / PVSB	6,068	0,095	0,001
6	P (mm^2) / O (mm) / ZO / F_{max} (mm) / F_{min} (mm) / PVSB	6,196	0,095	-0,021

P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje

*najprikladniji model na osnovi korigiranog koeficijenta determinacije

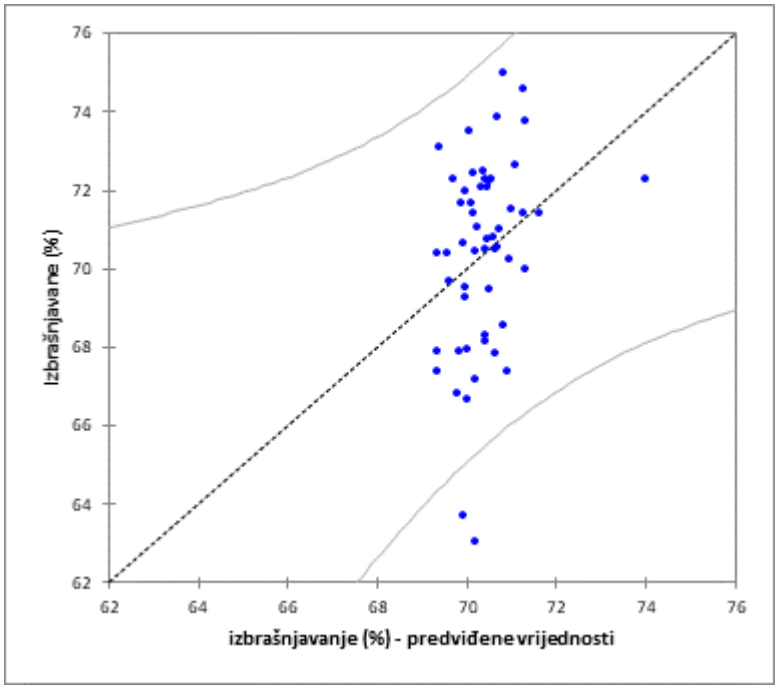
Tablica 6 Analiza varijance

Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*p*
Model	3	28,6202	9,5401	1,6272	0,1948
Pogreška	50	293,1367	5,8627		
Ukupno	53	321,7569			

Tablica 7 Parametri modela

Izvor varijacije	Vrijednost	Standardna greška	t	*p*	-95%	+95%
Odsječak	68,9406	8,2926	8,3135	< 0,0001	52,2845	85,5968
P (mm^2)	0,0000	0,0000				
O (mm)	3,1714	1,6362	1,9383	0,0582	-0,1150	6,4577
ZO	0,0000	0,0000				
F_{max} (mm)	-4,8734	3,2803	-1,4857	0,1436	-11,4621	1,7152
F_{min} (mm)	-6,2767	3,3218	-1,8896	0,0646	-12,9486	0,3953
PVSB	0,0000	0,0000				
Jednadžba modela: **IZB (%) = 68,941+3,171*O (mm)-4,873*Fmax -6,277*Fmin**						

P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje



Slika 12 Podudarnost modelom izračunatih vrijednosti postotka izbrašnjavanja (%) i eksperimentalnih podataka

Tablica 8 Statistički parametri prikladnosti modela predviđanja apsolutne mase (AM)

Red. br. varijable	Varijable	MSE	R^2	Korigirani R^2
1	P (mm^2)	7,378	0,422	0,411
2	P (mm^2) / PVSB	5,399	0,585	0,569
3	P (mm^2) / O (mm) / PVSB	5,374	0,595	0,571
4	**P (mm^2) / O (mm) / ZO / PVSB**	**4,716**	**0,652**	**0,624**
5	P (mm^2) / O (mm) / ZO / F_{min} (mm) /PVSB	4,797	0,653	0,617
6	P (mm^2) / O (mm) / ZO / F_{max} (mm) / F_{min} (mm) / PVSB	4,898	0,653	0,609

