Računalna analiza slike čajnog peciva s različitim udjelima vode i pogače bundeve

Pavlović, Mateja

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:109:194164

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

Mateja Pavlović

RAČUNALNA ANALIZA SLIKE ČAJNOG PECIVA S RAZLIČITIM UDJELIMA VODE I POGAČE BUNDEVE

DIPLOMSKI RAD

Osijek, travanj, 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 tjestenine i keksarskih proizvoda
Tema rada je prihvaćena na X. redovitoj sjednici Fakultetskog vijeća Prehrambeno-tehnološkog fakulteta Osijek u akademskoj godini 2016./2017. održanoj 13. srpnja 2017.
Mentor: prof. dr. sc. *Daliborka Koceva Komenić*
Komentor: doc. dr. sc. *Jasmina Lukinac Čačić*
Pomoć pri izradi: *Ana Šušak*, dipl. ing., stručni suradnik

Računalna analiza slike čajnog peciva s različitim udjelima vode i pogače bundeve

Mateja Pavlović, 225-DI

Sažetak: Cilj diplomskog rada je ispitivanje utjecaja različitih udjela vode te zamjene dijela pšeničnog brašna pogačom bundeve na parametre boje čajnog peciva. Ispitivanje se provodilo s udjelima vode 7,11% (sW), 9,20% (mW) i 11,30% (eW) i dodacima pogače bundeve u udjelima 20%, 40% i 60%, a navedene smjese su se koristile za izradu čajnog peciva prema standardnoj AACC metodi 10- 50D. Mjerenje boje provedeno je dvjema metodama, računalnom analizom slike te kolorimetrom. Rezultati promjene boje čajnog peciva prikazani su grafički i tablično. Dobiveni rezultati pokazali su da udio vode nema statistički značajan utjecaj na parametre boje čajnog peciva. Kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s različitim udjelom buče postoji statistički značajna razlika, dok među uzorcima čajnog peciva s udjelom buče od 40% i 60% ne postoji statistički značajna razlika. Boja mjerena računalnom analizom slike obuhvaća cjelokupni uzorak te je reprezentativnija i objektivnija za praćenje promjene boje čajnog peciva.

Ključne riječi: čajno pecivo, pogača bundeve, kolorimetar, računalna analiza slike

Rad sadrži: 79 stranica
41 slika
14 tablica
5 priloga
67 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.	prof. dr. sc. *Jurislav Babić*	zamjena člana

Datum obrane: 6. travnja 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 Technology
Subdepartment of grain processing technologies
Franje Kuhača 20, HR-31000 Osijek, Croatia

Graduate program Food Engineering

Scientific area: Biotechnical sciences
Scientific field: Food technology
Course title: Technology of pasta and biscuit production
Thesis subject was approved by the Faculty of Food Technology Osijek Council at its session X. held on July 13, 2017.
Supervisor: *Daliborka Koceva Komlenić*, PhD, full professor
Co-supervisor: *Jasmina Lukinac Čačić,* PhD, assistant professor
Technical assistance: *Ana Šušak*, Mag.Ing.

Digital image analysis of a biscuit with different water content and defatted pumpkin

Mateja Pavlović, 225-DI

Summary: The aim of this research was to investigate the effect of replacing part of wheat flour (20, 40 and 60%) with defatted pumpkin and different water content (7.11, 9.20 and 11.30%). Cookies were produced according to the AACC (American Association of Cereal Chemists) 10-50D method. To determine the colour change of samples digital image analysis and colorimeter were used. Results of the colour changes are shown graphically and in tables. The obtained results showed that the water content did not have a significant influence on the colour parameters of cookies. There is a statistically significant difference in the composition of puree wheat flour and the one with different wheat flour, while there is no statistically significant difference between the 40% and 60% wheat flour samples. The colour of the sample measured by digital image analysis covers the entire sample and is more representative and more objective for colour measurement.

Key words: biscuit, defatted pumpkin, colorimeter, computer image analysis

Thesis contains: 79 pages
41 figures
14 tables
5 supplements
67 references

Original in: Croatian

Defence committee:

1. *Marko Jukić*, PhD, associate professor — chair person
2. *Daliborka Koceva komlenić,* PhD, full professor — supervisor
3. *Jasmina Lukinac Čačić*, PhD, assistant professor — co-supervisor
4. *Jurislav Babić*, PhD, full professor — stand-in

Defence date: April 6, 2018

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

Popis slika

Slika 1. *Rasap svjetlosti na optičkoj prizmi---- 4*
Slika 2. *Vidljivi spektar svjetlosti---- 5*
Slika 3. *Kružna paleta kromatskih boja ---- 6*
Slika 4. *Akromatske boje---- 6*
Slika 5. *Svjetlina boje (0 - 100%)---- 6*
Slika 6. *Zasićenost boje (0 - 100%) ---- 6*
Slika 7. *RGB model boja---- 9*
Slika 8. *Usporedba sRGB i AdobeRGB modela boja----10*
Slika 9. *HSV prostor boja----10*
Slika 10. *CIE XYZ raspon boja ----11*
Slika 11. *CIEL*a*b* prostor boja ----12*
Slika 12. *Kolorimetrijska razlika u CIELAB sustavu ----13*
Slika 13. *Kolorimetar Konica Minolta CR-400 ----16*
Slika 14. *Proces obrade i analize digitalne slike ----17*
Slika 15. *Raspored boja i profilni prikaz Bayerova filtera i senzora ----18*
Slika 16. *Histogram boje na slici ----22*
Slika 17. *Skener EPSON Perfection V500 Photo (a), sučelje programa Epson Scan (b)----28*
Slika 18. *Izgled glavnog menija programa ImageJ----29*
Slika 19. *Primjena algoritma Color Histogram u ImageJ-u ----30*
Slika 20. *Izgled makro naredbe napisane u ImageJ programu ----30*
Slika 21. *Sjemenka buče (Cucurbita maxima L.) ----33*
Slika 22. *Izgled slike čajnog peciva prije i nakon formiranja pravokutnog izreska ----39*
Slika 23. *Segmentacija uzorka primjenom IsoData metode praga i Colour Histograma ----39*
Slika 24. *Prikaz prozora s rezultatima dobivenih ImageJ programom ----40*
Slika 25. *Nastavaka za mjerenja boje praškastih materijala (CR-A50) ----41*
Slika 26. *Vrijednosti svjetline površine čajnog peciva ----48*
Slika 27. *Vrijednosti svjetline donjeg dijela čajnog peciva ----48*
Slika 28. *Vrijednosti kromatske komponente crveno-zelene boje a* površine čajnog peciva ----49*
Slika 29. *Vrijednosti kromatske komponente crveno-zelene boje a* donjeg dijela čajnog peciva ----49*
Slika 30. *Vrijednosti kromatske komponente žuto-plave boje b* površine čajnog peciva ----50*
Slika 31. *Vrijednosti kromatske komponente žuto-plave boje b* donjeg dijela čajnog peciva ----50*
Slika 32. *Promjena boje površine čajnog peciva----51*
Slika 33. *Promjena boje donjeg dijela čajnog peciva----51*
Slika 34. *Vrijednosti svjetline površine čajnog peciva ----57*
Slika 35. *Vrijednosti svjetline usitnjenog čajnog peciva ----57*
Slika 36. *Vrijednosti kromatske komponente crveno-zelene boje a* površine čajnog peciva ----58*
Slika 37. *Vrijednosti kromatske komponente crveno-zelene boje a* usitnjenog čajnog peciva ----58*
Slika 38. *Vrijednosti kromatske komponente žuto-plave boje b* površine čajnog peciva ----59*
Slika 39. *Vrijednosti kromatske komponente žuto-plave boje b* usitnjenog čajnog peciva----59*
Slika 40. *Promjena boje površine čajnog peciva----60*
Slika 41. *Promjena boje usitnjenog čajnog peciva ----60*

Popis tablica

***Tablica 1**. Trisimulusne vrijednosti bijelog standarda CIEXYZ modela boja 16*
***Tablica 2**. Odnos broja bitova i broja mogućih nijansi 26*
***Tablica 3.** Tehničke karakteristike skenera 27*
***Tablica 4.** Postavke skenera 38*
***Tablica 5**. Analiza varijance parametara boje površine čajnog peciva mjerenog računalnom analizom slike 44*
***Tablica 6.** Analiza varijance parametara boje površine čajnog peciva mjerenog računalnom analizom slike 45*
***Tablica 7**. Analiza varijance parametara boje donjeg dijela čajnog peciva mjerenog računalnom analizom slike 46*
***Tablica 8.** Analiza varijance parametara boje donjeg dijela čajnog peciva mjerenog računalnom analizom slike 47*
***Tablica 9.** Analiza varijance parametara boje površine čajnog peciva mjerenog kolorimetrom 53*
***Tablica 10.** Analiza varijance parametara boje površine čajnog peciva mjerenog kolorimetrom 54*
***Tablica 11.** Analiza varijance parametara boje usitnjenog čajnog peciva mjerenog kolorimetrom 55*
***Tablica 12.** Analiza varijance parametara boje usitnjenog čajnog peciva mjerenog kolorimetrom 56*
***Tablica 13.** Koeficijenti korelacije, R i determinacije R^2 utjecaja vrste dodatka na parametre boje 61*
***Tablica 14.** Vrijednosti parametara boje čajnog peciva 61*

Popis priloga

***Prilog 1.** Tablica tisimulusnih referentnih vrijednosti parametara X, Y i Z za različit izvor rasvjete i standardnog promatrača 77*
***Prilog 2**. Prikaz uzoraka čajnog peciva 77*
***Prilog 3**. Kod programa za konverziju boja različitih modela 78*
***Prilog 4.** Izgled sjemenki buče 79*
***Prilog 5.** Različite vrste buče 79*

Sadržaj

1. UVOD ... 1
2. TEORIJSKI DIO ... 3
2.1. BOJA U RAČUNALNOJ ANALIZI SLIKE ... 4
2.2. BOJA ... 4
2.3. POJAVNOST BOJE ... 7
2.3.1. Sustav upravljanja bojom i modeli boja ... 7
2.3.2. Važnost kalibracije i karakterizacije uređaja ... 7
2.3.3. Osnovna podjela sustava (modela) boje ... 8
2.3.5. HSV model boja ... 10
2.3.6. CIE*XYZ* model boja ... 11
2.3.9. CIE *L*a*b prostor boja** ... 11
2.3.10. Transformacija (konverzija) boja iz jednog u drugi model boja ... 12
2.3.12. Uređaji za mjerenje boje ... 14
2.4. KOLORIMETAR ... 15
2.4.1. Izvor svjetla: lampa D65 ... 16
2.5. RAČUNALNA (DIGITALNA) ANALIZA SLIKE ... 17
2.5.1. Formiranje digitalne slike ... 17
2.5.2. Piksel ... 18
2.5.3. Najčešći formati slikovnih datoteka ... 18
2.5.4. Koraci u procesu računalne obrade i analize slike ... 21
2.5.5. Metode segmentacije ... 21
2.6. SKENER I SKENIRANJE ... 24
2.6.1. Građa skenera ... 25
2.6.2. Karakteristike skenera ... 25
2.6.3. Skener korišten u diplomskom radu: EPSON Perfection®V500 Photo Color Scanner ... 27
2.6.4. Programi za obradu slike ... 28
2.7. ČAJNO PECIVO ... 31
2.8. SIROVINE ZA PROIZVODNJU ČAJNOG PECIVA ... 31
2.9. BUČA ... 33
3.1. ZADATAK ... 36
3.2. MATERIJALI ... 36
3.3. METODE ... 36
3.3.1. Proces proizvodnje čajnog peciva ... 36
3.3.2. Mjerenje boje čajnog peciva računalnom analizom slike ... 37

3.3.3. Mjerenje boje čajnog peciva kolorimetrom 40
3.3.4. Statistička obrada rezultata 41
4. REZULTATI 42
4.1. REZULTATI MJERENJA BOJE ČAJNOG PECIVA RAČUNALNOMA ANALIZOM SLIKE 43
4.2. REZULTATI MJERENJA BOJE ČAJNOG PECIVA KOLORIMETROM 52
5. RASPRAVA 62
5.1. REZULTATI MJERENJA BOJE ČAJNOG PECIVA RAČUNALNOM ANALIZOM SLIKE 63
5.2 REZULTATI MJERENJA BOJE ČAJNOG PECIVA KOLORIMETROM 65
6. ZAKLJUČCI 69
7. LITERATURA 71
8. PRILOZI 76

1. UVOD

Boja ima znatan utjecaj na vizualni doživljaj hrane i njenu prihvatljivost od strane potrošača, važno je optičko svojstvo hrane te nije uvijek nužno povezana s nutritivnom vrijednosti, okusom ili funkcionalnim svojstvima hrane (Pedreschi i sur., 2006). Promjena boje hrane pokazatelj je različitih poželjnih i/ili nepoželjnih promjena koje mogu nastati kao posljedica prerade ili kvarenja hrane.

Nastanak boje na površini keksarskih proizvoda tijekom pečenja smatra se poželjnom osobinom, a nastaje kao rezultat reakcija neenzimskog posmeđivanja (Hodge, 1953). Smeđa boja čajnog peciva potječe od melanoidina, netopivog smeđeg pigmenta i karamela koji su produkti reakcija neenzimskog posmeđivanja (Maillardovih reakcija te karamelizacije šećera). U ovim reakcijama mogu nastati i nepoželjni produkti s potencijalnim mutagenim djelovanjem poput akrilamida, hidroksimetilfurfurala i furfurala, a dolazi i do gubitka nutritivne vrijednosti proizvoda (Gökmen i sur., 2007). Tijekom pečenja čajnog peciva promjena početne boje započinje pojavom svijetlih, žutih dekstrina, kada je na površini čajnog peciva postignuta temperatura od 110 do 120 °C (Wahlby i Skjoldebrand, 2002).

Mjerenje boje predstavlja takav postupak vrednovanja boja koji se izvodi vizualnim ocjenjivanjem i instrumentalnim mjerenjem. Kod mjerenja boja potrebno je poznavati njezinu svrhu jer ona određuje način mjerenja i odabir uređaja (instrumenata) za mjerenje. Instrumentalno mjerenje boje koje je precizno definirano mora se provoditi na način da je ono u korelaciji s vizualnom procjenom. Brojni istraživači razvili su različite direktne i indirektne metode mjerenja boje na površini proizvoda. Direktne metode usmjerene su na kvantitativno praćenje produkata Maillardovih reakcija i karamelizacije, dok se indirektne metode zasnivaju na principu mjerenja količine reflektirane svjetlosti s površine analiziranog uzorka uređajima kao što je kolorimetar, a u novije vrijeme i sustav za računalnu analizu slike, što potvrđuju brojna istraživanja (Purlis, i Salvadori 2007, 2009; Purlis 2010, Ramirez-Jimenez i sur., 2000a, b; van Boekel, 1996, 2008).

Čajno pecivo je proizvod dobiven pečenjem oblikovanog masnog tijesta, a sadrži najmanje 10 % masnoće (NN 73/05). Pogača bundeve je nusprodukt proizvodnje bučinog ulja. To je ostatak koji nastaje istiskivanjem ulja iz sjemenki, a koristi se kao stočna hrana iznimno bogata sirovim vlaknima, bjelančevinama, različitim mineralima, aminokiselinama i vitaminima. U diplomskom radu su prikazani rezultati ispitivanja utjecaja različitih udjela vode te zamjene dijela pšeničnog brašna pogačom bundeve na parametre boje čajnog peciva mjerene dvjema metodama, računalnom analizom slike te kolorimetrom.

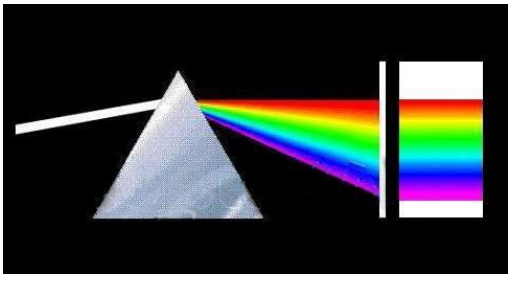
2. TEORIJSKI DIO

2.1. BOJA U RAČUNALNOJ ANALIZI SLIKE

Boja nastaje uslijed refleksije svjetlosnih zraka određenih valnih duljina s površine osvijetljenog objekta. Osvijetljeni objekt pri tome može dio ili ukupnu svjetlost reflektirati, apsorbirati ili propustiti, ovisno o njegovoj prirodi, geometriji i površini, pri čemu se u promatračevom oku stvara dojam određene boje predmeta. Osjet boje u ljudskom oku izaziva elektromagnetsko zračenje valnih dužina od 380 -750 nm. Tako će obojena hrana selektivno apsorbirati vidljivi dio spektra određenih valnih duljina, a propustiti ili reflektirati elektromagnetno zračenje ostalih valnih duljina u tom dijelu spektra. Kada to zračenje dospije u mrežnicu ljudskog oka, ono će izazvati osjet (kromatske) boje. Ljudsko oko može razlikovati i do 10 000 000 boja i njihovih nijansa što varira od čovjeka do čovjeka. Boja ili tekstura nekog objekta uz njegovu geometriju su vizualna obilježja koja predstavljaju primarne izvore informacija za njegov opis. Tekstura i boja se koriste u sustavima računalnog vida u svrhu raspoznavanja slika ili njihovu segmentaciju (Filko, 2013). U tehnološkom smislu boja je predstavlja indikator mogućih anomalija ili oštećenja proizvoda koja nastaju tijekom prerade, proizvodnje i skladištenja (Pedreschi i sur., 2007a, b).

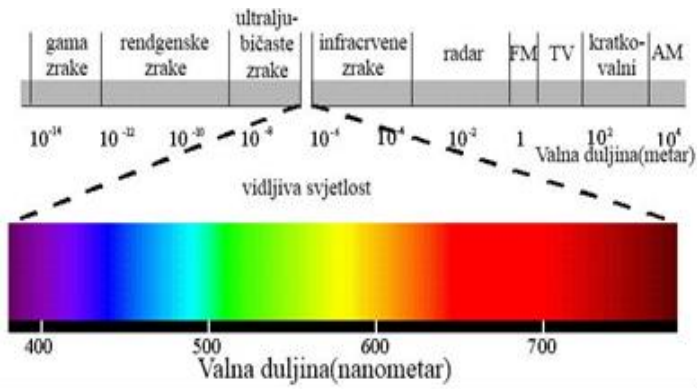
2.2. BOJA

Osjet boje je psihofizički doživljaj koji ovisi o izvoru svjetlosti, psihološkim i fiziološkim uvjetima promatrača i karakteristikama objekta koji se promatra (Lukinac Čačić, 2012). Prvo ozbiljno istraživanje boje zabilježeno je u sedamnaestom stoljeću kada je Sir Isaac Newton otkrio da kada sunčeva svjetlost obasja staklenu prizmu na izlazu iz nje ne dobijemo isto obojanu svjetlost već cijeli spektar bolje od ljubičaste do crvene što je prikazano na **Slici 1** (Filko, 2013).



Slika 1. Rasap svjetlosti na optičkoj prizmi (Filko, 2013)

Na **Slici 2** prikazana je vidljiva svjetlost koja je uzak spektar frekvencija u elektromagnetskom spektru koju ljudi mogu percipirati (Filko, 2013).



Slika 2. Vidljivi spektar svjetlosti (Web 1)

Doživljaj boje ovisan je o tri faktora:

- spektralnom sastavu svjetla koje pada na promatrani predmet,
- molekularnoj strukturi materijala s kojeg se svjetlo reflektira ili koje ga propušta,
- čovjekovim osjetom boje, kroz oči i mozak (Hsien-Che, 2005; Pomeranz i Meloan, 1994).

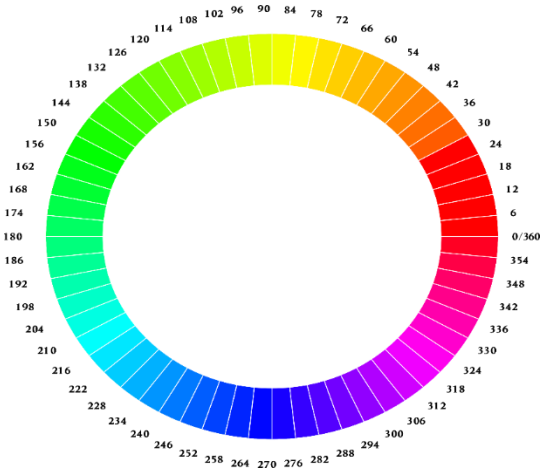
Ono što ljudi i neke životinje percipiraju kao boju je u biti reflektirana svjetlost s površine nekog objekta, zbog čega je karakteriziranje svjetlosti izuzetno bitno za znanost o bojama i korištenje boje u računalnom vidu (Filko, 2013).

Kada opisujemo boju koristimo njena svojstva kao što su:

- h° – ton boje ili tonalnost boje (engl. *hue*)
- S – zasićenost ili saturacija (engl. *saturation*)
- L^{*} – svjetlina ili luminancija (engl. *lightness*).

Ton boje označava vrstu boje te se definira kao kromatska kvaliteta boje, odnosno kvaliteta kojom se jedna boja razlikuje od druge. Ton može poprimiti vrijednosti 0° - 360° koji određuju položaj boje na kružnoj paleti boja. Crvena boja se nalazi na 0° (ili 360°), zelena na 120°, a plava na 240°.

Da bi se objasnili pojmovi zasićenost i svjetlina, najprije je potrebno boje podijeliti u dvije osnovne skupine. U prvoj skupini nalaze se prave boje, kao što su crvena, narančasta, žuta, zelena, plava itd., koje se nazivaju **kromatskim** bojama, ili jednostavno bojama. **Slika 3** prikazuje kromatske boje.



Slika 3. Kružna paleta kromatskih boja (Web 2)

U drugoj skupini boja nalaze se crna, siva i bijela, koje se nazivaju **akromatskim** bojama ili nebojama i čine skalu koja seže od crne, preko sive, do bijele. Na **Slici 4** prikazane su akromatske boje. Neke od kromatskih boja su tamnije ili svjetlije od drugih i moguće je uspoređivati svaki stupanj njihove svjetline sa svjetlinom sive akromatske boje.



Slika 4. Akromatske boje (Web 3)

Svjetlina je osobina kromatske boje koja je usporediva sa svjetlinom sive akromatske boje. Svjetlina se također izražava u postocima 0% - 100%. Vrijednost 0% će dati crnu, a 100% bijelu boju. **Slika 5** prikazuje svjetlinu boje.



Slika 5. Svjetlina boje (0 - 100%) [Web 4]

Zasićenost boje je stupanj čistoće boje, koji se određuje udjelom akromatskih boja (crna, siva, bijela) u kromatskim bojama (crvena, narančasta, žuta, zelena). Zasićenost se izražava u postocima i poprima vrijednosti u postotcima od 0 % do 100 %. Vrijednost 0 % će dati sivu boju, dok će vrijednost 100% predstavljati čistu boju. **Slika 6** prikazuje zasićenost boje (Russ i Neal, 2007).



Slika 6. Zasićenost boje (0 - 100%) [Web 4]

2.3. POJAVNOST BOJE

Pod pojmom **pojavnost boje** podrazumijevamo kako promatrač percipira to jest shvaća neku boju dok pojam **specifikacije boje** apsolutno određuje neku boju što ne znači da dobro opisuje boju točno onako kako ju promatrač vidi. Boja se specificira na način da odredimo njene koordinate u sustavu boja (npr. CIEXYZ, CIE*L*a*b**, RGB). Sustav boja ili model boja je način pomoću kojeg se definiraju, stvaraju i vizualiziraju boje. CAT (eng. *Color adaptation transform*) je metoda kojom se računaju vrijednosti odgovarajuće boje pod referentnim izvorom svjetla za neki podražaj određen pod testnim izvorom svjetla koja se temelji na hipotezi Johannesea von Kriesa (Fairchild, 2013).

2.3.1. Sustav upravljanja bojom i modeli boja

Sustav za upravljanje bojom (*Color Management system*) je programska podrška za kalibraciju i karakterizaciju svih ulaznih i izlaznih uređaja koje koristimo za prikaz boja, te automatsku konverziju boja među njima, s ciljem standardizacije i reprodukcije boja neovisne o korištenom uređaju (Strgar Kurečić, 2007). Korištenje standardiziranog sustava za upravljanje bojom nužno je iz razloga što razni uređaji (digitalna kamera, skener, monitor, printer, tiskarski stroj) drugačije prikazuju boju. Sustav za upravljanje bojom čine:

- Referentni prostor boja (*Profile Conection Space – PCS*, npr. CIE*XYZ,* CIELAB)
- Modul sa algoritmima za usklađivanje boja (*Color Management Module - CMM*)
- ICC profili (Strgar Kurečić, 2007).

Da bi se ostvarila točna reprodukcija boja između dva uređaja, prvo je potrebno vrijednosti boja koje daje uređaj transformirati u model boja neovisan o uređaju (CIELAB ili CIEXYZ), i tek onda iz tog modela boja ponovo napraviti konverziju u "o uređaju ovisan" model boja (RGB).

2.3.2. Važnost kalibracije i karakterizacije uređaja

Za provedbu *Color Managementa*, potrebno je izvršiti pripremne radnje koje uključuju procese kalibracije i karakterizacije uređaja.

- **Kalibracija** je postupak kojim se mijenja način rada uređaja radi postizanja željenog stanja, tj. ponašanja uređaja. Najvažniji razlog provođenja kalibracije je da se način rada uređaja učini stabilnim i konstantnim, tako da profil koji opisuje taj uređaj ostane točan. Jer, ako se način rada uređaja mijenja, onda profil tog uređaja koji je opisivao

način rada prije promjene, više nije točan.

- **Karakterizacija** je postupak kojim se registrira način rada uređaja i stvara profil uređaja. Za razliku od kalibracije, karakterizacijom se ne mijenja način rada uređaja, već se stvara profil koji opisuje ponašanje uređaja. Profil uređaja je datoteka koja povezuje vrijednosti boje (RGB ili CMYK) koje daje uređaj sa vrijednostima neovisnima o uređaju (CIEXYZ ili CIELAB) koje predstavljaju boje koje vidi standardni promatrač. Profil sadrži informacije o tri osnovne varijable koje opisuju ponašanje uređaja; informacije o gamutu, dinamičkom rasponu i informacije o reprodukciji tonova koje uređaj može postići.

Bitno je da se uređaji periodički rekalibriraju, tako da se omogući konstantno produciranje jednakih vrijednosti boja i da ponašanje uređaja bude onakvo kakvo je opisano u profilu. Učestalost kojom se uređaj treba kalibrirati ovisi o tipu uređaja, odnosno o varijablama koje se kalibracijom podešavaju. Kad je uređaj kalibriran, moguće ga je karakterizirati (Strgar Kurečić, 2007).

2.3.3. Osnovna podjela sustava (modela) boje

Modeli (sustavi) boje su trodimenzionalni prikazi boja uz pomoć kojih je moguće pobliže odrediti i vizualizirati sve vidljive boje i one koje se mogu koristiti u određenom reprodukcijskom sustavu.

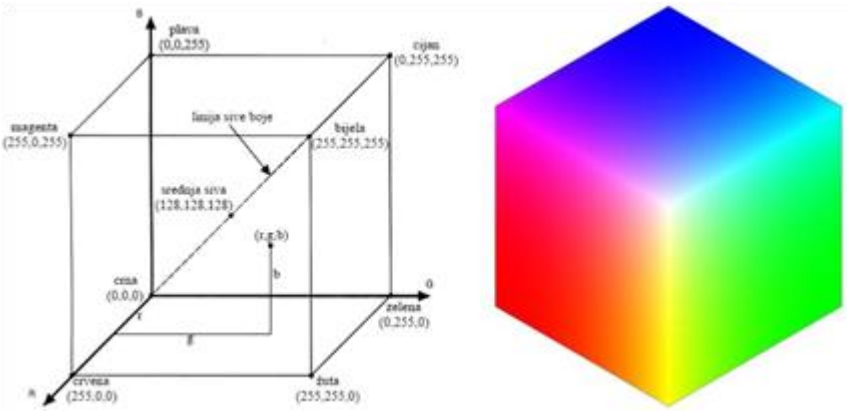
Prema klasifikaciji modeli boje mogu biti podijeljeni u dvije osnovne grupe:

- **aditivni -** modeli boja ovisni o uređaju, kod kojih se boja dobiva zbrajanjem pojedinih komponenti (npr. RGB ili CMY)
- **subtraktivni -** modeli kod kojih se boja dobiva oduzimanjem pojedinih komponenti i oni su neovisni o uređaju (to su CIE prostori boja kao npr. CIEXYZ, CIE*L*a*b** ili CIE*L*u*v**)

Modeli boja koji su **ovisni** o uređaju na kojem se primjenjuju, orijentirani su na fizičke komponente i karakteristike samog uređaja, tj. ovise o kromatskim karakteristikama seta primarnih boja koji se koristi kod procesa bojanja. Prostori boja **neovisni** o uređaju, definiraju boju na bazi percepcije standardnog promatrača, a ne na mogućnostima uređaja.

2.3.4. RGB model boja

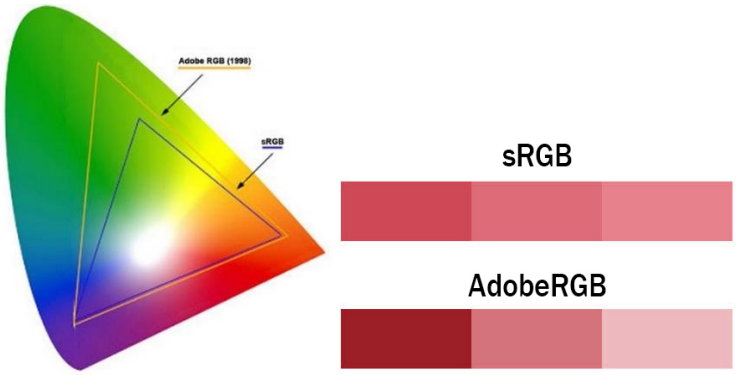
RGB model predstavljen je pomoću kocke, gdje crvena boja predstavlja x-os, zelena boja y-os, a plava boja z-os. Koristi tri primarne boje, crvenu, zelenu i plavu, a njihovim miješanjem nastaju druge boje (sekundarne). RGB je aditivni model, što znači da se boje dobivaju zbrajanjem komponenti. Ako sve tri komponente iznose minimum (0), dobit ćemo crnu boju, a ako sve komponente iznose maksimum (255), dobit ćemo bijelu boju. Različitim kombinacijama pojedinih komponenata dobit ćemo različite boje. Ako su komponente jednake po iznosu, dobit ćemo nijanse sive boje (**Slika 7**). Raspon boja (gamut) je podskup boja unutar određenog prostora boja. Danas je najraširenija upotreba RGB prostora boja koji se temelji na 24 bitnom modelu (8 bita po svakom od tri kanala) koji ima raspon od 16.7 milijuna boja. RGB modeli boja za prikaz boja koriste monitore, digitalne i video kamere, skenere, televizijske uređaje. Međutim, kako RGB varira među uređajima, boja nije uvijek bila prikazana jednako na različitim zaslonima. Postoji više RGB prostora koji se razlikuju po rasponu boja (gamut), bijeloj točci (izvor svjetla koji koristi prostor boja) te primarnim bojama. Najčešći su sRGB i AdobeRGB modeli.



Slika 7. RGB model boja (Web 1)

sRGB model boja (Standard RGB) razvili su Hewlett-Packard, Microsoft za korištenje na monitorima i internetu. sRGB je kalibrirani RGB model koji je prilagođen za veliku većinu računalnih zaslona, operativnih sustava i internet preglednika. Slike na zaslonu koje su određene kao sRGB datoteke, po pitanju boja prikazuju se precizno i točno na većini monitora i televizorima te ga se uvjetno može smatrati neovisnim o uređajima. Upravo radi toga njegova je prednost nad ostalim RGB modelima boja

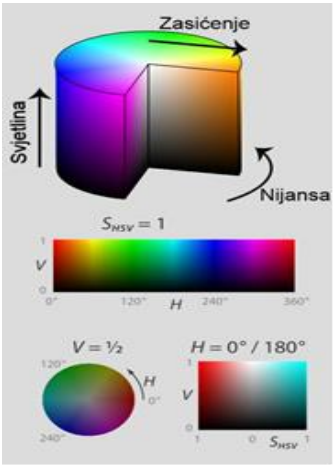
AdobeRGB98 model boja razvila je tvrtka Adobe Systems Inc. 1998. godine za upotrebu u programu Adobe Photoshop. Ovaj prostor boja obuhvaća gotovo sve boje koje se mogu reproducirati u CMYK prostoru printera. AdobeRGB98 prostor ima veći raspon boja od sRGB prostora (**Slika 8**), pogotovo u području zeleno-plavih boja (Stokes i sur., 1996; Sanchez-Cuevas i sur. 2013).



Slika 8. Usporedba sRGB i AdobeRGB modela boja (Web 5)

2.3.5. HSV model boja

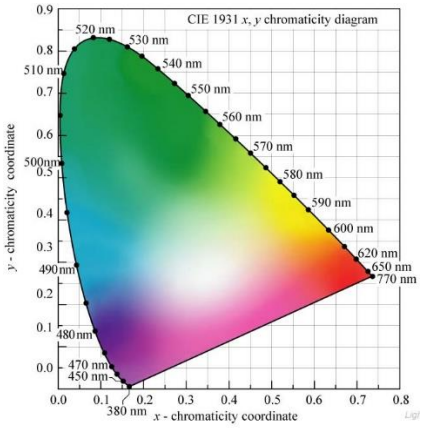
HSV model boja predstavljen je pomoću valjka (**Slika 9**), a često se prikazuje kao stožac ili šesterostrana piramida. Taj prostor boja definiran je s tri koordinate: tonom boje (engl. *hue*), zasićenjem boje (engl. *saturation*) i svjetlinom boje (engl. *value, intensity, brightness*). Ton boje predstavljen je kutom od 0° do 360°. Zasićenost boje ima vrijednost od 0% do 100%. Svjetlina boje ima vrijednost od 0% do 100%. Prednost ovog modela boja je što se radi o relativno jednostavnoj transformaciji RGB modela te se stoga može brzo izvesti i to što je ovaj način opisa boja najsličniji ljudskoj precepciji. Nedostaci su slični kao i kod RGB prostora, a to je da nije perceptualno jedinstven (Filko, 2013).



Slika 9. HSV prostor boja (Web 6)

2.3.6. CIE*XYZ* model boja

CIE*XYZ* model boja je jedan od prvih matematički definiranih modela boja, nastao je 1931. godine od strane organizacije CIE (eng. *International Commission on Illumination*). Razlog njegovog nastanka je da se što bolje opiše model boja koje prosječno ljudsko oko može vidjeti, u odnosu na RGB model boja, koji više ima namjenu opisati boje koje se mogu reproducirati standardnim uređajima ili snimiti kamerom. U ovom modelu boja X se može smatrati linearnom kombinacijom R, G i B boje, Y se može smatrati svjetlinom, dok Z komponenta odgovara donekle plavoj boji. Raspon boja koji se može dobiti XYZ modelom boja je prikazan xy kromatskim dijagramom na **Slici 10** (Filko, 2013).

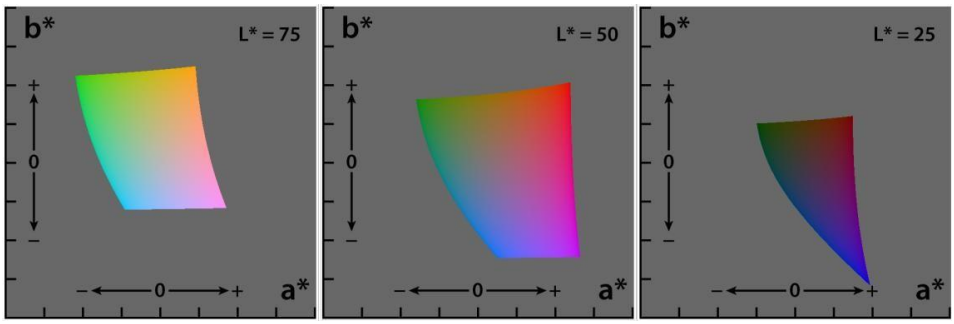


Slika 10. CIE XYZ raspon boja (Web 6)

2.3.9. CIE *L*a*b** prostor boja

CIE*L*a*b** je trodimenzionalni prostor boja baziran na percepciji boje standardnog promatrača, neovisnim o uređaju. Numeričke vrijednosti u CIE*L*a*b** sustavu opisuju sve boje koje može razlikovati svako zdravo ljudsko oko. CIE*L*a*b** prostor boja je opisan pomoću tri komponente: svjetlina (*lightness*), ***L**** koja je akromatska komponenta i dvije kromatske komponente, ***a**** komponenta (u rasponu od -128 do +127) koja je odnos između crvene i zelene boje (negativne vrijednosti označavaju zelenu, a pozitivne crvenu) i ***b**** kromatske komponente (u rasponu od -128 do +127) koja je odnos plave i žute (negativne vrijednosti za plavu, a pozitivne za žutu). Svjetlina se mjeri 0-100 po vertikalnoj osi, gdje je 0=crna, a 100=bijela. **Slika 11** prikazuje CIE*L*a*b** prostor boje (Yam i Papadakis, 2014., Hsien-Che, 2005). CIE*L*a*b** model boja često nalazi primjenu u prehrambenoj industriji i u istraživanjima koja uključuju prisutnost prirodnih pigmenata. Prednost trodimenzionalnog (CIE*L*a*b**)

modela boja pred drugim modelima boje njegova je kompatibilnost s percepcijom ljudskog oka, točnije, udaljenost između dvije točke u koordinatnom sustavu (razlika između dvije boje) izračunava se i definira kao fizikalna vrijednost Δ*E*, koja je ujedno i mjera tolerancije ljudskog oka za razlikovanje boja.



Slika 11. CIEL*a*b* prostor boja (Web 6)

2.3.10. Transformacija (konverzija) boja iz jednog u drugi model boja

Ova metoda podrazumijeva pretvorbu iz RGB u CIE$L^*a^*b^*$ sustav boja u nekoliko koraka (Leon i sur., 2006; Mendoza, 2006; Larrain i sur., 2008).