P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje
*najprikladniji model na osnovi korigiranog koeficijenta determinacije

Tablica 9 Analiza varijance

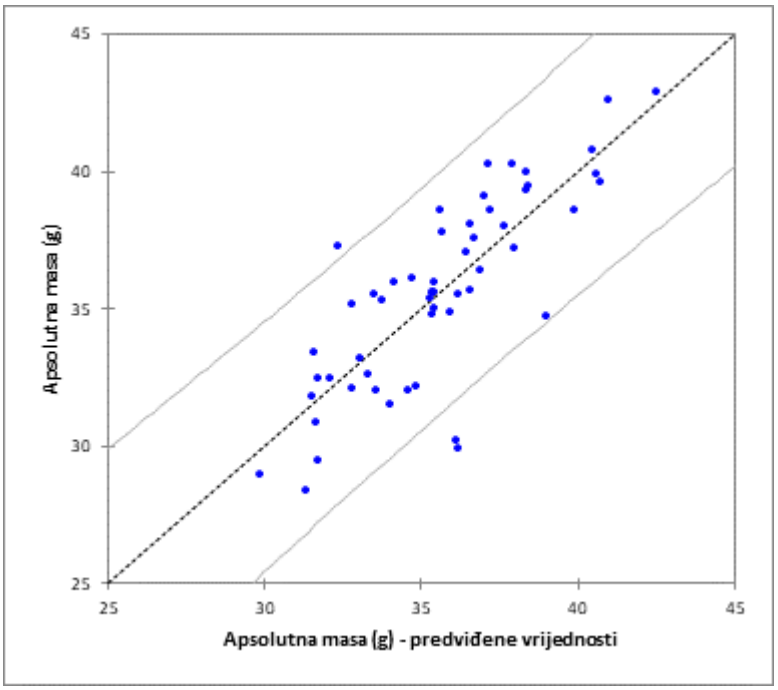
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*p*
Model	4	432,8582	108,2146	22,9455	**< 0,0001***
Pogreška	49	231,0921	4,7162		
Ukupno	53	663,9504			

Tablica 10 Parametri modela

Izvor varijacije	Vrijednost	Standardna greška	t	*p*	-95%	+95%
Odsječak	273,7919	87,2292	3,1388	0,0029	98,4981	449,0856
P (mm^2)	10,6312	2,8932	3,6746	0,0006	4,8172	16,4453
O (mm)	-15,8155	5,2537	-3,0104	0,0041	-26,3732	-5,2579
ZO	-182,5935	64,6759	-2,8232	0,0069	-312,5645	-52,6225
F_{max} (mm)	0,0000	0,0000				
F_{min} (mm)	0,0000	0,0000				
PVSB	-0,0705	0,0193	-3,6543	0,0006	-0,1093	-0,0317

Jednadžba modela: **AM (g) = 273,792+10,631* P (mm2)-15,816* O (mm)-182,594*ZO-0,071*PVSB**

P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje



Slika 13 Podudarnost modelom izračunatih vrijednosti apsolutne mase (g) i eksperimentalnih podataka

Tablica 11 Statistički parametri prikladnosti modela predviđanja hektolitarske mase (HM)

Red. br. varijable	Varijable	MSE	R^2	Korigirani R^2
1	PVSV	2,621	0,646	0,639
2	ZO / PVSB	2,301	0,695	0,683
3	P (mm^2) / O (mm) / PVSB	2,270	0,705	0,687
4	**P (mm^2) / O (mm) / F_{max} (mm) /PVSB**	**2,135**	**0,728**	**0,706**
5	P (mm^2) / O (mm) / ZO / F_{max} (mm) / PVSB	2,179	0,728	0,700
6	P (mm^2) / O (mm) / ZO / F_{max} (mm) / F_{min} (mm) / PVSB	2,225	0,728	0,693

P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje
*najprikladniji model na osnovi korigiranog koeficijenta determinacije