Normalizacija s*RGB* vrijednosti pri čemu vrijedi $0 \leq R, G, B \leq 1$

$$R = \frac{sR}{255}, \qquad G = \frac{sG}{255}, \qquad B = \frac{sB}{255} \tag{1}$$

$$R' = \left[\frac{R + 0{,}055}{1{,}055}\right]^{2/4} \begin{cases} ako\ je\ R > 0{,}04045 \\ u\ protivnom\ R' = \dfrac{R}{12{,}92} \end{cases}$$

$$G' = \left[\frac{G + 0{,}055}{1{,}055}\right]^{2/4} \begin{cases} ako\ je\ G > 0{,}04045 \\ u\ protivnom\ G' = \dfrac{G}{12{,}92} \end{cases} \tag{2}$$

$$B' = \left[\frac{B + 0{,}055}{1{,}055}\right]^{2/4} \begin{cases} ako\ je\ B > 0{,}04045 \\ u\ protivnom\ B' = \dfrac{B}{12{,}92} \end{cases}$$

$$R_s = R' \cdot 100, \qquad G_s = G' \cdot 100, \qquad B_s = B' \cdot 100 \tag{3}$$

Pri standardnim vrijednostima D65 i 10° vrijedi:

$$\begin{vmatrix} X \\ Y \\ Z \end{vmatrix} = \begin{vmatrix} 0{,}4124 & 0{,}3576 & 0{,}1805 \\ 0{,}2126 & 0{,}7152 & 0{,}0722 \\ 0{,}0193 & 0{,}1192 & 0{,}9505 \end{vmatrix} \cdot \begin{vmatrix} R_s \\ G_s \\ B_s \end{vmatrix} \tag{4}$$

Prema slijedećim formulama **(5-7)** moguće je izračunati *L*, a** i *b** koordinate iz standardnih CIE*XYZ* vrijednosti:

Tisimulusne vrijednosti bijelog standarda CIE1964., D65, 10°

$$X_{ref} = 95{,}811, \qquad Y_{ref} = 100{,}00, \qquad Z_{ref} = 107{,}304 \tag{5}$$

$$X' = \frac{X}{X_{ref}}, \qquad Y' = \frac{Y}{Y_{ref}}, \qquad Z' = \frac{Z}{Z_{ref}}$$

$$X_s = 7{,}787 \cdot X' + \left(\frac{16}{116}\right) \begin{cases} ako\ je\ X' > 0{,}008856 \\ u\ protivnom\ X_s = (X')^{1/3} \end{cases}$$

$$Y_s = 7{,}787 \cdot Y' + \left(\frac{16}{116}\right) \begin{cases} ako\ je\ Y' > 0{,}008856 \\ u\ protivnom\ Y_s = (Y')^{1/3} \end{cases} \tag{6}$$

$$Z_s = 7{,}787 \cdot Z' + \left(\frac{16}{116}\right) \begin{cases} ako\ je\ Z' > 0{,}008856 \\ u\ protivnom\ Z_s = (Z')^{1/3} \end{cases}$$

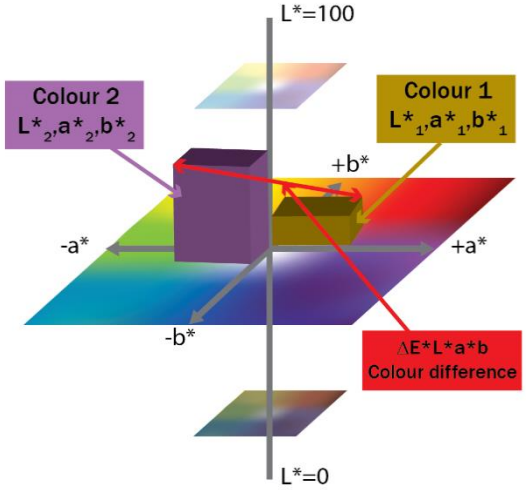
$$L^* = (116 \cdot Y_s) - 16$$

$$a^* = 500 \cdot \left[\frac{X}{X_s}\right]^{1/3} - \left(\frac{Y}{Y_s}\right)^{1/3} \tag{7}$$

$$b^* = 200 \cdot \left[\frac{Y}{Y_s}\right]^{1/3} - \left(\frac{Z}{Z_s}\right)^{1/3}$$

2.3.11. Matematički izrazi za ukupnu razliku boje

Ukupna razlika boja ili kolorimetrijska razlika (Δ*E*) predstavlja razliku između dvije boje u CIE sustavu. Definira se kao euklidska razlika između koordinata za dva položaja boja (referentnog i uspoređivanog) što je prikazano na **Slici 12**.



Slika 12. Kolorimetrijska razlika u CIELAB sustavu (Web 7)

Ukupna razlika boja prema CIE 1976. (Δ*E*) izračunava se slijedećom formulama **(8-11)**:

$$\Delta E = [(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2]^{1/2} \quad \textbf{(8)}$$

$$\Delta L^* = L_1^* - L_2^* \quad \textbf{(9)}$$

$$\Delta a^* = a_1^* - a_2^* \quad \textbf{(10)}$$

$$\Delta b^* = b_1^* - b_2^* \quad \textbf{(11)}$$

gdje se veličine L_1^*, a_1^*, b_1^* odnose na boju kojoj se mjeri odstupanje (uzorak), a veličine L_2^*, a_2^*, b_2^* na referentnu boju (standard). Prema konvenciji, pozitivne vrijednosti pojedinih razlika $\Delta L^*, \Delta a^*, \Delta b^*$, znače da uzorak ima više te varijable nego standard. Na primjer, ako je razlika u svjetlini pozitivna vrijednost($\Delta L^* > 0$) to znači da je uzorak svjetliji od standarda, i obrnuto [CIE 1976]. Koliko je to odstupanje u boji vidljivo/uočljivo za promatrača opisali su Mokrzycki and Tatol (2012) kako slijedi

$0 < \Delta E < 1$	promatrač ne vidi razliku
$1 < \Delta E < 2$	razliku boja primjećuje iskusni promatrač
$2 < \Delta E < 3{,}5$	razliku boja primjećuje i neiskusni promatrač
$3{,}5 < \Delta E < 5$	jasno uočljiva razlika boja
$5 < \Delta E$	promatrač uočava dvije različite boje

2.3.12. Uređaji za mjerenje boje

Boja namirnice prvi je doživljaj kod potrošača prilikom odabira. U tehnološkom smislu boja je svojevrsni indikator mogućih anomalija ili oštećenja proizvoda koja nastaju tijekom prerade, proizvodnje i skladištenja (Pedreschi i sur., 2007a, b). Brojni istraživači razvili su različite metode određivanja boje na površini pekarskih proizvoda. Direktne metode usmjerene su na kvantitativno praćenje produkata Maillardovih reakcija i karamelizacije (AA, HMF i furfurala) (Ramirez-Jimenez, 2000), dok se indirektne metode zasnivaju na principu mjerenja reflektirane količine svjetlosti s površine analiziranog uzorka različitim mjernim uređajima. Na tržištu je dostupno mnogo različitih uređaja za indirektno određivanje boje. Većina njih dizajnirani su tako da se određivanje boje vrši direktnim kontaktom uređaja i uzorka. Uređaji za indirektno određivanje boje koji se često primjenjuju u praksi su (Gokmen i sur., 2008; Purlis i Salvadori, 2007) kolorimetar/kromametar, denziometar, spektrofotometar. Ovi instrumenti uspješno se koriste za određivanje boje homogenih uzoraka. Međutim, glavni nedostatak ovih

mjernih instrumenata je ograničenje u veličini i geometriji uzorka koji je podvrgnut mjerenju (mjere malo područje uzorka). To čini mjerenja prilično nereprezentativnim za heterogene materijale, kakvi su mnogi prehrambenih proizvoda. Stoga je za objektivnu analizu, određivanje boje istog uzorka potrebno provesti na više različitih mjesta na uzorku. U većini slučajeva, povećanje broja mjerenja istog uzorka nije prihvatljiv pristup pogotovo za uzorke nepravilnog oblika (odstupanja u mjerenjima su velika). U novije vrijeme za analizu boje često se koristi sustav za računalnu analizu slike (Brosnan i Sun, 2002, 2004; Zeng i sur., 2007).
Za dobivanje precizne i objektivne informacije o boji, potrebno je primijeniti određivanje boje metodom koja omogućava analizu sveukupne površine uzorka u istom koraku mjerenja. To je osobito važno za primjenu u industriji u kojoj je ujednačenost boje namirnice važna značajka. (Pletney, 2007; Zeng i sur., 2007). Računalna analiza slike može obuhvatiti cjelokupnu površinu uzorka, što ju čini objektivnijom i preciznijom metodom, za razliku od kolorimetra kod kojih je analizirana površina svega nekoliko centimetara (oko 2 cm^2) (Mendoza i sur., 2006).U nastavku biti će opisano mjerenje boje kolorimetrom i računalnom analizom slike.

2.4. KOLORIMETAR

Kolorimetar je uređaj koji mjeri tristimulusne vrijednosti boja (na način sličan ljudskom doživljaju boja), u pravilu podešenom prema krivulji standardnog promatrača. Mjerenje boja kolorimetrom temelji se na uspoređivanju ispitivane boje s bojom nastalom u kolorimetru miješanjem osnovnih boja aditivne sinteze, prema Grassmanovim zakonima. Većina kolorimetara prikazuje vrijednosti u jednom od CIE prostora boja (XYZ, LAB ili LUV). Jedna od najvažnijih prednosti kolorimetra je da omogućava izračunavanje ΔE razlike boja, na temelju razlika u svjetlini, tonu i kromatičnosti. Glavni nedostatak kolorimetra je nemogućnost registriranja metamernih boja. Oni su ograničeni na standardnog promatrača i na samo jedan standardni izvor svjetla (D50 ili D65), pa ne mogu provjeriti vizualno poklapanje boja dva različita uzorka pod različitim izvorima svjetla. U ovom radu korišten je kolorimetar Konica Minolta CR-400 (**Slika 13**).



Slika 13. Kolorimetar Konica Minolta CR-400 (Web 8)

2.4.1. Izvor svjetla: lampa D65

Prosječna dnevna rasvjeta (dnevno svjetlo) temperature boje 6504K. CIE je definirala spektar raspodjele energije zračenja različitih tipova bijelog svjetla i standardizirala vrste svjetlosti (rasvjete). Ta standardizirana vrsta svjetlosti naziva se *illuminat* (Schanda, 2007).

CIE 1931 2° standardni promatrač

Pojam koji označava statistički podatak dobiven nizom mjerenja u kojima su sudjelovali ljudi dobrog vida i bez deformacije viđenja boja. U eksperimentima je sudjelovalo dvadesetak osoba. Cilj je bio odrediti kako promatrač ocjenjuje male vizualne razlike u boji.

CIE 1964 10° standardni promatrač

Eksperiment je ponovljen 1964. godine sa kutom gledanja od 10° čime je definiran CIE 1964 10° standardni promatrač jer je zaključeno da su čunjići u oku smješteni u većem luku (Allen 2011). U **Tablici 1** dane su vrijednosti X, Y i Z bijelog standarda za različite standardne promatrače.

Tablica 1. Trisimulusne vrijednosti bijelog standarda CIEXYZ modela boja (Berns 2000; Kheng 2002)

Izvor svjetla	Standardni promatrač	X	Y	Z
Lampa D65	2°	95,047	100,000	108,883
	10°	94,811	100,000	107,304

2.5. RAČUNALNA (DIGITALNA) ANALIZA SLIKE

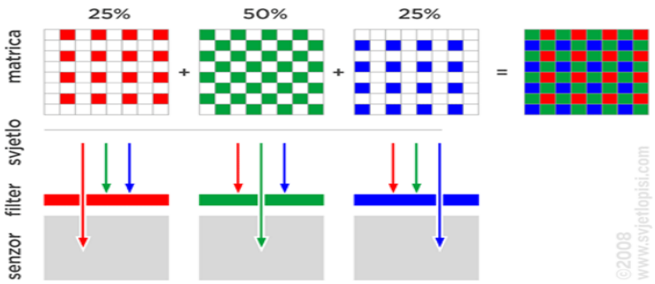


Slika 14. Proces obrade i analize digitalne slike

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

2.5.1. Formiranje digitalne slike

Digitalna fotografija nastaje kada svjetlo kroz objektiv dolazi na fotodiode senzora koji uzima u obzir vrijednost osjetljivosti i propušta signal do sljedeće faze, odnosno interpolacije Bayerovog uzorka, koja će odvojiti signal na osnovne tri RGB boje (crvenu, zelenu i plavu). Bayer iz tvrtke Kodak tvorac je sheme rasporeda RGB filtara u matrici (**Slika 15**). Po toj shemi 50% filtra propušta samo zelenu (G), a po 25% crvenu(R) i plavu (B) komponentu upadnog svjetla. Digitalna slika je niz, mreža ili matrica (*array, matrix*) slikovnih elemenata – piksela. Piksel, tj. svaka ćelija na senzoru pojedinačno registrira samo intezitet svjetla koje je palo na njega. Tek naknadno, uzimajući u obzir vrijednosti okolnih piksela i njihovu poziciju na filtar matrici, određuje se i boja tog piksela i ovaj princip nazivamo Bayerovom interpolacijom (Strgar Kurečić, 2015).



Slika 15. Raspored boja i profilni prikaz Bayerova filtera i senzora (Strgar Kurečić, 2015)

2.5.2. Piksel

Piksel (eng. *Picture Element*) predstavlja najmanji sastavni element digitalne slike. Sadrži brojevnu vrijednost, ili više njih, koja je osnovna informacija slike za određenu koordinatu. Dva su faktora koja u kombinaciji određuju kvalitetu slike: veličina senzora i veličina piksela. Broj piksela određuje količinu detalja u slici i veličinu ispisa. Više piksela znači veću rezoluciju i mogućnost većeg povećanja snimljene fotografije. No rezolucija sama po sebi nije mjerilo tehničke kvalitete slike. Kvaliteta će u velikoj mjeri ovisiti o veličini piksela, to jest veličini fotoosjetljivih elemenata (fotodioda) na senzoru koji generiraju piksele. Udaljenost od centra jedne do centra susjedne fotodiode naziva se ***Pixel pitch***. Mjeri se u mikronima i ovisi o površini senzora i broju piksela na njemu. Na većim senzorima veličina piksela iznosi oko 6,8 – 10 µm, dok je njihova veličina na senzorima manjeg formata oko 2.6 – 3,4 µm. Što su fotodiode na senzoru veće to više fotona svjetla mogu primiti (osjetljivije su na svjetlo), pa senzor ima širi dinamički raspon (raspon od svijetlog do tamnog tona koji može zabilježiti) i ima veći raspon signal/šum (reducira se količina šuma u konačnoj slici). S druge pak strane, što su one veće, na senzoru određenog formata ima ih ukupno manji broj, što znači da je rezolucija senzora manja (Strgar Kurečić, 2015).

2.5.3. Najčešći formati slikovnih datoteka

Svi podaci u računalu spremaju se i obrađuju u binarnom obliku. Način na koji će se boje i oblici sa slike pretvoriti u binarne brojeve zove se format za pohranu slika. **Format zapisa slikovnih datoteka** je standardizirani način organiziranja i pohranjivanja slika. Različiti formati mogu koristiti ili ne koristiti sažimanje (kompresiju, engl. *compression*) podataka i mogu biti s gubitkom ili bez gubitka podataka. **Sažimanje podataka** podrazumijeva pretvorbu podatka u

oblik koji zauzima što manje memorije. Pretvorba bez gubitka podataka pri sažimanju naziva se još i **nezaboravno sažimanje**. Pri takvom postupku pretvorbe svi podaci sadržani u izvornoj slici ostaju sačuvani nakon sažimanja. To znači da je slika pohranjena sa svim svojim dijelovima i da pri pretvorbi nije izgubila ništa na kvaliteti (izgledu). Pretvorba s gubitkom dijela podataka naziva se još i zaboravno sažimanje. Podrazumijeva takvu pretvorbu kod koje se namjerno bespovratno gubi dio podataka. Takvim se postupkom kvari izgled slike, a za uzvrat se dobiva zapis koji zauzima manje memorije. Pri pretvorbi u binarni oblik korisnik može izabrati optimalni omjer između kvalitete izgleda slike i veličine zapisa.

RAW format (sirov format) - format zapisa slikovnih datoteka u kojemu nema gubitka informacija. RAW zapis sadrži sve informacije na slici bez ikakvih obrada odnosno kompresije. RAW format se tako zove zbog toga što slikovne datoteke u RAW formatu nisu obrađene i nisu spremne za izrađivanje. Slikovna datoteka u RAW formatu sadrži minimalno obrađene podatke iz senzora digitalnog fotoaparata, skenera ili film skenera. RAW zapis je znatno veći od ostalih formata, čak i do nekoliko desetaka megabajta što ga čini nezgodnim za spremanje, slanje i slično.

JPEG (engl. *Joint Photographic Experts Group*) - najčešće korišten formata zapisa koji koristi kompresiju podataka s gubitcima, a stupanj kompresije može se regulirati ljestvicom 0-100 što rezultira proporcionalnom gubitku informacija s uštedom kapaciteta pohrane podataka. Time se može smanjiti veličina slikovne datoteke, ali bez značajnog pogoršanja njene kvalitete. Nedostatak JPEG formata je gubitak kvalitete zapisa prilikom svake modifikacije i rezanja, to jest dekompresije i ponovne kompresije. Pored svega ne podržava prozirnost niti animaciju.

BMP (engl. *Bitmap*) - standardni format kojeg podržavaju svi programi za obradu slikovnih datoteka s Windows operativnim sustavom. Kod ovog formata nema kompresije što jamči izvornu kvalitetu slike. Bitmape podržavaju potpunu skalu boje, promjenom veličine BMP datoteke, mijenja se veličina svakog pojedinog piksela što rezultira nejasnim i zamućenim oblicima. Ne upotrebljava se tako često baš zbog svoje nemogućnosti kompresije, ne podržava transparenciju i animaciju. Koristi se za sve namjene od pohrane crteža i jednostavnih slika do pohrane fotografija.

TIFF (*TaggedImageFileFormat*) - format za pohranu slikovnih datoteka, široko podržan od

strane aplikacija za obrađivanje fotografija, izgleda stranice, skeniranje, faksiranje, obradu teksta, optičkih znakova za prepoznavanje i drugih aplikacija. Glavna karakteristika TIFF formata jest da je on fleksibilan, prilagodljiv format za rukovanje slikovnim datotekama i podacima u jednoj datoteci, uključujući i zaglavlja oznaka (veličina, definicija, primijenjena kompresija slikovne datoteke) koja definiraju slikovnu datoteku. Format podržava sažimanje podataka bez gubitaka, ali može pohranjivati i nesažete podatke. Odlikuje se manje izraženim nepravilnostima slike, koristi se za sve namjene od pohrane crteža i jednostavnijih slika do fotografija gdje izvrsno ocrtava sitne detalje. Prednosti formata u odnosu na BMP format je manje zauzeće memorije, a u odnosu na JPEG format kvaliteta slika.

GIF (engl. *Graphics Interchange Format*) - format koristi sažimanje podataka bez gubitaka kvalitete slike. Sažimanjem se zapis pretvara u oblik koji zauzima što manje memorije, ali ne na račun kvalitete slike. Koristi se za pohranu crteža i jednostavnijih slika koje ne sadrže puno prijelaza boja stoga se koristi za pohranu slika koje su fotografije ili imaju u sebi puno boja (ili nijansi sive boje) odnosno prijelaza boja. On ima neke mogućnosti koje drugi formati nemaju, a to su prozirnost tj. transparentnost i animacija.

PNG (engl. *Portable Network Graphics*) - format koji koristi kompresiju podataka bez gubitaka. Podržava transparenciju i koristi 24 ili 32 bit/pix ali ne podržava animaciju. PNG je zamišljen za prijenos slika na internet prosječne kvalitete što ga ne čini najpopularnijim kod profesionalne upotrebe te ne podržava non-RGB prostore boja, kao što je CMYK, te zbog toga nema primjenu u tisku. Usprkos svojoj kvaliteti i prostoru boja, njegova primjena je također ograničena i na webu zbog nekompatibilnosti s mnogim preglednicima. PNG je najkvalitetniji grafički format u RGB prostoru boja.

PDF - format služi da neovisno o softveru, hardveru ili operacijskom sustavu reprezentira informacije ujednačeno onakvima kakve jesu, odnosno bez gubitka informacija. Svaki PDF dokument u sebe ugradi svaki font, tekst, sliku i layout koji je potreban, odnosno one elemente koji su sadržani u prethodnom formatu datoteke, a žele se dalje distribuirati, reproducirati ili otisnuti. Ima mnogo inačica PDF-a koje se razlikuju po pojedinim standardima, prostoru boja i slično (Strgar Kurečić, 2014).

2.5.4. 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, odnosno računalo provjerava pripada li ili ne pojedini piksel grupi odnosno objektu.

4. POSTPROCESIRANJE - u osnovi vezano je 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, složenija obilježja mogu biti povezana s teksturom, oblicima ili pokretima.

2.5.5. Metode segmentacije

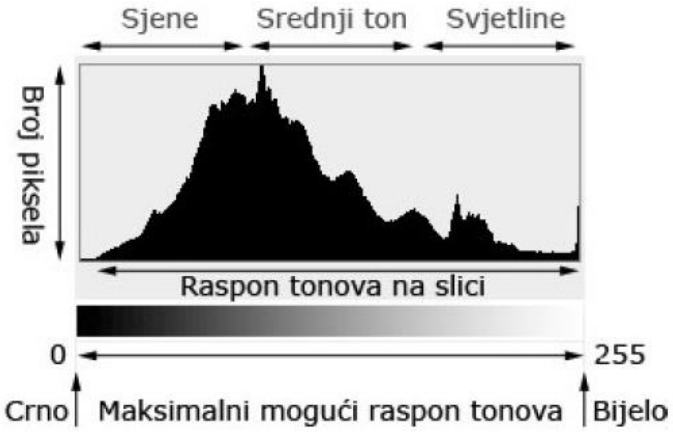
Metode segmentacije mogu se razdijeliti u tri grupe (Gonzalez-Barron i Butler, 2006):

- **određivanje praga** (*thresholding*) – izdvajanje cijelog objekta od pozadine
- **pronalaženje rubova** (*edge-based*)
- **segmentacija bazirana na regijama** (*region-based*)

Ne postoji univerzalna tehnika segmentacije koja će raditi na svim slikama niti je i jedna tehnika segmentacije savršena.

Određivanje praga je jednostavna metoda koja se lako može izvoditi i u realnom vremenu, a kao parametar se koristi intenzitet piksela, I, tj. piksel se smatra dijelom objekta, ako je dovoljno svijetao. Za segmentaciju je potrebno odrediti prag t, kojim će se pikseli odijeliti na objekt i pozadinu. Podjela se izvodi primjenom jednostavnog pravila: ako $I(x, y) > t$, pikseli na (x, y) pripadaju objektu. Odnosno, $I(x, y) < t$, piksel na (x, y) pripada pozadini. Glavni je zadatak, pravilan izbor vrijednosti praga t. Metode određivanja praga baziraju se na analizi oblika histograma (predstavlja relativnu frekvenciju svjetlina točaka u slici) sa rasponom intenziteta piksela I $[0, L-1]$. Najčešće se koristi histogram prvog reda.

Histogram je grafički prikaz raspodjele tonskih vrijednosti snimke (**Slika 16**). Vodoravna os histograma prikazuje tonski raspon od 0 (crno) do 255 (bijelo), a okomita os predstavlja relativan broj piksela u pojedinom tonu. Taj broj nije toliko važan, koliko su važni relativni odnosi po pojedinim dijelovima histograma. Na **Slici 16** prikazan je histogram koji ima tri dijela: pikseli koji predstavljaju sjene, srednji ton i svjetline na slici.



Slika 16. Histogram boje na slici

U ovom radu primijenjena je IsoData metoda praga priliko analize slike u svrhu izdvajanja uzorka čajnog peciva i njegovu analizu boje. **IsoData metoda praga** (*Iterative Self Organizing Dana Analysis Technique*) - je iterativna metoda praga za segmentaciju objekata na slici koju su razvili Ridler i Calvard (1978). Metoda polazi od pretpostavljene početne vrijednosti praga (thresholda). Nakon što je početna vrijednost praga pretpostavljena ona se koristi u iterativnom postupku za raspodjelu piksela prema srednjim vrijednostima u dvije kategorije (one koji predstavljaju objekt i one za pozadinu). Vrijednost praga je postavljena da pada točno na polovici izračunatih srednjih vrijednosti. U novom iterativnom koraku srednje vrijednosti

se ponovno računaju i dobiva se novi prag, te se postupak iteracija nastavlja sve dok se vrijednosti praga počnu ponavljati.

Neka su vrijednosti piksela na histogramu označeni kao: $h(0), h(1), \dots, h(L-1)$, gdje $h(i)$ određuje broj piksela na slici s nijansama sive boje u rasponu od i do $(L-1)$, pri čemu $(L-1)$ predstavlja maksimalnu vrijednost piksela i iznosi 255. Kao početna pretpostavka za t je uzeta vrijednost medijana piksela. Za vrijednosti manje ili jednake t, prosječna vrijednost piksela μ_1 izračunava se kao:

$$\mu_1 = \sum_{i=o}^{t} i \cdot h(i) \Big/ \sum_{i=o}^{t} h(i) \qquad \textbf{(12)}$$

Dok je za vrijednosti veće od t prosječna vrijednost piksela $\mu_2$dana formulom:

$$\mu_2 = \sum_{i=t+1}^{L-1} i \cdot h(i) \Big/ \sum_{i=t+1}^{L-1} h(i) \qquad \textbf{(13)}$$

Vrijednost t ponovno se procjenjuje kao cjelobrojna vrijednost od srednjih vrijednosti μ_1 i μ_2. Iterativni postupak se ponavlja sve dok se za t ne dobiju dva puta uzastopno iste vrijednosti (Gonzalez-Barron i Butler, 2006; Kalavathi 2014).

Segmentacija bazirana na rubovima se zasniva na rubovima pronađenim uz pomoć raznih detektora, ti rubovi označavaju lokacije diskontinuiteta između nijansi, boja, tekstova ili nečega drugoga. Najčešće se problemi kod ove segmentacije javljaju zbog šumova ili drugih vrsta loših informacija o slici a to su da se registrira rub gdje ne postoji ili da se ne registrira gdje on postoji. Granice objekata se mogu izdvajati metodama praćenja granice, interpolacijom krivulje i Houghovom transformacijom. Rubovi su mjesta naglih promjena u vrijednosti točaka slike te je zbog toga moguće koristiti gradijent funkcije za detekciju ruba. Gradijent funkcije dviju varijabli je vektor koji pokazuje smjer najbrže promjene funkcije

$$grad\ f(x,y) = \left[\frac{\partial f(x,y)}{\partial x} \ \ \frac{\partial f(x,y)}{\partial y}\right] = [fx \ \ fy] \qquad \textbf{(14)}$$

Metoda segmentacije zasnovana na regijama ima za cilj identificirati dijelove slike koje imaju slične značajke. Dvije karakteristične metode su: izrastanje područja te metoda dijeljenja i stapanja. Za razliku od prethodnih metoda u kojima su se tražili rubovi između regija ove

metode direktno određuju regije. Ova metoda je pogodnija za slike koje imaju dosta šuma gdje je teško odrediti granice.

2.6. SKENER I SKENIRANJE

Skener (engl. *scanner*) je uređaj koji služi za digitalizaciju fotografija, crteža i transparentnih medija (npr. negativ filma, dijapozitiv, prozirnica). Tri osnovne **vrste** skenera su: ručni, plošni i rotacijski.

- **Ručni** postoje u nekoliko oblika: mali skeneri slični olovci za skeniranje teksta ili crtičnog koda (engl. *bar code*) i uređaji malo veći od miša. Značajke ručnih skenera su niska cijena i relativno niska kvaliteta. Postoje crno-bijeli i u boji, razlučivosti do najviše 400 dpi, a obično imaju najviše 8 bita. Ručni skeneri se danas rabe uglavnom kao čitači crtičnog koda, dok se za digitalizaciju slika više ne rabe.

- **Plošni** skeneri (engl. *flatbed scanner*) su najpopularniji, a zbog činjenice da se drže na stolu pored računala zovu se i stolni skeneri. S gornje strane imaju staklenu plohu na koju se stavlja predložak. Skener ima izvor svjetlosti (ako se radi o reflektivnom predlošku s donje, a ako je riječ o transparentnom predlošku s gornje strane) i optički sustav koji dovodi rezultirajuću svjetlost do fotoosjetljivih elemenata. Stolnih skenera ima crno-bijelih i u boji, a format im je najčešće A4 ili rjeđe A3. Razlučivost stolnih skenera je do 1200 točaka po palcu. Stolni skeneri danas su najrasprostranjenija vrsta skenera.

- **Rotacijski** su skeneri skupi, a razlučivosti su od 2400 do 9600 točaka po palcu. Predložak se lijepi na prozirni šuplji valjak (bubanj) koji rotira i pomiče se u smjeru osi rotacije. Na rotacijskom skeneru mogu se skenirati samo savitljivi predlošci. Rotacijski skeneri rabe se za profesionalnu primjenu gdje je potrebna vrhunska kakvoća skeniranja. Format skenera govori o tome koliko se veliki predložak može odjednom skenirati.

2.6.1. Građa skenera

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.

2.6.2. Karakteristike skenera

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.

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 – mogu biti jednotonski (za tekstualne i jednostavne materijale koji su crno-bijeli), u sivoj skali (za fotografije cijelog raspona svjetline i tonskih prijelaza) te puna boja (koji pohranjuje sve informacije o slici, raspon svjetline i informacije o boji. Za skeniranje fotografija u boji).

Razlučivost skenera je najvažnija značajka skenera i izražava se brojem točaka po palcu (eng. *dots per inch*, ***dpi***). 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.

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 (**Tablica 2**). 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 bitova može imati jednu od mogućih 256 vrijednosti (28=256), odnosno vrijednost od 0 do 255.

Tablica 2. Odnos broja bitova i broja mogućih nijansi

Broj bita (*n*)	Broj nijansi (2^n)	Pojašnjenje
1 bit	2	1 binarna znamenka, 2 moguće kombinacije, 1 ili 0 (bijelo ili crno)
2 bita	4	2 binarne znamenke, 4 moguće kombinacije (crno, tamno sivo, svjetlo sivo, bijelo)
4 bita	16	3 binarne znamenke, 8 mogućih kombinacija
8 bita	256	8 binarnih znamenki, 256 mogućih kombinacija
16 bita	65536	16 binarnih znamenki, 65536 mogućih kombinacija

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 oko 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.

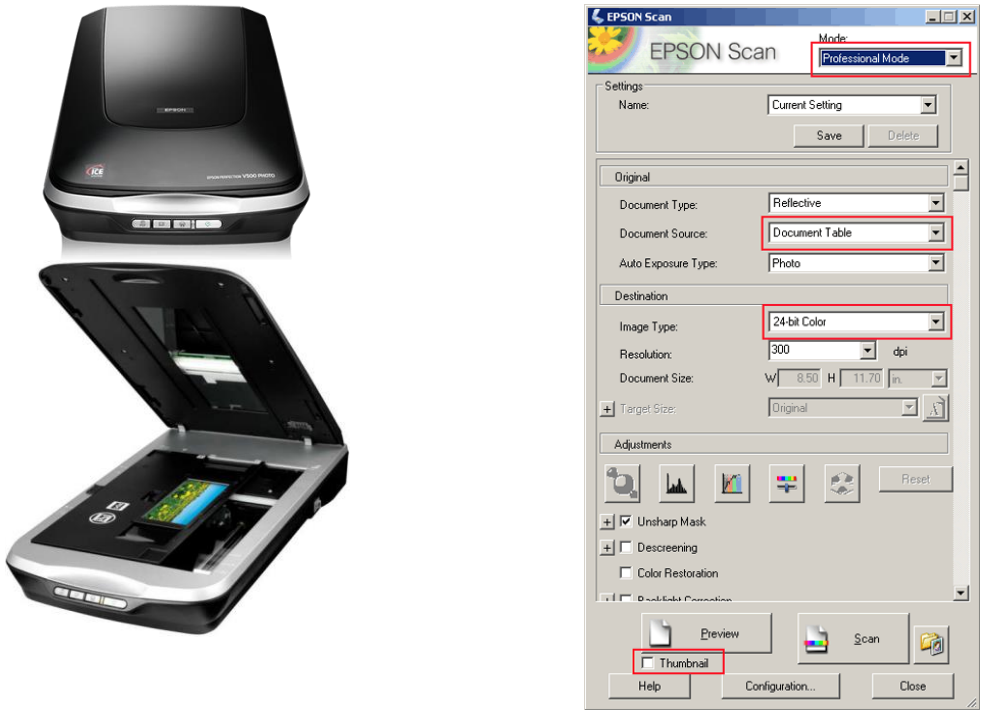
Rezolucija - je mjera za kakvoću slike, a veličina digitalne slike definirana je ***pikselima***. Broj piksela je apsolutna vrijednost, ali oni ovise o uređaju na kojem se prikazuju. Što je rezolucija veća, oku je vidljivo više detalja.

2.6.3. 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 3**, a izgled skenera te sučelje programa korištenog za akviziciju slika prikazani su na **Slici 17**.

Tablica 3. 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 17. Skener EPSON Perfection V500 Photo (a), sučelje programa Epson Scan (b)

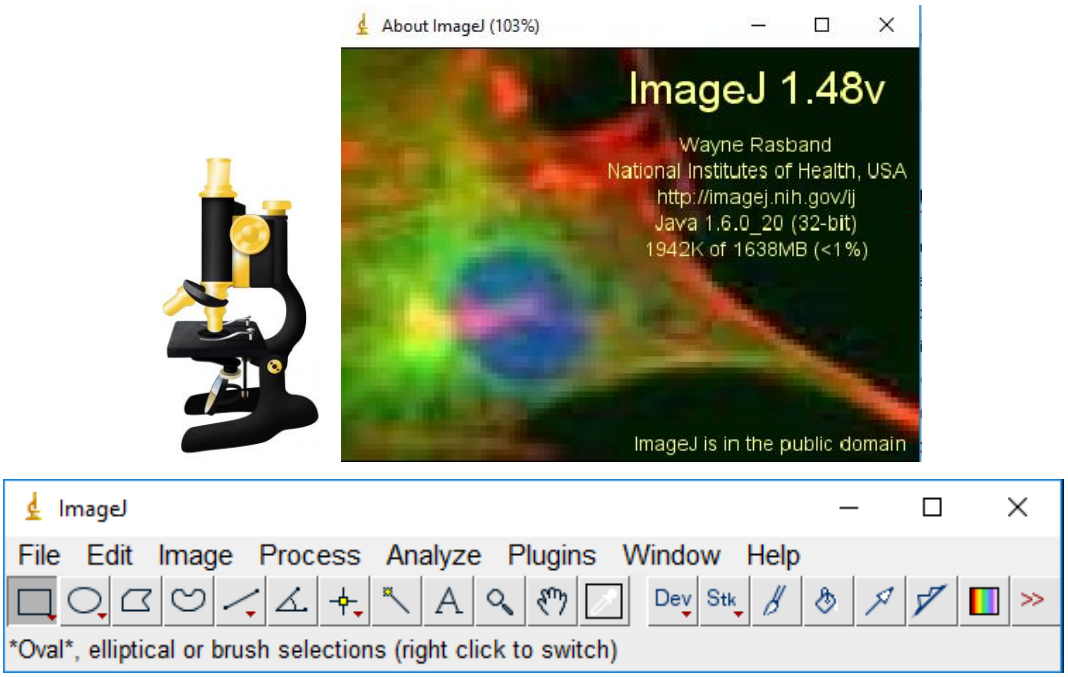
2.6.4. Programi za obradu slike

ImageJ je program otvorenog koda (*opensource*) napisan u Javi. Autor programa je Wayne Rasband (NIH, SAD, Maryland). Program radi kao *online* aplikacija ili kao *dowload* na bilo kojem računalu koji ima instaliranu Java 1.4 ili noviju verziju (**Slika 18**).

Obzirom da je otvorenog koda nudi mogućnost nadogradnje i proširenja pomoću skripti i *plugin*-a, te služi za obavljanje čitavog niza zadataka za obradu slike znanstvenih višedimenzionalnih slika. Program nudi automatizirane, reproducibilne tijekove rada preko skripti i makronaredbi. Ima korisničko sučelje s funkcijama za učitavanje, prikazivanje, analiziranje, i 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.

Mogućnosti koje program nudi su osim standardne obrade slike i određivanje morfoloških karakteristika objekata (površina, volumen, deskriptori oblika), izračunati područje i vrijednost piksela, izmjeriti udaljenosti i kutove, a sadrži i opcije za podešavanje kontrasta, izoštravanje, poravnavanje, kolokalizacija, registracija, segmentacija, praćenje, vizualizacija 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.

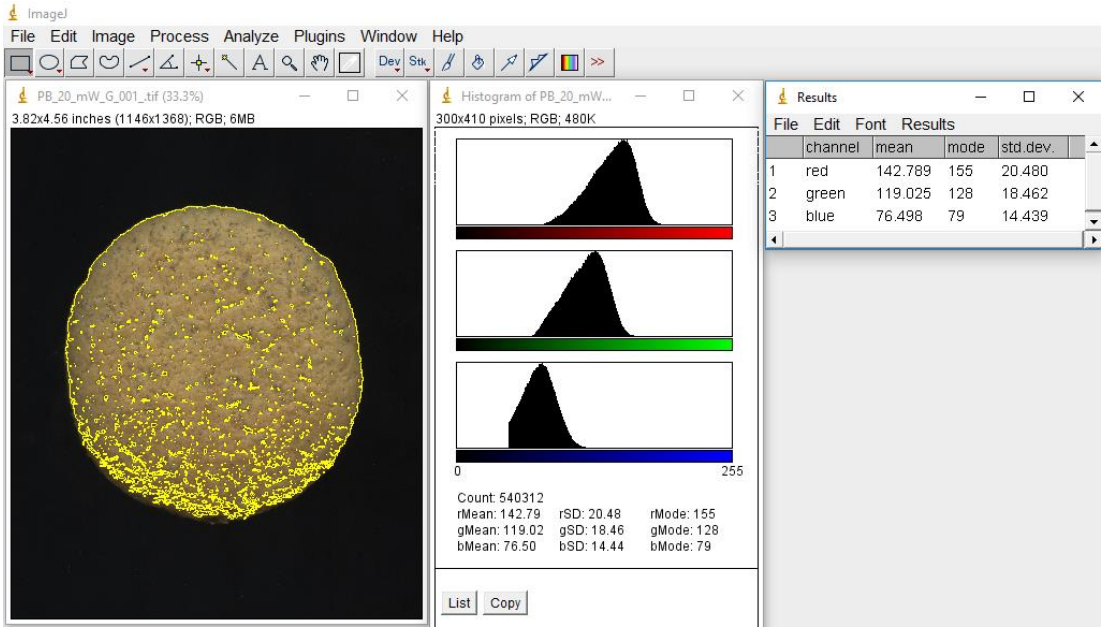


Slika 18. Izgled glavnog menija programa *ImageJ*

Naredba za analiziranje šupljina (engl. *„Analyze Particles“*) mjeri objekte u binarnim ili „*threshold*“ slikama, a radi na principu skeniranja slike sve dok se ne pronađe rub objekta. „*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 algoritama poput *ColorHistogram* za mjerenje boja na slici. Ovom naredbom program prikazuje histograme R, G i B vrijednosti i prosječne vrijednosti piksela svakog kanala boje u tablici rezultata (*Results*). ColorHistogram algoritam može se primijeniti na čitavu sliku ili na definirano područje interesa (ROI) kao što je prikazano na **Slici 19**.