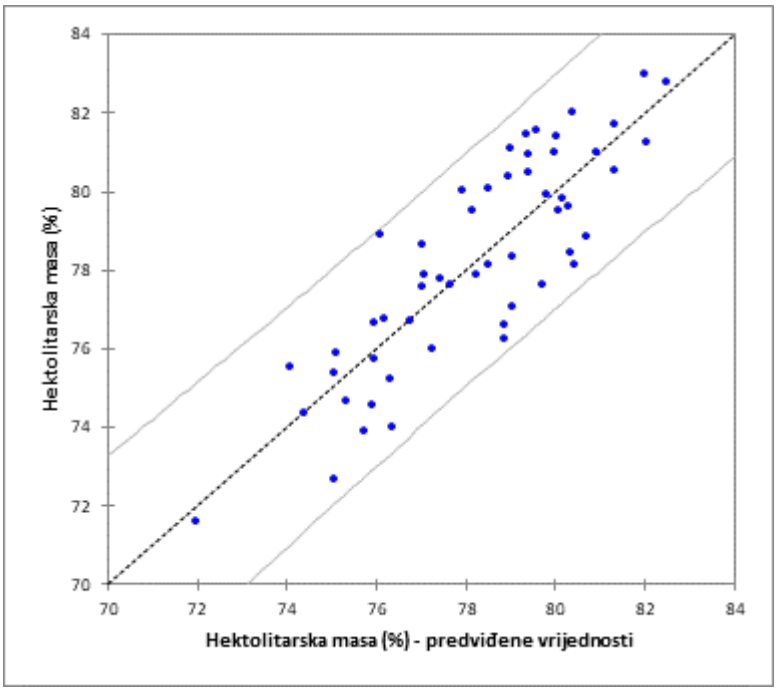
Tablica 12 Analiza varijance

Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*p*
Model	4	280,0609	70,0152	32,7867	**< 0,0001***
Pogreška	49	104,6384	2,1355		
Ukupno	53	384,6993			

Tablica 13 Parametri modela

Izvor varijacije	Vrijednost	Standardna greška	t	*p*	-95%	+95%
Odsječak	119,1779	6,3832	18,6705	< 0,0001	106,3503	132,0054
P (mm^2)	1,5728	0,4548	3,4582	0,0011	0,6588	2,4867
O (mm)	-4,1877	1,1407	-3,6713	0,0006	-6,4799	-1,8955
ZO	0,0000	0,0000				
F_{max} (mm)	3,5151	1,7279	2,0343	0,0474	0,0427	6,9875
F_{min} (mm)	0,0000	0,0000				
PVSB	-0,1096	0,0131	-8,3803	< 0,0001	-0,1359	-0,0833
Jednadžba modela: **HM (kg/hl) = 119,178+1,573*P (mm2)- 4,186*O (mm)+ 3,515Fmax*ZO-0,110*PVSB**						

P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje



Slika 14 Podudarnost modelom izračunatih vrijednosti hektolitarske mase (kg/hl) i eksperimentalnih podataka

Tablica 14 Statistički parametri prikladnosti modela predviđanja staklavosti zrna (ST)

Red. br. varijable	Varijable	MSE	R^2	Korigirani R^2
1	**PVSB**	**44,662**	**0,894**	**0,892**
2	O (mm) / PVSB	44,795	0,895	0,891
3	ZO / F_{min} (mm) / PVSB	44,949	0,897	0,891
4	O (mm) / ZO / F_{min} (mm) / PVSB	45,165	0,899	0,890
5	P (mm^2) / O (mm) / ZO / F_{min} (mm) / PVSB	45,268	0,901	0,890
6	P (mm^2) / O (mm) / ZO / F_{max} (mm) / F_{min} (mm) / PVSB	45,973	0,901	0,889

P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje
*najprikladniji model na osnovi korigiranog koeficijenta determinacije