Kako bi se ubrzala obrada slika, te omogućilo automatizirano izvođenje potrebnih operacija nad njima, koriste se makro naredbe. **Makro naredbe** (engl. *macros*) su nizovi naredbi odnosno jednostavni programi koji omogućavaju automatizirano izvođenje funkcija. Zapisani su u .txt datoteci kao „običan” tekst (**Slika 20**), u makro jeziku (baziran na Javi) koji se

interpretira u *ImageJ*-u, te omogućuju implementaciju automatiziranih naredbi povezivanjem postojećih funkcija u *ImageJ*-u.



Slika 19. Primjena algoritma Color Histogram u *ImageJ*-u

```
// "BatchCrop"
   requires("1.33s");
   dir = getDirectory("Choose a Directory ");
   setBatchMode(true);
   count = 0;
   countFiles(dir);
   n = 0;
   processFiles(dir);
   //print(count+" files processed");

   function countFiles(dir) {
              countFiles(""+dir+list[i]);
          else
              count++;
      }
  }

   function processFiles(dir) {
      list = getFileList(dir);
      for (i=0; i<list.length; i++) {
          if (endsWith(list[i], "/"))
              processFiles(""+dir+list[i]);
          else {
             showProgress(n++, count);
             path = dir+list[i];
             processFile(path);
          }
      }
  }

  function processFile(path) {
       if (endsWith(path, ".tif")) {
           open(path);
           //setTool("rectangle");
          makeRectangle(1008, 1038, 1146, 1146);
          run("Crop");
          save(path);
           close();
      }
  }
```

Slika 20. Izgled makro naredbe napisane u *ImageJ* programu

2.7. ČAJNO PECIVO

Fini pekarski proizvodi su proizvodi specifičnih senzorskih svojstava proizvedeni različitim tehnološkim procesima, a sastoje se od mlinskih proizvoda, šećera, masti ili ulja i drugih sastojaka kojima se ističe njihova specifičnost. Čajno pecivo je proizvod dobiven pečenjem oblikovanog tijesta, a sadrži najmanje 10 % masti ili ulja i najviše 5 % vode, računato na ukupnu masu gotovog proizvoda. (Pravilnik, NN 81/2016)

2.8. SIROVINE ZA PROIZVODNJU ČAJNOG PECIVA

Sirovine za proizvodnju čajnog peciva se dijele u dvije osnovne skupine, a to su osnovne i dodatne sirovine. U osnovne sirovine spadaju brašno, voda, masnoće i šećeri, dok u dodatne sirovine spadaju sredstva za narastanje koja su iznimno važna zbog formiranja strukture tijekom pečenja, uz sredstva za narastanje tu su još i aditivi, jaja, i med koji mogu utjecati na reološka svojstva tijesta. Potrebne sirovine za proizvodnju čajnog peciva ovise o recepturi čajnog peciva (Manley, 2000).

Čajno pecivo se može proizvoditi od tvrdog ili mekog zamjesa. Razlika između ova dva zamjesa je u količini dodane vode. Kod mekog zamjesa dodaje se manja količina vode dok je udio masnoće i šećera visoka s toga je tijesto manje rastezljivo i lako puca za razliku od tvrdog zamjesa gdje se dodaje veća količina vode dok su šećer i masnoća u manjem postotku te takva tijesta su rastezljiva i čvršća (Manley, 2000).

Pšenično brašno - u proizvodnji čajnog peciva najčešće korišteni tipovi pšeničnog brašna su T-400 i T-550 (Gavrilović, 2011) s tim da granulacija brašna ima važnu ulogu. Izbor brašna po granulometrijskom sastavu ovisi o sirovinskom sastavu tijesta i načinu mehaničke obrade.

Masnoće - koje se koriste u proizvodnji čajnih peciva mogu biti prirodne, emulgirane ili hidrogenirane. Osim što su odgovorne za plastična svojstva tijesta masnoće smanjuju i skupljanje tijesta tijekom mehaničke obrade jer smanjuju napetosti koje dovode do deformacije oblikovanog komada tijesta. Mast se raspoređuje po česticama brašna i pri tome omogućuje vodi pristup i hidratizaciju proteina i škroba. Porastom temperature tijekom zamjesa, dio masti osobito *shortening* sporo prelazi u tekuću fazu što to povoljno utječe na proces hidratacije. Ako mast nije dovoljno plastična ona se otapa porastom temperature

tijekom zamjesa. Mast u tijestu se nalazi u dodiru s enzimima brašna, kiselinama, sredstvima za narastanje i drugim sirovinama i manjom ili većom količinom vode (Gavrilović, 2003).

Šećer - saharoza se najviše koristi u proizvodnji keksarskih proizvoda. Osim što je daje okus slatkoće utječe i na teksturu i strukturu keksa te na viskoznost tijesta (Hoseney, 1994). U proizvodnji keksa upotrebljava se saharoza različite veličine čestica 50 – 1000 μm (Manley, 1998). Ako je sadržaj vlage u tijestu manji od 25% upotrebljava se šećer u prahu, a što je manja veličina kristala to je veća brzina otapanja (Manley, 1998). Neotopljeni šećer se prilikom pečenja potpuno otapa što pridonosi širenju tijesta (Hoseney, 1994). Osim što smanjuje osmotsku aktivnost vode tijekom zamjesa dolazi i do sporijeg bubrenja glutena, a tijesto se sporije oblikuje (Manley, 1998). O količini dodanog šećera u zamjesu također ovise i tvrdoća, svježina (hrskavost), boja i volumen keksa (Hoseney, 1994).

Voda - u tijestu se nalazi u slobodnom ili vezanom obliku. Vezana voda se nalazi u sastavu glutena dok kapilarnu vodu prima škrob. Upravo visoko-elastična svojstva tijesta ovise o udjelu slobodne vode (Gavrilović, 2011). Za čvrstoću i elastičnost tijesta je važna količina mineralnih tvari vode koja se dodaje tijekom zamjesa. Uloga mineralnih tvari je sprječavanje razgradnje glijadina i bubrenje proteina. Optimalna tvrdoća vode za zamjes je 15 – 20 °nj (Kent i Evers, 1994).

Pekarski kvasac - pekarski kvasac može se koristiti u svježem stanju (oko 70 % vode) ili u suhom aktivnom obliku (Kent i Evers, 1994). Tijekom fermentacije, djelovanjem enzima kvasca dolazi do razgradnje šećera do vode i CO_2 koji u tijestu stvara pore.

Sol - se pekarskim proizvodima dodaje zbog okusa te daje glutenu žilavost što rezultira da se tijesto lakše kida i manje je rastezljivo. Dodaje 1,8 – 2,1 % soli na suhu tvar brašna, što iznosi 1,1 – 1,4 % soli u kruhu. Sol se može dodavati na dva načina: u suhom obliku ili kao vodena otopina (sol otopljena u vodi potrebnoj za zamjes) (Kent i Evers, 1994).

Sredstva za narastanje (rahljenje) - u proizvodnji finih pekarskih proizvoda sredstva za narastanje (rahljenje) se dijele na:

- kemijska sredstva za narastanje (natrijev hidrogenkarbonat, natrijev bikarbonat ili soda-bikarbona ($NaHCO_3$)
- biokemijska sredstva za narastanje (pekarski kvasac *Saccharomyces cerevisiae* u kojem se odvijaju procesi fermentacije)

Kemijska sredstva za narastanje tijesta utječu na promjenu pH sredine tijesta, sprječavaju ljepljivost tijesta te je na taj način moguće stanjivanje tijesta tijekom mehaničke obrade i utječu i na promjenu reoloških svojstava tijesta.

2.9. BUČA

Buča (lat. *Cucurbita pepo* L.) je jednogodišnja zeljasta biljka puzave stabljike ili loze, a pripada porodici *Cucurbitaceae* (tikvovke), rod *Cucurbita*. Buča se može podijeliti prema više karakteristika. Prema stabljici buče se dijele na: *Cucurbita maxima*, *Cucurbita pepo*, *Cucurbita moschata i Cucurbita mixta*. Plodovi prema obliku mogu biti okrugli, eliptični, izduženi, spljošteni ili kruškoliki. Boja kore ploda varira od tamno zelene do svijetlo žute, a može biti glatka ili naborana tj. rebrasta, a meso ploda od jarko žute do tamno narančaste boje. Bučine sjemenke (**Slika 21**) su eliptičnog, spljoštenog, duguljastog, ovalnog oblika s jasno izraženim rubom te čine 1-3 % ploda. Sjemenka je blijedo žute, bijele ili svijetlo smeđe boje kod sorti s ljuskom, a kod golice ili beskorke je zelena, maslinasto zelena ili sivkasto zelena te je ona prikladna za proizvodnju bučinog ulja. Danas se intenzivnije uzgajaju beskorke, jer sadrže više ulja i proteina, a manje celuloze od obične bučine koštice s ljuskom (Jacobo- Valenzuela i sur., 2011).



Slika 21. Sjemenka buče *(Cucurbita maxima L.)* [Web 10]

Bučina pogača je nusprodukt proizvodnje bučinog ulja. To je ostatak koji nastaje po istiskivanju ulja iz sjemenki. Na tržištu se nalaze prutići sjemene pogače, ali pogača se prerađuje i u razne namaze te brašno, te se koristi u konditorskoj i tjesteničarskoj proizvodnji kao bojilo i aromatična supstanca. U pogači zaostaje, ovisno o proizvodnoj opremi i uvjetima

proizvodnje, oko 12% ulja. Po kemijskom sastavu pogača je bogata kvalitetnim proteinima, vitaminima i mineralima te je upravo iz tih razloga ovaj nusproizvod već ima svoju primjenu u ljudskoj prehrani no moguća je još veća primjena (Brkan, 2013). Kemijski sastav varira, ovisno o količini ulja i udjelu ljuske. Postoje sorte bez ljuske koje imaju viši sadržaj proteina u odnosu na sorte s ljuskom. Pogače bez ljuske sadrže oko 49% sirovih proteina i oko 7% sirovih vlakana (Dumovski i Milas, 2004).

3. EKSPERIMENTALNI DIO

3.1. ZADATAK

Zadatak ovog diplomskog rada temelji se na mjerenju parametara boje čajnog peciva tijekom pečenja proizvedenih u laboratorijskim uvjetima primjenom računalne analize slika i kolorimetrom. U tu svrhu korišten je program *ImageJ* 1.48v (Wayne Rasband, National Institute of Health, Maryland, USA). Ispitan je utjecaj različitih udjela vode (7,11% sW, 9,20% mW i 11,30% eW) te zamjene dijela pšeničnog brašna pogačom bundeve (u udjelima 20%, 40% i 60%) na parametre boje čajnog peciva.

3.2. MATERIJALI

Materijali korišteni u istraživanju su:

- Bijelo oštro pšenično brašno TIP-550 („Podravka d.d.“, Koprivnica, 2017.), nabavljeno u lokalnoj trgovini;
- Pogača bundeve – nusproizvod dobiven prešanjem sjemenki bundeve u svrhu dobivanja ulja

3.3. METODE

3.3.1. Proces proizvodnje čajnog peciva

Čajna peciva korištena u izradi ovog diplomskog rada oblikovana su i pečena prema recepturi opisanoj u AACC 10-50D metodi (AACC, 2000a) od sirovina kupljenih u lokalnoj trgovini, te od nusprodukata zaostalih nakon prešanja sjemeni plodova bundeve, odnosno njihove pogače.

Materijal za izradu čajnog peciva:

- 64,0 g shortening-a (margarin) – (udio shortening-a se smanjuje s obzirom na udio masti u pojedinom dodatku)
- 65,0 g šećera
- 2,1 g NaCl
- 2,5 g NaHCO3
- 33,0 g otopine glukoze (8,9 g glukoze otopiti u 150 cm3 destilirane vode)
- 16,0 g vode
- 225,0 g brašna (ili smjese brašna sa 20, 40 i 60% dodatka)

Čajna peciva su oblikovana i pečena prema recepturi opisanoj u standardnoj AACC 10-50D metodi (American Association of Cereal Chemists, 2000). Korišteno je namjensko bijelo brašno

fine pekrske proizvode (Podravka d.d., Koprivnica) i brašno pogače sjemenki buče s udjelom ulja od 32% (ISO 659: 2009) koja je zaostala nakon hladnog prešanja primjenom kontinuirane pužne preše (Moslavac i sur., 2017). Pogača je usitnjena primjenom komercijalnog blendera (Philips HR2860/55, China). Pogača buče korištena je kao zamjena za pšenično brašno u udjelima od 20, 40 i 60%. Ostale sirovine kupljene su u lokalnoj trgovini i uključivale su hidrogeniziranu biljnu mast – „šortening" (Zvijezda d.d., Zagreb, Hrvatska), glukozu, saharozu, kuhinjsku sol (NaCl) i natrijev hidrogenkarbonat ($NaHCO_3$). Povećanjem količine supstitucije pšeničnog brašna pogačom buče udio „šorteninga" se smanjivao s obzirom na udio ulja u pogači i iznosio je 28,4% (računato na količinu brašna) bez dodatka bučine pogače te 22,0% za 20%, 15,6% za 40% i 9,2% za 60% dodatka.

Odvagani „šortening", saharoza, sol i natrijev hidrogenkarbonat stavljeni su u posudu za miješanje elektroničkog miksera (Gorenje MMC800W, Slovenija) i miješani najsporijom brzinom tijekom 3 minute nakon čega su dodani otopina glukoze i destilirana voda, a zamjes se nastavio 1 minutu najsporijom brzinom, te još jednu minutu srednjom brzinom. Zatim je dodano brašno (ili smjesa brašna i usitnjene pogače buče), a miješanje provedeno tijekom 2 minute najsporijom brzinom pri čemu se svakih 30 sekundi sastojci trebaju skidati sa stjenki posude. Nakon zamjesa tijesto je okruglo oblikovano i u PVC vrećici ostavljeno u hladnjaku 60 minuta. Nakon hlađenja i vaganja tijesto je stanjeno razvijačem za tijesto na debljinu 7 mm u dva poteza valjka za tijesto (naprijed-nazad) te izrezano cilindričnim sjekačem u okrugle oblike tijesta promjera 60 mm (~35 g). Oblikovano je po 6 komada tijesta iz svakog zamjesa, a pečenje je provedeno u konvekcijskoj peći (Wiesheu Minimat Zibo, Wiesheu GmbH, Njemačka) tijekom 10 minuta pri 205 °C s preciznošću od ±1 °C.

3.3.2. Mjerenje boje čajnog peciva računalnom analizom slike

Boja uzoraka čajnog peciva mjerena je na sirovim (tijesto) i pečenim uzorcima, na površini i donjem dijelu uzoraka te su dobiveni rezultati u RGB modelu boja. Mjerenje boje računalnom analizom slike provedeno je u nekoliko koraka:

- ***Akvizicija (digitalizacija) slike – skener***
- ***Obrada i analiza slike – računalo, programska oprema***
    - segmentacija *IsoData* metodom praga
    - analiza boje (intenzitet R, G i B vrijednosti) primjenom naredbe *color histogram* (amplitudna segmentacija)

Uzorci su digitalizirani pomoću stolnog skenera u boji EPSON Perfection® V500 Photo (SEIKO EPSON, Japan) programom EPSON Scan (Ver. 3.74EN). Skener je smješten u tamnu komoru, u kontroliranim uvjetima rasvjete, te je uzorak osvijetljen ugrađenim donjim izvorom LED svjetlost (*ReadyScan* LED). Osvjetljenje skenera je nepromjenjivo i kreće se ispod objekta, zajedno sa senzorom. Na staklenu plohu skenera stavljani su uzorci čajnog peciva te su skenirani u rezoluciji od 300 dpi, dubini boje 24-bita i dinamičkom rasponu 3.4, u RGB modelu boja i spremljene u TIFF formatu. Detaljne postavke skenera dane su u **Tablici 4**.

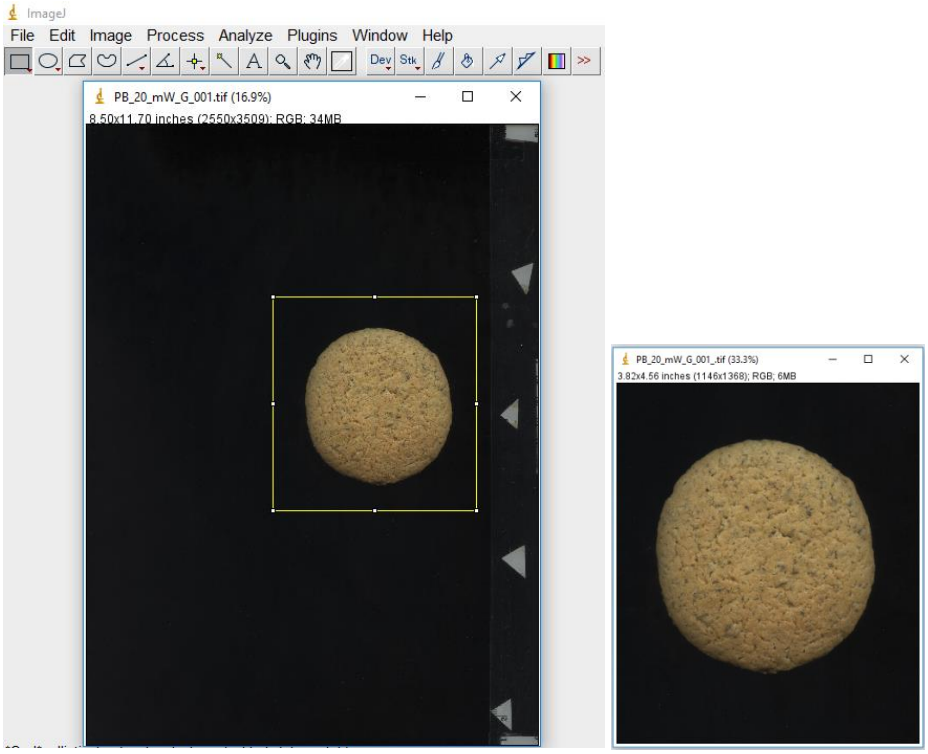
Nakon prihvata i digitalizacije slijedi obrada i analiza digitalne slike programom *ImageJ.* Prvi korak u obradi slike bio je kreiranje izreska dimenzija 1146x1146 pixela sa originalne slike (dimenzija 2550x3509 pixela) što je prikazano na **Slici 22**. Izresci su spremljeni u novu mapu te je na njima uzorak segmentiran primjenom IsoData metode praga (razdvojeni su uzorak od pozadine)[Ridler, 1978., El-Zaart. 2010].

Nakon segmentacije i uklanjanja pozadine slijedi analiza boje čajnog peciva. Primjenom metode amplitudne segmentacije (*amplitude thresholding*) i histograma prvog reda (*color histogram*), dobiveni su rezultati relativne frekvencije svjetlina točaka u slici (RGB vrijednosti točaka u slici) što je prikazano na **Slici 23** i **Slici 24**.

Kako bi se automatizirala i ubrzala analiza slike, napravljeno je nekoliko makro naredbi, prva *BatchCrop.txt* za kreiranje pravokutnog izreska sa originalne slike te program kreira nove slike s kojih je izrezan veći dio pozadine koja nije relevantna za obradu slike (**Slika 20**).

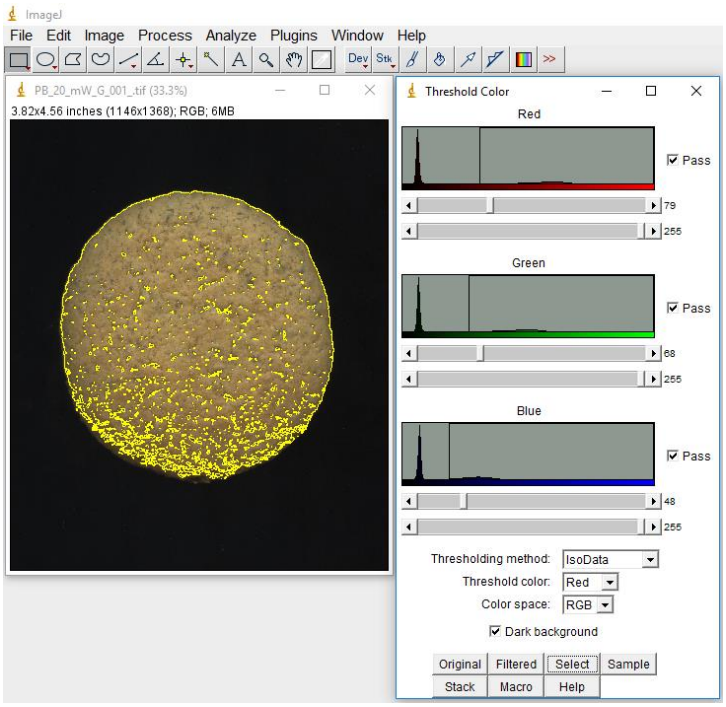
Tablica 4. Postavke skenera

Vrsta skenera	Stolni skenere (*flatbed skenner)*
Optički senzor	Color Epson MatrixCCD™
Izvor svjetla	Bijela LED lampa s ReadyScan™ LED tehnologijom
Optička rezolucija	300 dpi
Način skeniranja	Puna boja
Dubina boje	24 bit boja
Model boja	sRGB
Brzina skeniranja	16,98 msec/line
Tonska gustoća (dinamički raspon)	3,4 Dmaks.
Raspon skeniranja (maksimum)	216 x 297 mm
Način rada skenera	Reflektivan način skeniranja
Izlazni format slike	TIFF
Priključci	USB 2.0 tipa B
Programska podrška	Epson Scan

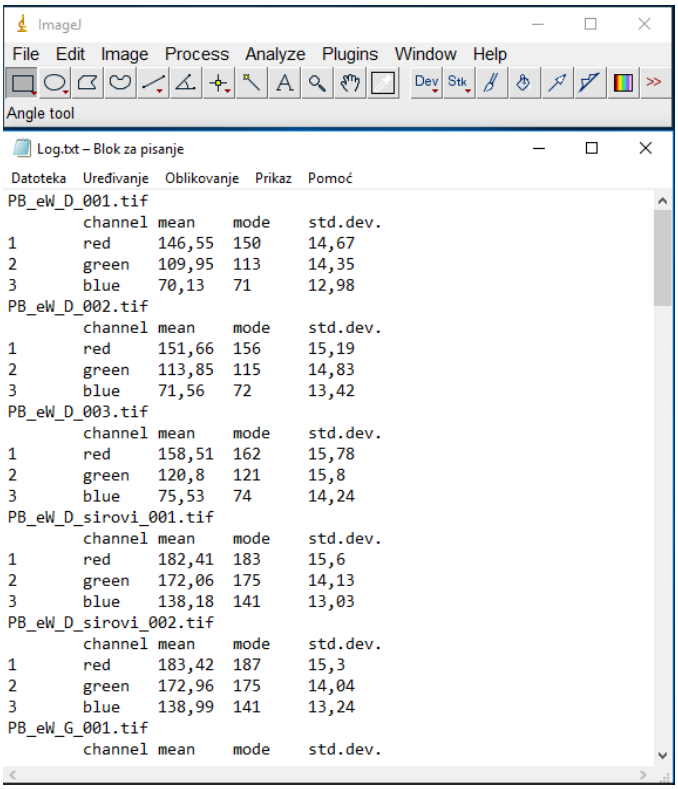


Slika 22. Izgled slike čajnog peciva prije i nakon formiranja pravokutnog izreska

Druga makro naredba *BatchTresholdSelectionISO.txt.* kojom se definira područje interesa na slici (izdvajanje uzorka od pozadine) metodom praga IsoData i treća makro naredba *BatchColorHistogram.txt,* za dobivanje rezultata primjenom algoritma ColorHistogram (**Slika 22**). Dobiveni rezultati (**Slika 23**) histograma boje spremaju se u .txt datoteku te sadržavaju vrijednosti boja RGB modela (**Slika 24**).



Slika 23. Segmentacija uzorka primjenom IsoData metode praga i Colour Histograma



Slika 24. Prikaz prozora s rezultatima dobivenih *ImageJ* programom

3.3.3. Mjerenje boje čajnog peciva kolorimetrom

Boja uzoraka čajno peciva mjerena je kolorimetrom (Konica Minolta Chroma Meter CR-400) te su rezultati mjerenja boje prikazani CIE*L*a*b** modelom boja. Uređaj se sastoji od mjerne glave s otvorom mjernog promjera 8 mm kroz koji pulsirajuća ksenonska lampa baca difuzno svjetlo okomito na površinu uzorka. Reflektirana svjetlost s površine uzorka detektira se pomoću šest osjetljivih silikonskih fotoćelija. Vrijeme mjerenja je 1 s sa minimalnim intervalom između mjerenja 3 s. Neposredno prije svakog mjerenja uređaj je kalibriran pomoću standardne bijele keramičke pločice (CR-A43).

Boja uzoraka čajnog peciva mjerena je na 5 različitih mjesta na površini (sirovog i pečenog uzorka) te na usitnjenim i homogeniziranim uzorcima korištenjem komore za praškaste uzorke (CR-A50) prikazane na **Slici 25**. Mjerenje je provedeno u 5 paralela na svim uzorcima. Prema izmjerenim vrijednostima boje čajnog peciva CIE*L*a*b** izračunata je i ukupna promjena boje (ΔE).



Slika 25. Nastavaka za mjerenja boje praškastih materijala (CR-A50) [Web 9]

Konačni rezultati mjerenja boje u eksperimentalnom dijelu ovog rada bazirani su na CIE*L*a*b** modelu boja. RGB signali generirani pri skeniranju transponiraju se u CIE*L*a*b** model boja, dok je boja mjerena kolorimetrom generirana u CIE*L*a*b** modelu boja. Transponiranje vrijednosti boja između RGB i CIE*L*a*b** modela boja napravljena je u nekoliko koraka. Prvi korak je prevođenje RGB vrijednosti u CIE*XYZ*, a potom se dobivene vrijednosti CIE*XYZ* prevode u CIE*L*a*b** model boja što je detaljno pisano u 2.3.10. ovog rada.

3.3.4. Statistička obrada rezultata

Rezultati mjerenja boje prikazani su kao CIE*L*a*b** parametri boje te kao ukupna promjena boje ili kolorimetrijska razlika (Δ*E*) između dvije boje u CIE sustavu (referentnog i uspoređivanog). Detaljan opis i način izračuna ukupne razlike boja dan je u poglavlju 2.3.10. Dobiveni rezultati su prikazani kao srednja vrijednost ± standardna devijacija. Analiza varijance (ANOVA) i Fisher-ov LSD test najmanje značajne razlike (engl. *Least significant difference*) provedeni su upotrebom programa Statistica 12 (Stat Soft Inc. Tulsa, SAD).

4. REZULTATI

4.1. REZULTATI MJERENJA BOJE ČAJNOG PECIVA RAČUNALNOMA ANALIZOM SLIKE

Eksperimentalni podaci mjerenja boje dobiveni računalnom analizom slike prikazani su tablično **Tablicama 5 - 8** i grafički **Slikama 26 - 33** kao parametri CIE*L*a*b** modela boja i kao ukupna promjena boje (Δ*E*) na površini i donjem dijelu uzoraka čajnog peciva. U **Tablici 6 i 8** prikazan je utjecaj udjela vode (7,11% sW, 9,20% wW i 11,30% eW) na parametre boje (*L*, a*, b** i ΔE_{CVS}), a na **Slikama 26 - 33** i **Tablicama 5 i 7** prikazan je utjecaj udjela dodatka pogače buče (0%, 20%, 40% i 60%) na parametre boje (*L*, a*, b** i ΔE_{CVS}) mjerene računalnom analizom slike. Prikazani podaci su srednja vrijednost ± standardna devijacija; vrijednosti označene istim slovima nisu statistički značajno različite (p<0,05) prema Fisher-ovom LSD testu najmanje značajne razlike.

Tablica 5. Analiza varijance parametara boje površine čajnog peciva mjerenog računalnom analizom slike

Analiza varijance za parametar ***L**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	1128,617	376,206	256,761	< 0,0001
Pogreška	32	46,886	1,465		
Ukupno	35	1175,503			
Analiza varijance za parametar ***a**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	26,832	8,944	18,255	< 0,0001
Pogreška	32	15,678	0,490		
Ukupno	35	42,510			
Analiza varijance za parametar ***b**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	77,408	25,803	94,016	< 0,0001
Pogreška	32	8,782	0,274		
Ukupno	35	86,190			
Analiza varijance za parametar ΔE_{cvs} čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	353,777	117,926	52,305	< 0,0001
Pogreška	32	72,146	2,255		
Ukupno	35	425,923			

Tablica 6. Analiza varijance parametara boje površine čajnog peciva mjerenog računalnom analizom slike

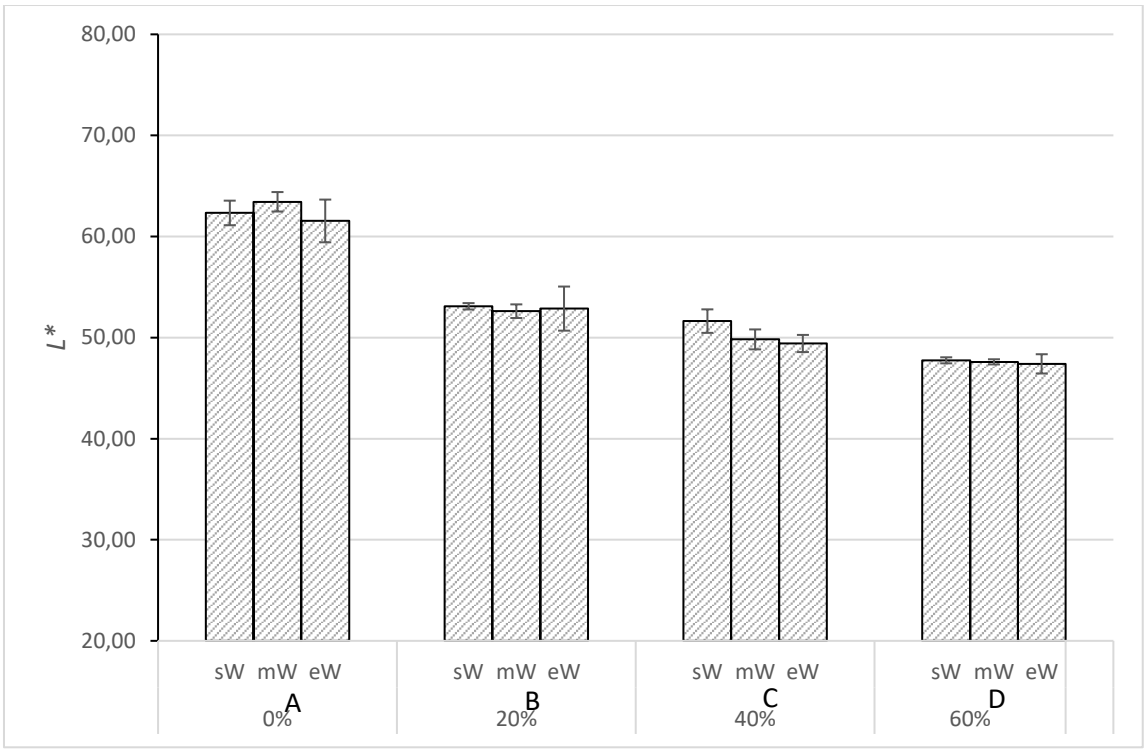
Analiza varijance za parametar ***L**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	4,922	2,461	0,069	0,933
Pogreška	33	1170,581	35,472		
Ukupno	35	1175,503			
Analiza varijance za parametar ***a**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	0,425	0,212	0,167	0,847
Pogreška	33	42,086	1,275		
Ukupno	35	42,510			
Analiza varijance za parametar ***b**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	0,118	0,059	0,023	0,978
Pogreška	33	86,073	2,608		
Ukupno	35	86,190			
Analiza varijance za parametar ΔE_{cvs} čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	19,902	9,951	0,809	0,454
Pogreška	33	406,021	12,304		
Ukupno	35	425,923			

Tablica 7. Analiza varijance parametara boje donjeg dijela čajnog peciva mjerenog računalnom analizom slike

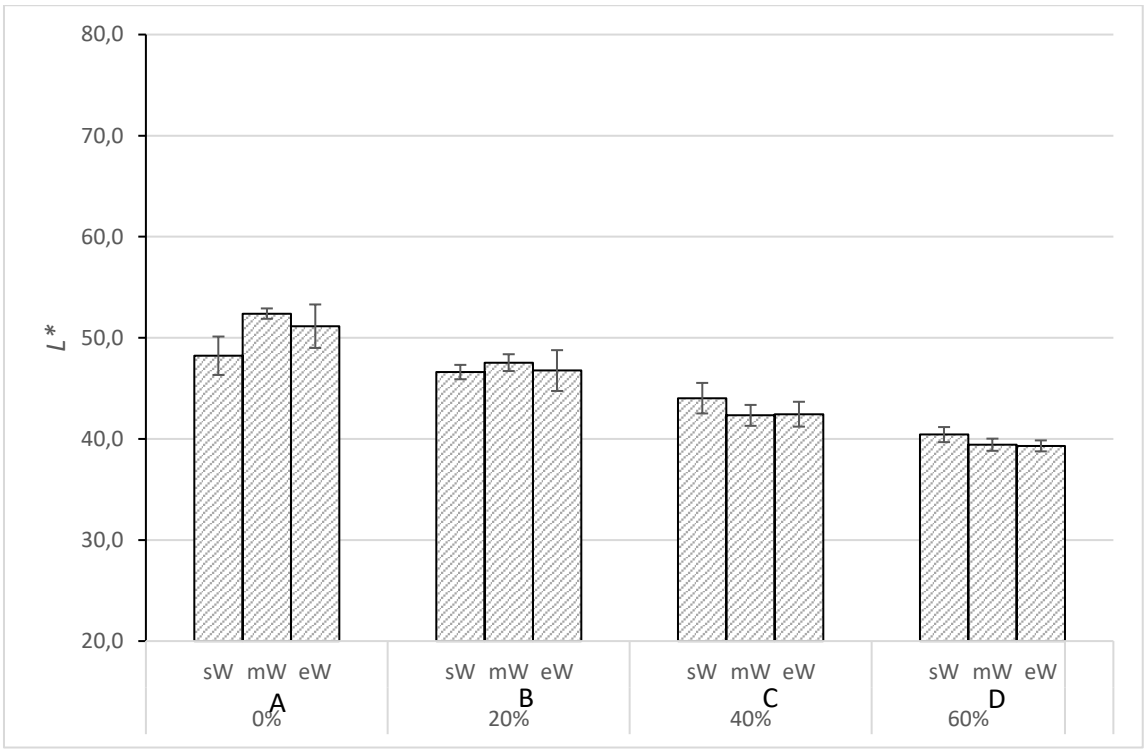
Analiza varijance za parametar ***L**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	605,472	201,824	84,547	< 0,0001
Pogreška	32	76,388	2,387		
Ukupno	35	681,860			
Analiza varijance za parametar ***a**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	40,612	13,537	47,522	< 0,0001
Pogreška	32	9,116	0,285		
Ukupno	35	49,728			
Analiza varijance za parametar ***b**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	169,295	56,432	66,750	< 0,0001
Pogreška	32	27,054	0,845		
Ukupno	35	196,348			
Analiza varijance za parametar ΔE_{CVS} čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	1269,357	423,119	748,391	< 0,0001
Pogreška	32	18,092	0,565		
Ukupno	35	1287,449			

Tablica 8. Analiza varijance parametara boje donjeg dijela čajnog peciva mjerenog računalnom analizom slike

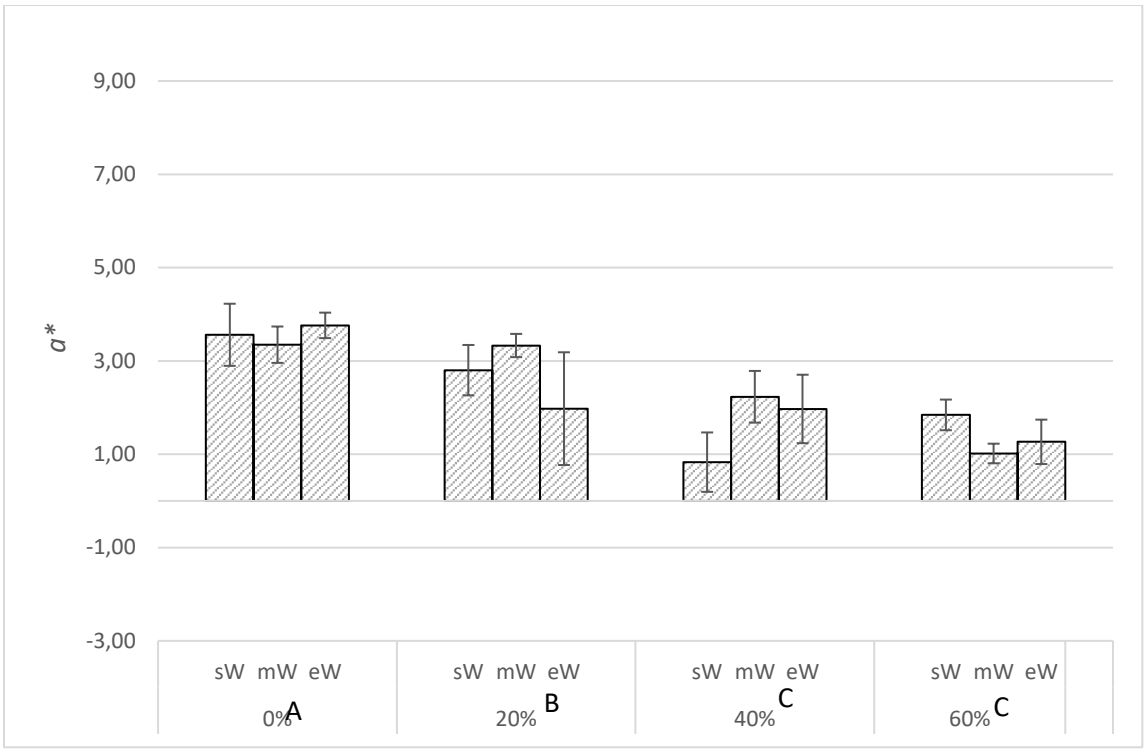
Analiza varijance za parametar ***L**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	2,501	1,250	0,061	0,941
Pogreška	33	679,360	20,587		
Ukupno	35	681,860			
Analiza varijance za parametar ***a**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	0,007	0,003	0,002	0,998
Pogreška	33	49,721	1,507		
Ukupno	35	49,728			
Analiza varijance za parametar ***b**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	1,808	0,904	0,153	0,858
Pogreška	33	194,541	5,895		
Ukupno	35	196,348			
Analiza varijance za parametar ΔE_{CVS} čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	2,774	1,387	0,036	0,965
Pogreška	33	1284,674	38,930		
Ukupno	35	1287,449			