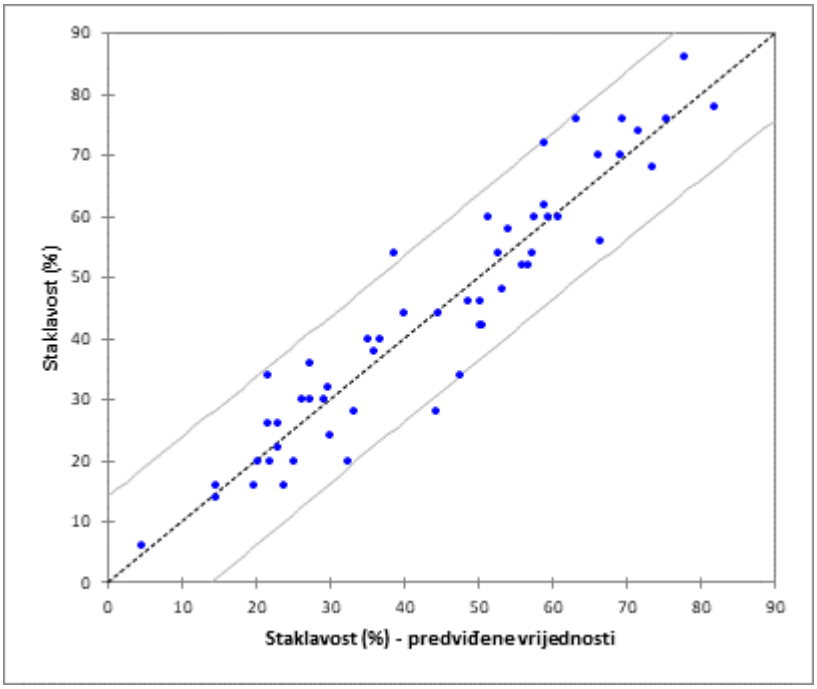
Tablica 15 Analiza varijance

Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*p*
Model	1	19535,7102	19535,7102	437,4097	**< 0,0001***
Pogreška	52	2322,4380	44,6623		
Ukupno	53	21858,1481			

Tablica 16 Parametri modela

Izvor varijacije	Vrijednost	Standardna greška	t	*p*	-95%	+95%
Odsječak	224,9936	8,6929	25,8825	< 0,0001	207,5500	242,4371
P (mm^2)	0,0000	0,0000				
O (mm)	0,0000	0,0000				
ZO	0,0000	0,0000				
F_{max} (mm)	0,0000	0,0000				
F_{min} (mm)	0,0000	0,0000				
PVSB	-1,1466	0,0548	-20,9143	< 0,0001	-1,2567	-1,0366
Jednadžba modela: **ST (%) = 224,994-1,147*PVSB**						

P-površina, O-opseg, ZO-zaokruženost, F_{max}-maksimalni Feretov dijametar, F_{min}-minimalni Feretov dijametar, PVSB-prosječna vrijednost sive boje



Slika 15 Podudarnost modelom izračunatih vrijednosti staklavosti zrna (%) i eksperimentalnih podataka

5. RASPRAVA

Zadatak rada bio je primjenom računalne analize slike ispitati različite geometrijske značajke zrna različitih sorti ozime pšenice (površina, opseg, zaokruženost, dužina i širina, prosječna vrijednost sive boje) te utvrditi njihovu povezanost s različitim fizikalnim svojstvima zrna (postotak izbrašnjavanja, apsolutna masa, hektolitarska masa, staklavost zrna). U istraživanju je korišteno 54 uzorka različitih sorti ozime pšenice roda 2017. godine zasijanih na osječkom i zagrebačkom području.