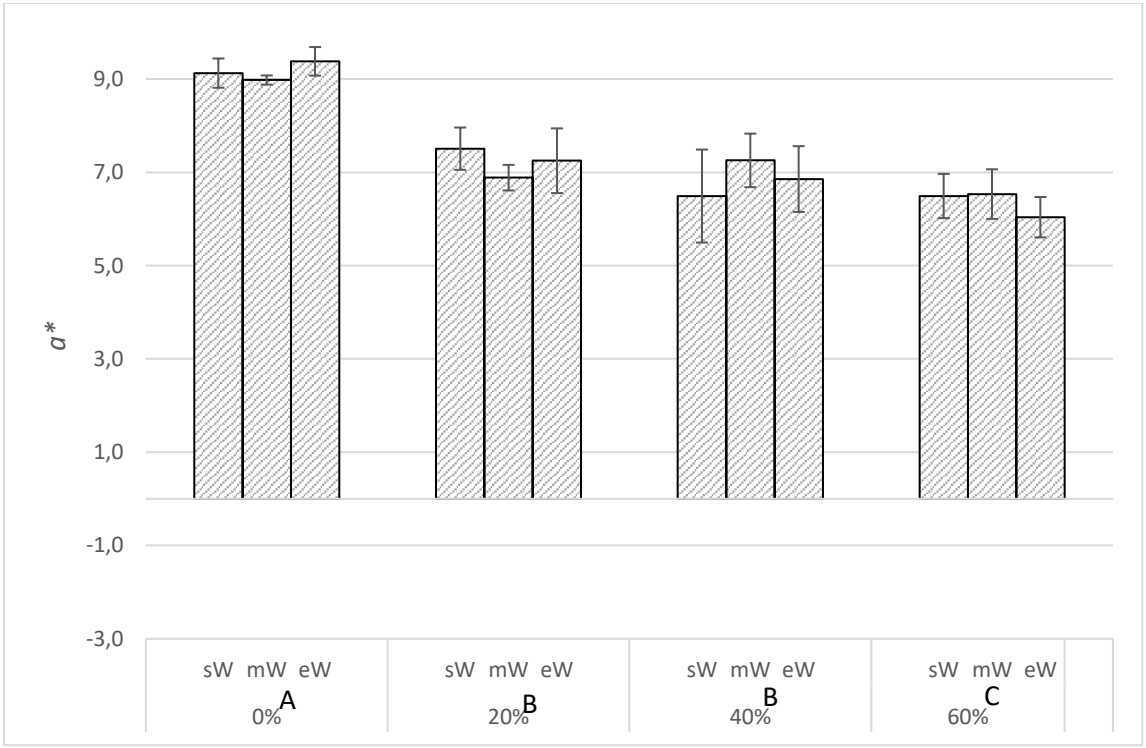
Slika 26. Vrijednosti svjetline površine čajnog peciva



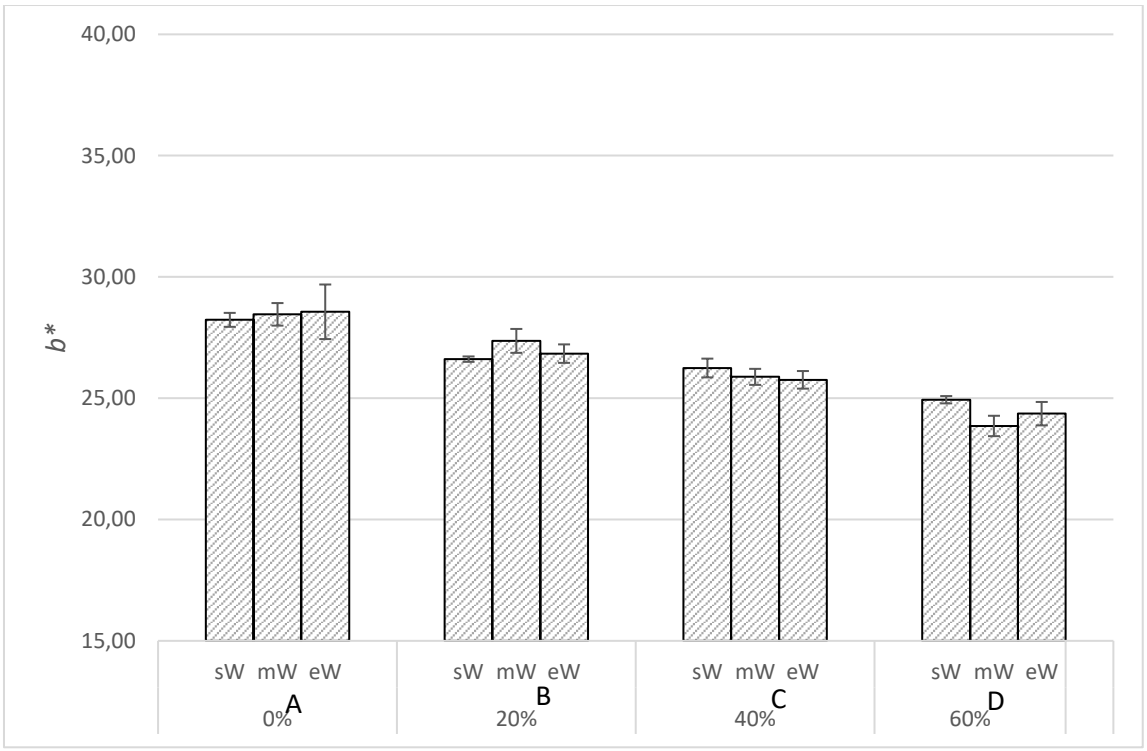
Slika 27. Vrijednosti svjetline donjeg dijela čajnog peciva



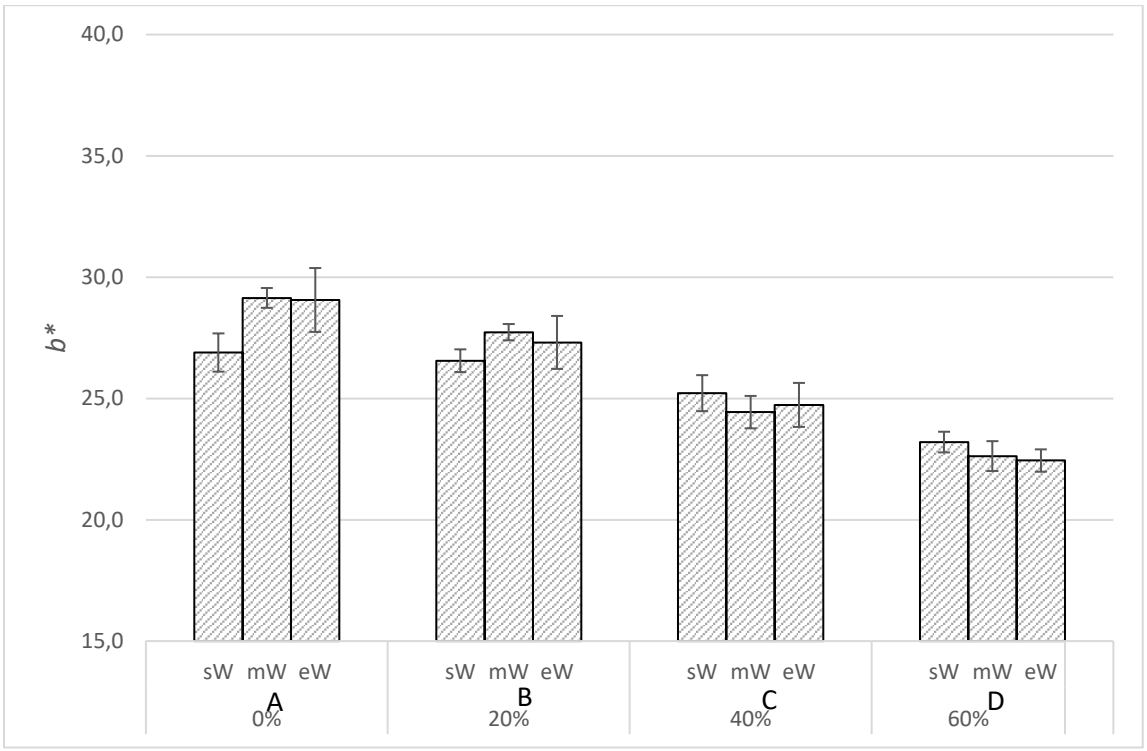
Slika 28. Vrijednosti kromatske komponente crveno-zelene boje a* površine čajnog peciva



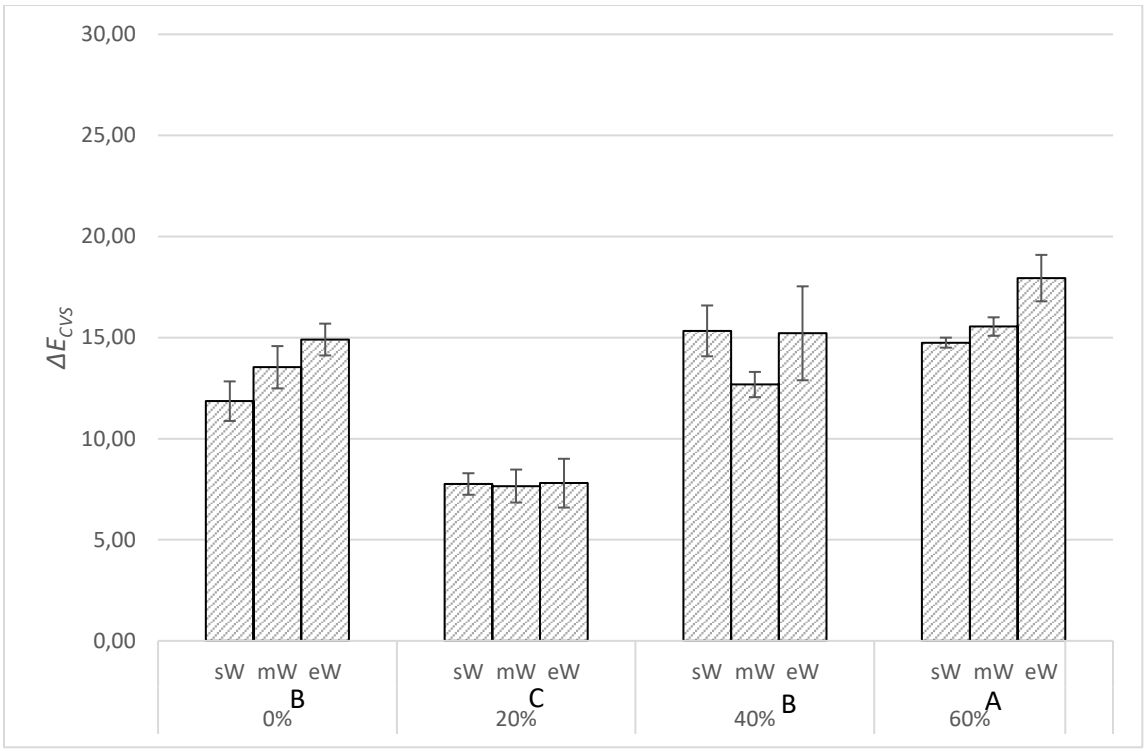
Slika 29. Vrijednosti kromatske komponente crveno-zelene boje a* donjeg dijela čajnog peciva



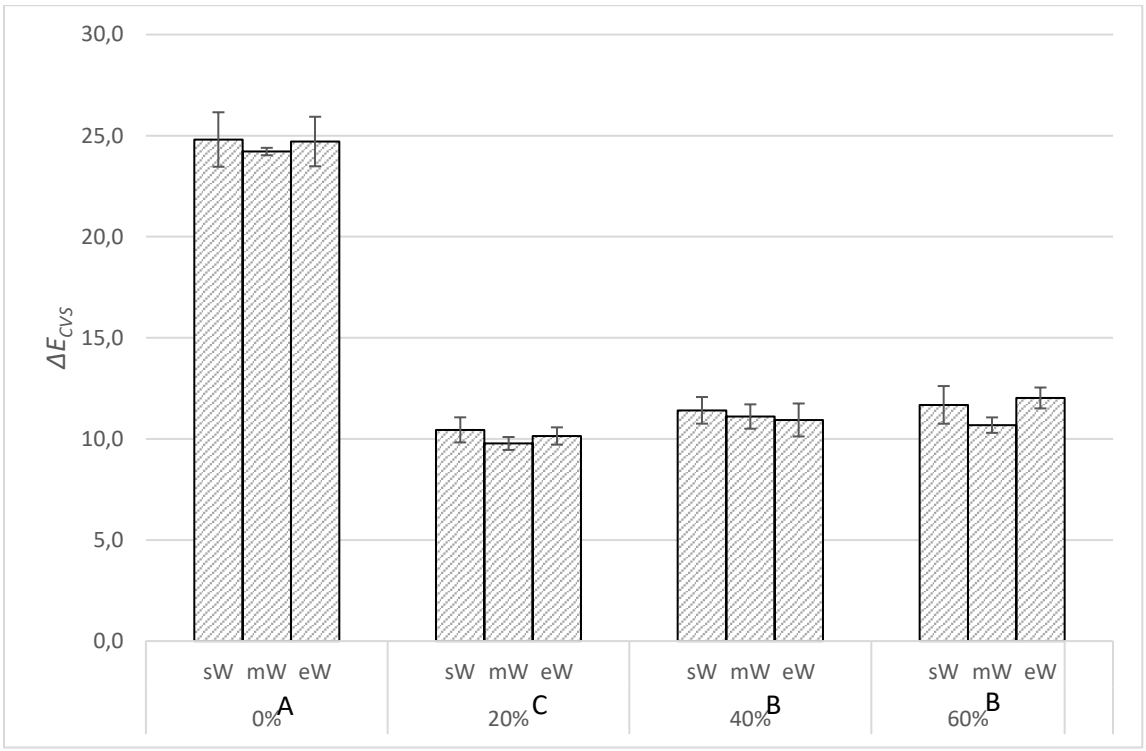
Slika 30. Vrijednosti kromatske komponente žuto-plave boje b* površine čajnog peciva



Slika 31. Vrijednosti kromatske komponente žuto-plave boje b* donjeg dijela čajnog peciva



Slika 32. Promjena boje površine čajnog peciva



Slika 33. Promjena boje donjeg dijela čajnog peciva

4.2. REZULTATI MJERENJA BOJE ČAJNOG PECIVA KOLORIMETROM

Eksperimentalni podaci mjerenja boje dobiveni kolorimetrom prikazani su tablično **Tablicama 9 - 12** i grafički **Slikama 34 - 41** kao parametri CIE*L*a*b** modela boja i kao ukupna promjena boje (Δ*E*) za površinu čajnog peciva te za usitnjene uzorke čajnog peciva. U **Tablicama 10 i 12** prikazan je utjecaj udjela vode (7,11% sW, 9,20% wW i 11,30% eW) na parametre boje (*L*, a*, b** i $\Delta E_{kolorimetar}$), a na **Slikama 34 - 41** i **Tablicama 9 i 11** prikazan je utjecaj udjela dodatka pogače buče (0%, 20%, 40% i 60%) na parametre boje (*L*, a*, b** i $\Delta E_{kolorimetar}$) mjerene kolorimetrom. Prikazani podaci su srednja vrijednost ± standardna devijacija; vrijednosti označene istim slovima nisu statistički značajno različite (p<0,05) prema Fisher-ovom LSD testu najmanje značajne razlike.

Tablica 9. Analiza varijance parametara boje površine čajnog peciva mjerenog kolorimetrom

Analiza varijance za parametar ***L**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	860,882	286,961	77,686	< 0,0001
Pogreška	56	206,855	3,694		
Ukupno	59	1067,736			
Analiza varijance za parametar ***a**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	260,913	86,971	48,084	< 0,0001
Pogreška	56	101,288	1,809		
Ukupno	59	362,201			
Analiza varijance za parametar ***b**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	188,408	62,803	25,677	< 0,0001
Pogreška	56	136,966	2,446		
Ukupno	59	325,374			
Analiza varijance za parametar $\Delta E_{kolorimetar}$ čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	780,102	260,034	31,331	< 0,0001
Pogreška	56	464,776	8,300		
Ukupno	59	1244,878			

Tablica 10. Analiza varijance parametara boje površine čajnog peciva mjerenog kolorimetrom

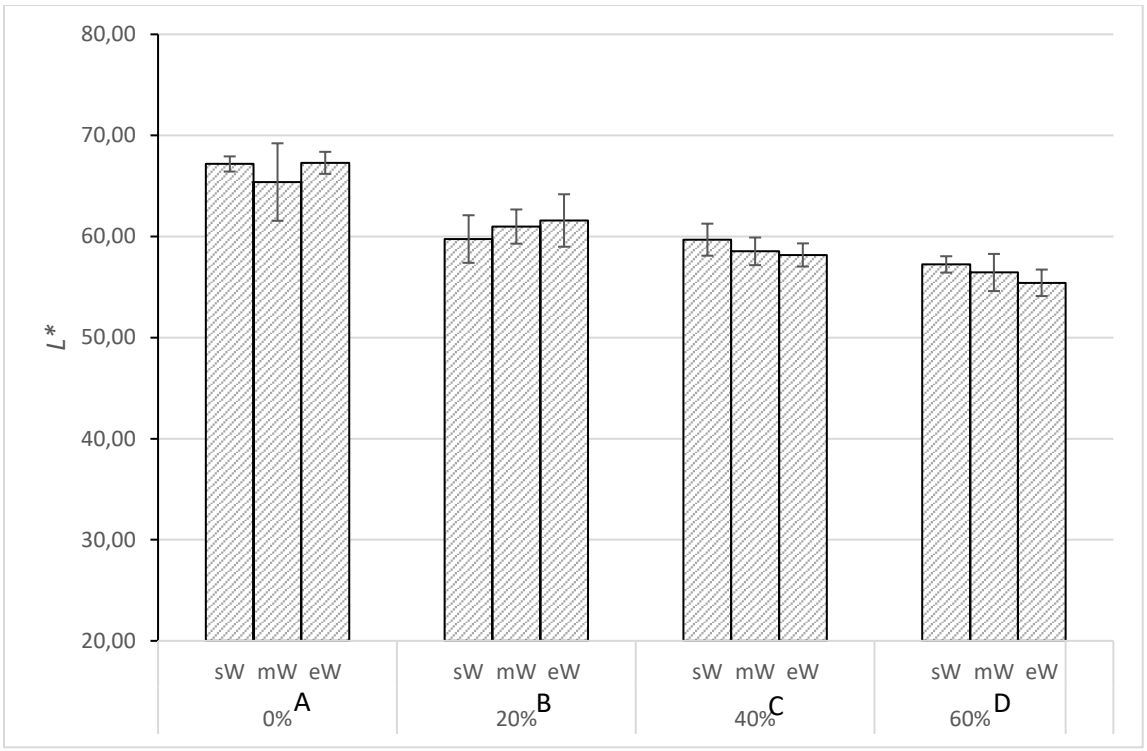
Analiza varijance za parametar ***L**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	3,946	1,973	0,106	0,900
Pogreška	57	1063,791	18,663		
Ukupno	59	1067,736			
Analiza varijance za parametar ***a**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	1,492	0,746	0,118	0,889
Pogreška	57	360,709	6,328		
Ukupno	59	362,201			
Analiza varijance za parametar ***b**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	3,645	1,823	0,323	0,725
Pogreška	57	321,729	5,644		
Ukupno	59	325,374			
Analiza varijance za parametar $\Delta E_{kolorimetar}$ čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	56,509	28,255	1,355	0,266
Pogreška	57	1188,369	20,849		
Ukupno	59	1244,878			