U **Tablici 2** prikazani su rezultati određivanja geometrijskih značajki zrna primjenom računalne analize slike pomoću programa *ImageJ*. Površina vidljive strane pšeničnog zrna kretala se u rasponu od 13,2 do 17,4 mm, a opseg od 15,5 do 17,9 mm. Zaokruženost, kojom se određuje oblik zrna u odnosu na savršeni krug, uzoraka zrna iznosila je od 0,64 do 0,73 s prosječnom vrijednošću 0,69. Duljina zrna (maksimalni Feretov dijametar) kretala se od 5,8 do 6,8 mm, a širina (minimalni Feretov dijagram od 2,9 do 3,6 mm. Prosječna vrijednost sive nijanse selektiranog područja presjeka zrna iznosila je od 124,7 do 183,5. Ova vrijednost može se kretati u rasponu od 0 (crno) do 255 (bijelo).

U **Tablici 3** prikazani su rezultati ispitivanja fizikalnih svojstava zrna pšenice standardnim metodama. Laboratorijsko mljevenje pšenice provedeno je pomoću laboratorijskog mlina MLU-202 (Bühler, Švicarska), a postotak izbrašnjavanja u odnosu na dobiveno bijelo brašno iznosio je od 63,0 do 75%. Apsolutna masa bila je u rasponu od 28,4 do 42,9 g. 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 i provedenim agrotehničkim mjerama. Hektolitarska masa, kao jedan od važnijih fizikalnih pokazatelja kvalitete pšenice, iznosila je od 71,6 do 83,0 kg/hl, prosječno 78,2 kg/hl. S većom hektolitarskom masom raste i količina brašna koja se može dobiti mljevenjem, ali to ne mora biti pravilo. Hektolitarska masa ovisi o sortnim svojstvima pšenice, klimatskim prilikama pojedine godine, kao i o masenom udjelu vode u pšenici. Također je ovisna o gustoći, krupnoći i obliku zrna te količini i vrsti primjesa. Prosječna vrijednost hektolitarske mase je 75,5 kg/hl. (Klauđerski i Filipović, 1998). Hektolitarsku masu snižavaju mekana brašnasta zrna, velika duguljasta zrna, te debela i hrapava ljuska, a povećavaju ju kompaktna staklasta zrna, potpuno dozrela zrna, ovalna zrna glatke površine, nizak udio vode i tanka ljuska.

Na poprečnom presjeku zrna određivala se staklavost, odnosno struktura presjeka. Staklavost zrna ovisi o udjelu proteina, ona je subjektivan faktor te se uzima kao grubi indeks udjela

proteina u pšenici. Staklasta zrna uglavnom imaju veći udio proteina te tvrdu, kompaktnu strukturu, dok brašnasta zrna imaju bijelu boju na presjeku te mekšu strukturu. Staklavost se kretala u rasponu od 6 do 86% uz prosječnu vrijednost od 44%.

U **Tablici 4** prikazana je korelacijska matrica Pearson-ovih koeficijenata korelacije (*r*) između geometrijskih značajki zrna pšenice određenih primjenom računalne analize slike i rezultata ispitivanja fizikalnih svojstava zrna standardnim metodama. Apsolutna masa značajno je korelirala (p<0,05) s površinom (r=0,650), opsegom (r=0,506) te duljinom (r=0,485) i širinom zrna (r=0,574). Također je utvrđena i značajna negativna korelacija s prosječnom vrijednošću sive boje (r=-0,358). Zaokruženost zrna je bila u značajnoj korelaciji s hektolitarskom masom (r=0,476) i staklavosti zrna (r=0,285). Najznačajnija korelacija utvrđena je između prosječne vrijednosti sive nijanse presjeka zrna i staklavosti zrna (r=-0,945). Veće prosječne vrijednosti sive nijanse ukazuju na bijelu boju presjeka što odgovara brašnastom izgledu, odnosno mekšoj strukturi zrna. S obzirom da staklavost utječe na hektolitarsku masu žita, utvrđena je i značajna korelacija između hektolitarske mase i prosječne vrijednosti sive nijanse (r=-0,804).

U **Tablicama 5-16** prikazani su rezultati izrade modela predviđanja fizikalnih svojstava zrna metodom višestruke linearne regresije. Za izradu modela kao prediktorske varijable upotrijebljeni su površina, opseg, zaokruženost, duljina (F_{max}) i širina(F_{min}) zrna te prosječna vrijednost sive nijanse (PVSB).

Na osnovi korigiranog koeficijenta determinacije kao najprikladniji prediktori postotka izbrašnjavanja pokazali su se površina, duljina i širina zrna (korigirani R^2=0,034). Niska vrijednost korigiranog R^2 ukazuje na slab model predviđanja postotka izbrašnjavanja što je potvrđeno analizom varijance modela (p=0,195) (**Tablice 5 i 6**). To je bilo i očekivano s obzirom na činjenicu da niti jedan od upotrijebljenih prediktora nije bio u statistički značajnoj korelaciji sa izbrašnjavanjem (**Tablica 4**).

U **Tablici 8** prikazani su statistički parametri prikladnosti modela predviđanja apsolutne mase. Najbolji model predviđanja postiže se upotrebom površine, opsega i zaokruženosti zrna te prosječne vrijednosti sive nijanse (R^2=0,624) kao prediktorima, što je potvrđeno i analizom varijance (p<0,0001) čiji su rezultati prikazani u **Tablici 9**.

Analizom varijance utvrđena je i statistička značajnost modela s odabranim prediktorima (p<0,0001) hektolitarske mase (**Tablice 11 i 12**).

Metodom višestruke linearne regresije utvrđeno je da je prosječna vrijednost sive nijanse presjeka zrna (PVSB) najbolji prediktor staklavosti (brašnavosti) zrna (**Tablice 14 i 15**). Korigirani koeficijent determinacije iznosio je 0,892 uz vrlo visoku značajnost modela (p<0,0001).

U **Tablici 16** prikazani su parametri dobivenog modela i pripadajuća jednadžba (Staklavost (%) = 224,994-1,147 x PVSB), a na **Slici 15** podudarnost modelom izračunatih vrijednosti staklavosti i eksperimentalnih podataka.

6. ZAKLJUČCI

Na temelju provedenih ispitivanja 54 uzorka zrna ozime pšenice i provedene korelacijske i regresijske analize može se zaključiti da se primjenom računalne analize slike u određivanju geometrijskih značajki pšeničnog zrna vrlo dobro mogu predvidjeti neka fizikalna svojstva zrna.

Apsolutna masa u korelaciji je površinom, opsegom te duljinom i širinom zrna, zaokruženost zrna s hektolitarskom masom i staklavosti zrna, a prosječne vrijednosti sive nijanse presjeka zrna sa staklavosti zrna i hektolitarskom masom.

Prosječne vrijednosti sive nijanse presjeka zrna najbolji su prediktor staklavosti zrna.

7. LITERATURA

Collins TJ: ImageJ for microscopy. *BioTechniques* 43: 25-33, 2018.

Delcour JA, Hoseney RC: *Principles of Cereal Science and Technology*, Amer Assn of Cereal Chemists. St. Paul, 2010.

Diamond J: *Guns, Germs, and Steel: The Fates of Human Societies*. W. W. Norton & Company, New York, 1997.

Dougherty ER: *Digital Image Processing Methods*. Marcel Dekker Inc., New York, 1994.

Dvorak J, Akhunov ED, Akhunov AR, Deal KR, Luo MC: Molecular characterization of a diagnostic DNA marker for domesticated tetraploid wheat provides evidence for gene flow from wild tetraploid wheat to hexaploid wheat. *Molecular Biology and Evolution* 23:1386–1396, 2006.

Đaković Lj: *Pšenično Brašno*. Tehnološki fakultet, Novi Sad, 1980.

Evers AD, Cox RI, Shaheedullah MZ, Withey: Predicting milling extraction rate by image analysis of wheat grains. *Aspects of Applied Biology* 25: 417–426, 1990.

FAO http://www.fao.org/3/a-i7343e.pdf [6.9.2018.]

Feldman M: Origin of cultivated wheat. *Lavoisier Publishing* 3-20, 2001.

Fuller DQ: Contrasting patterns in crop domestication and domestication rates: Recent archaeobotanical insights from the Old World. *Annals of Botany* 100: 903–924, 2007.

Gonzalez RC, Woods RE: *Digital Image Processing*. Addison-Wesley Publishing Company, Reading, 1992.

Gonzalez RC, Woods RR, Eddins SL: *Digital Image Processing Using Matlab (*2nd ed.). Gatesmark Publishing, Knoxville, 2009.

Gonzalez RC, Woods RR: *Digital Image Procesing*. Addison-Wesley Publishing Co., Boston, 1992.

http://studenti.ptfos.hr/Diplomski_studij/Tehnologija_proizvodnje_i_prerade_brasna/inzenjerstvo/TPPB_1_uvod_16_17.pdf [4.9.2018.]

Igathinathane C, Pordesimo LO, Batchelor WD: Major orthogonal dimensions measurement of food grains by machine vision using ImageJ. *Food Research International* 42: 196-203, 2009.

Ikić I, Mlinar M, Maričević M: Nove sorte ozime pšenice Bc Instituta d.d. Zagreb. *Sjemenarstvo* 30: 35-43, 2014.

Jain AK: *Fundamentals of Digital Image Processing*. Prentice Hall Inc., California,1989.

Jančić Z, Kerkez Z, Miličić I, Matošević G, Raspović R, Pletikosa K: *Digitalna fotografija i osnove obrade: AdobePhotoshop*. Algebra, 2008.

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

Khan K, Shewry P: *Wheat chemistry and technology*. AACC International, Minesota, 2009.

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

Koceva Komlenić D, Jukić M: Materijali s predavanja na kolegiju „Tehnologija proizvodnje i prerade brašna“. Prehrambeno-tehnološki fakultet Osijek, Osijek, 2016.

Kovach MJ, Sweeney MT, McCouch SR: New insights into the history of rice domestication. *Trends in Genetics* 23: 578–587, 2007.

Lukinac Čačić J.: Matematičko modeliranje i optimiranje kinetike promjene boje kruha

Ministarstvo poljoprivrede: *Pravilnik o žitaricama i proizvodima od žitarica*. Narodne novine 81/2016, 2016.

Rapčan I: *Bilinogojstvo sistematika, morfologija i agroekologija važnijih ratarskih kultura*. Poljoprivredni fakultet u Osijeku, Osijek, 2014.

Rasband WS: ImageJ: Image processing and analysis in Java. *Astrophysics Source Code Library*, 2012.

Shahin MA, Symons SJ: Seed sizing from images of non-singulated grain samples. *Canadian biosystems engineering* 47: 3.49-3.54, 2005.

Strgar Kurečić M: *Primjena digitalne fotografije u reprodukcijskim medijima*. Grafički fakultet, 2015.

tijekom pečenja. *Doktorski rad*. Prehrambeno-tehnološki fakultet, Osijek, 2012.

Ugarčić Ž, Koceva Komlenić D, Jukić M, Kosović I, Kuleš A: Upute za laboratorijske vježbe na kolegiju „Sirovine biljnog podrijetla“. Prehrambeno-tehnološki fakultet Osijek, Osijek, 2016.

http://studenti.ptfos.hr/Preddiplomski_studij/Sirovine_biljnog_podrijetla/zitarice/Sirovine%20biljnog%20podrijetla%20skripta.pdf [7.9.2018.]

Web 1: *Hektolitarska vaga*. URL: http://sierkybema.co.za/hectoliter-mass-unit/ [4.9.2018.]

Web 2: *Poprečni presjek staklaste i brašnaste pšenice*. URL: https://www.researchgate.net/figure/Light-microscopy-images-of-cross-cut-sections-of-vitreous-left-and-starchy-kernels_fig1_281573534 [6.9.2018.]

Yam KL, Papadakis SE: A simple digital imaging method for measuring and analyzing color of food surfaces. *Journal of Food Engineering* 61: 137-142, 2004.

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