Tablica 11. Analiza varijance parametara boje usitnjenog čajnog peciva mjerenog kolorimetrom

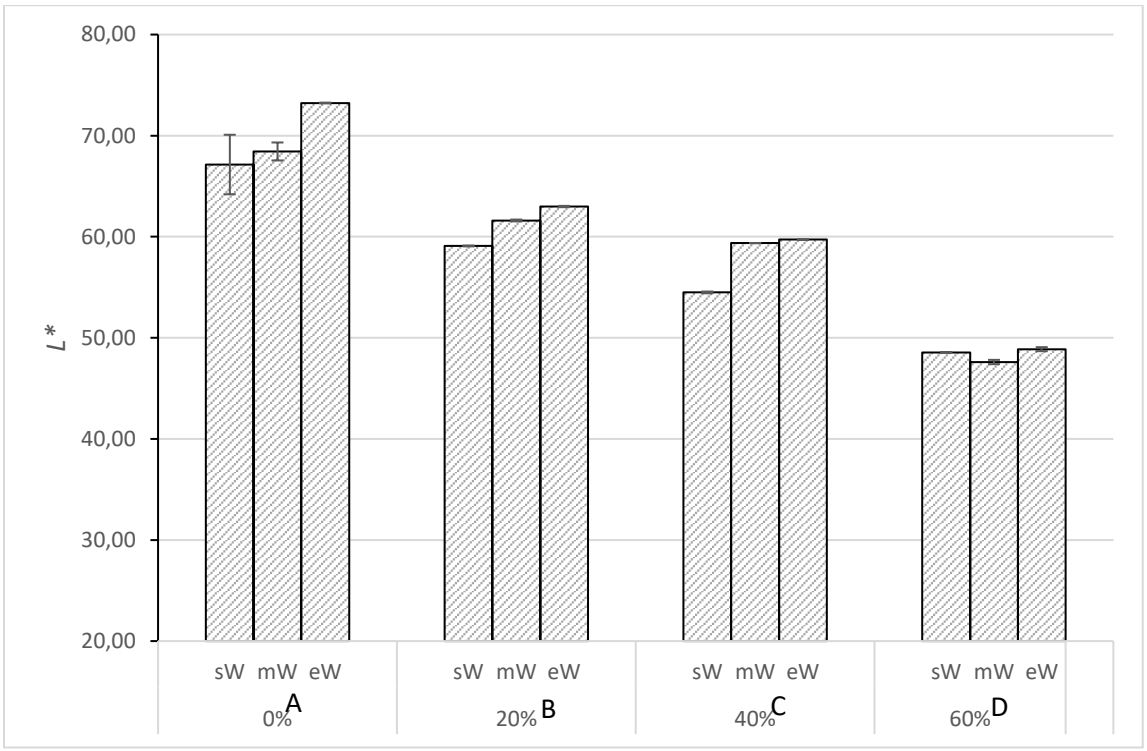
Analiza varijance za parametar ***L**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	3479,031	1159,677	240,477	< 0,0001
Pogreška	56	270,054	4,822		
Ukupno	59	3749,085			
Analiza varijance za parametar ***a**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	60,422	20,141	63,181	< 0,0001
Pogreška	56	17,851	0,319		
Ukupno	59	78,273			
Analiza varijance za parametar ***b**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	321,427	107,142	90,439	< 0,0001
Pogreška	56	66,343	1,185		
Ukupno	59	387,770			
Analiza varijance za parametar $\Delta E_{kolorimetar}$ čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Vrsta dodatka	3	1079,059	359,686	42,811	< 0,0001
Pogreška	56	470,498	8,402		
Ukupno	59	1549,557			

Tablica 12. Analiza varijance parametara boje usitnjenog čajnog peciva mjerenog kolorimetrom

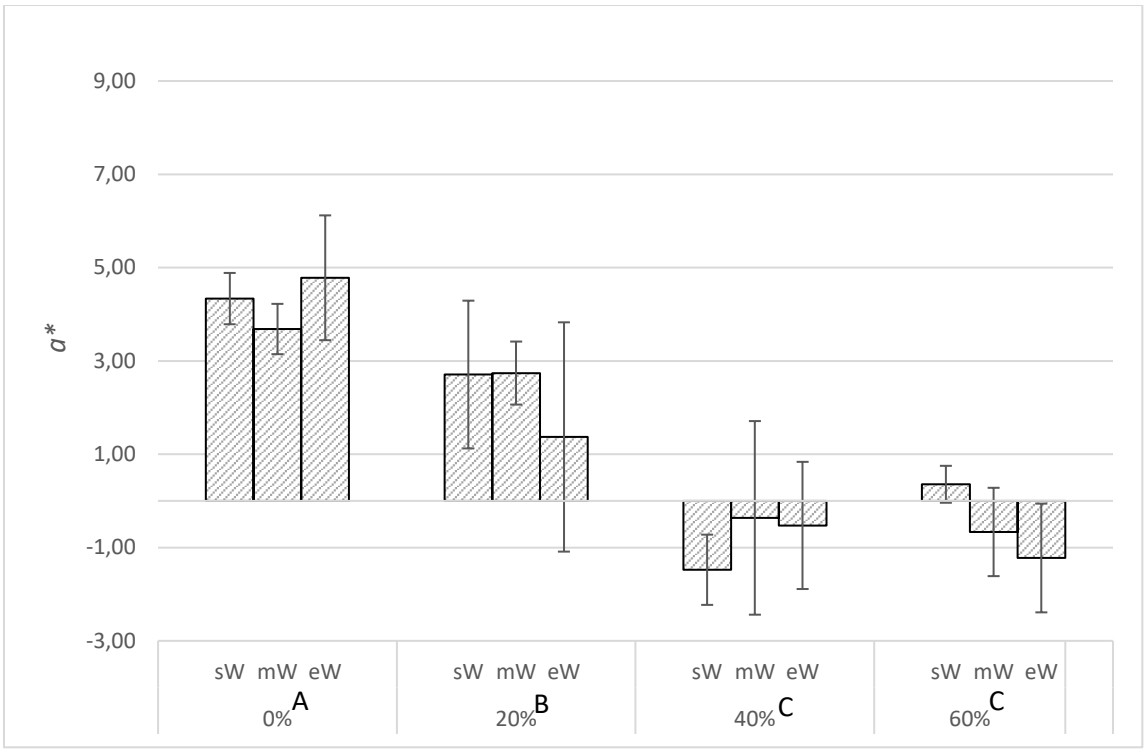
Analiza varijance za parametar ***L**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	150,777	75,389	1,194	0,310
Pogreška	57	3598,307	63,128		
Ukupno	59	3749,085			
Analiza varijance za parametar ***a**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	4,964	2,482	1,930	0,155
Pogreška	57	73,309	1,286		
Ukupno	59	78,273			
Analiza varijance za parametar ***b**** čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	24,460	12,230	1,919	0,156
Pogreška	57	363,310	6,374		
Ukupno	59	387,770			
Analiza varijance za parametar $\Delta E_{kolorimetar}$ čajnog peciva					
Izvor varijacije	Stupnjevi slobode	Suma kvadrata	Srednji kvadrat odstupanja	$F_{rač}$ - vrijednost	*P* - vrijednost
Udio vode	2	23,045	11,522	0,430	0,652
Pogreška	57	1526,512	26,781		
Ukupno	59	1549,557			



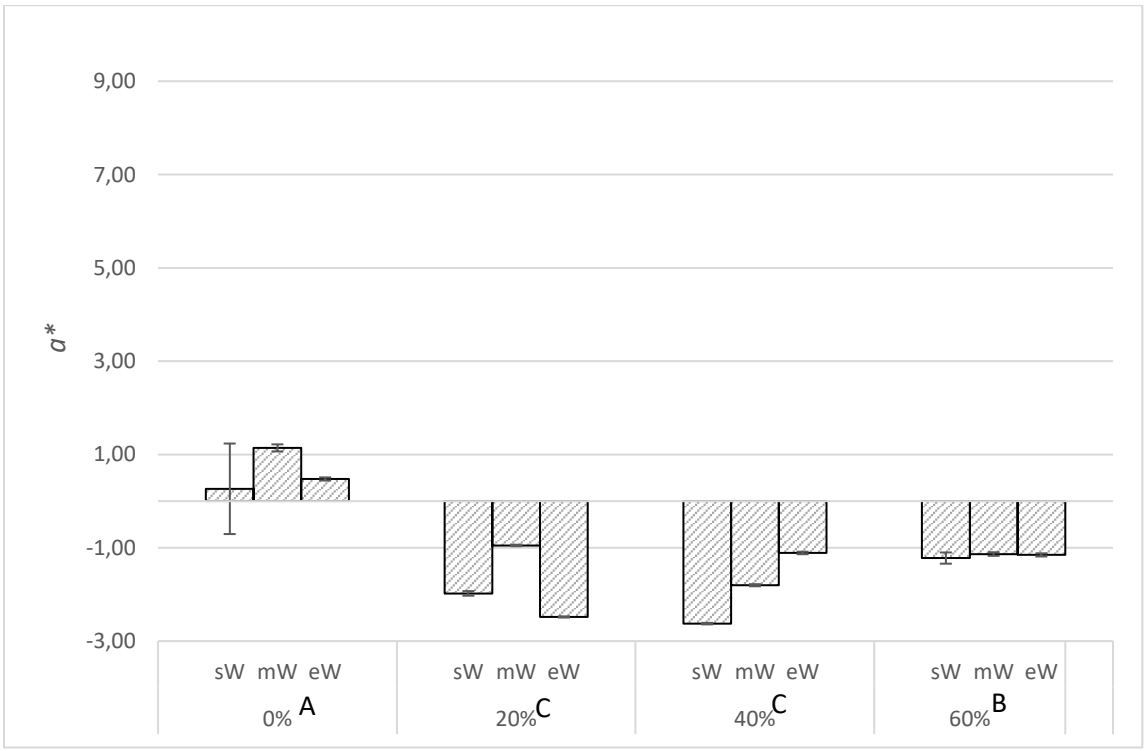
Slika 34. Vrijednosti svjetline površine čajnog peciva



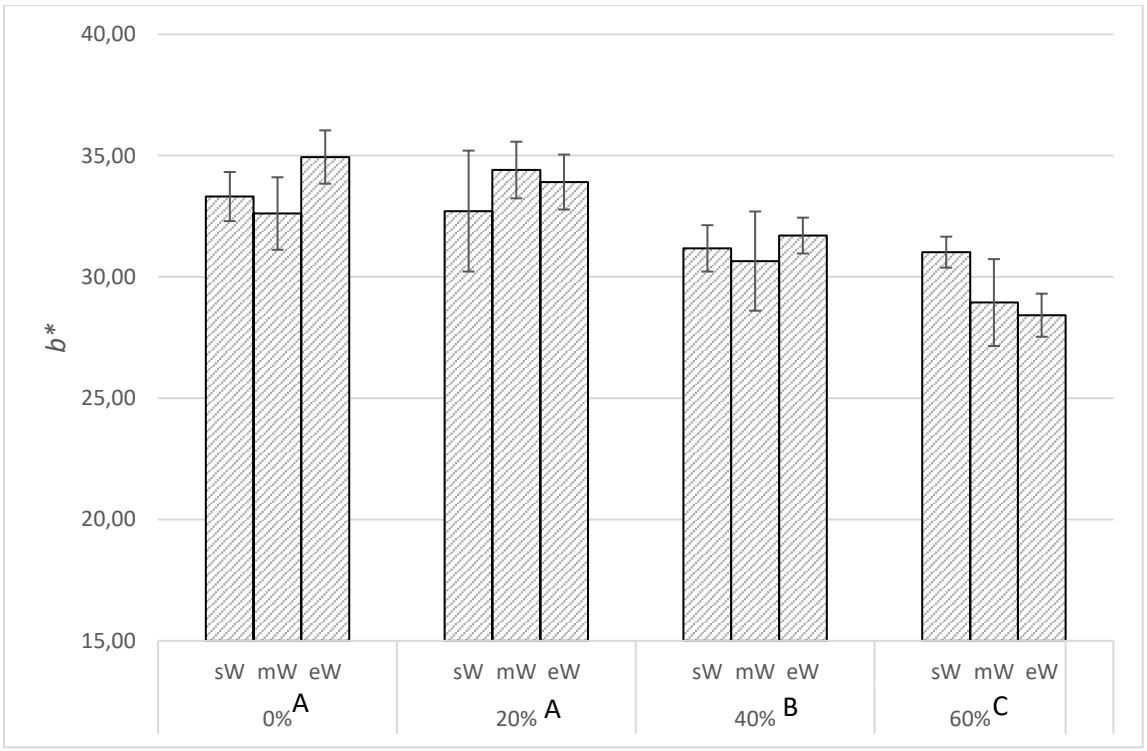
Slika 35. Vrijednosti svjetline usitnjenog čajnog peciva



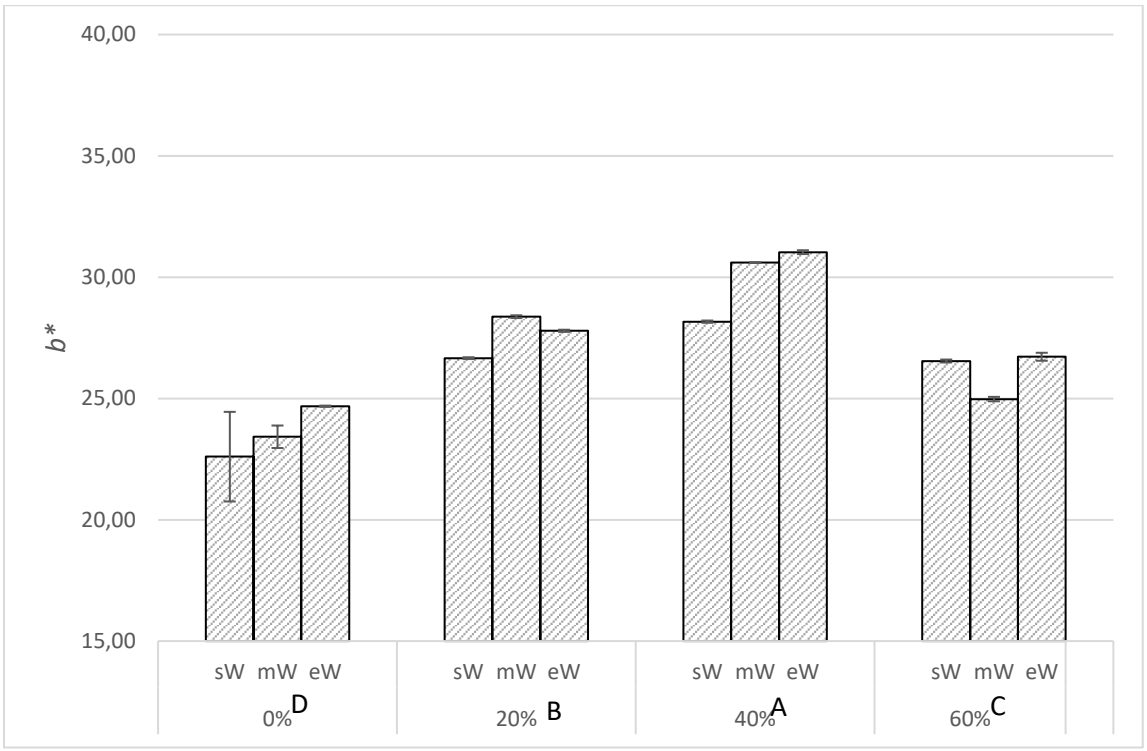
Slika 36. Vrijednosti kromatske komponente crveno-zelene boje a* površine čajnog peciva



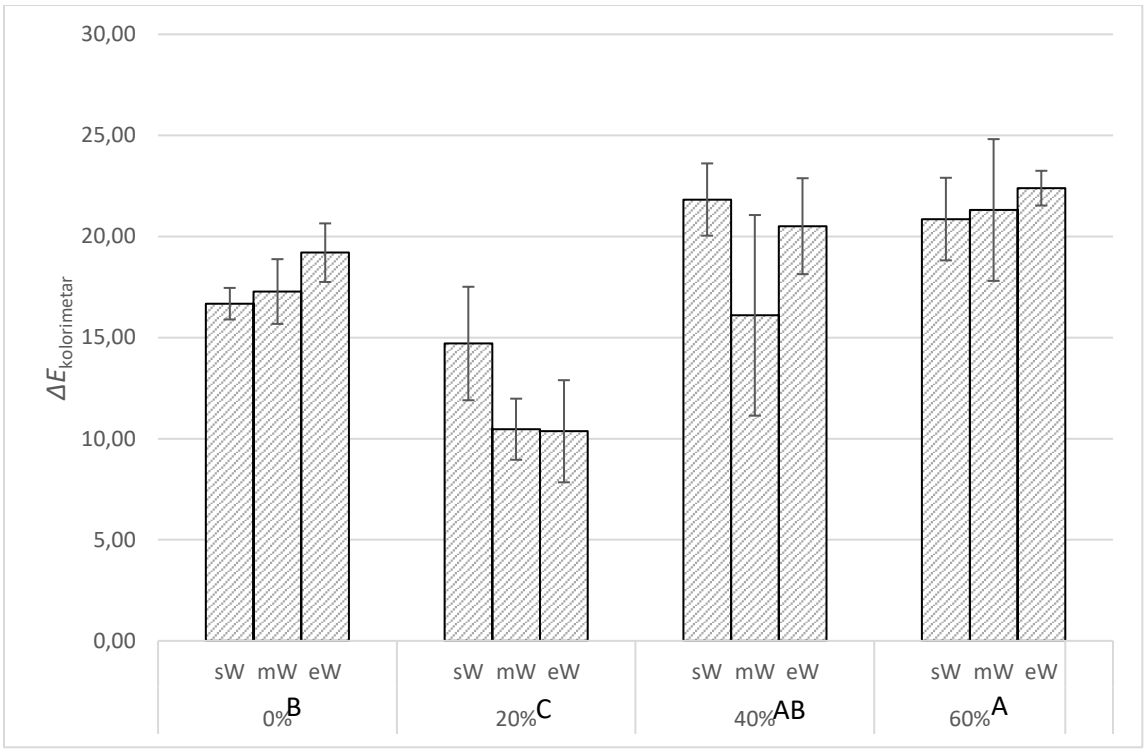
Slika 37. Vrijednosti kromatske komponente crveno-zelene boje a* usitnjenog čajnog peciva



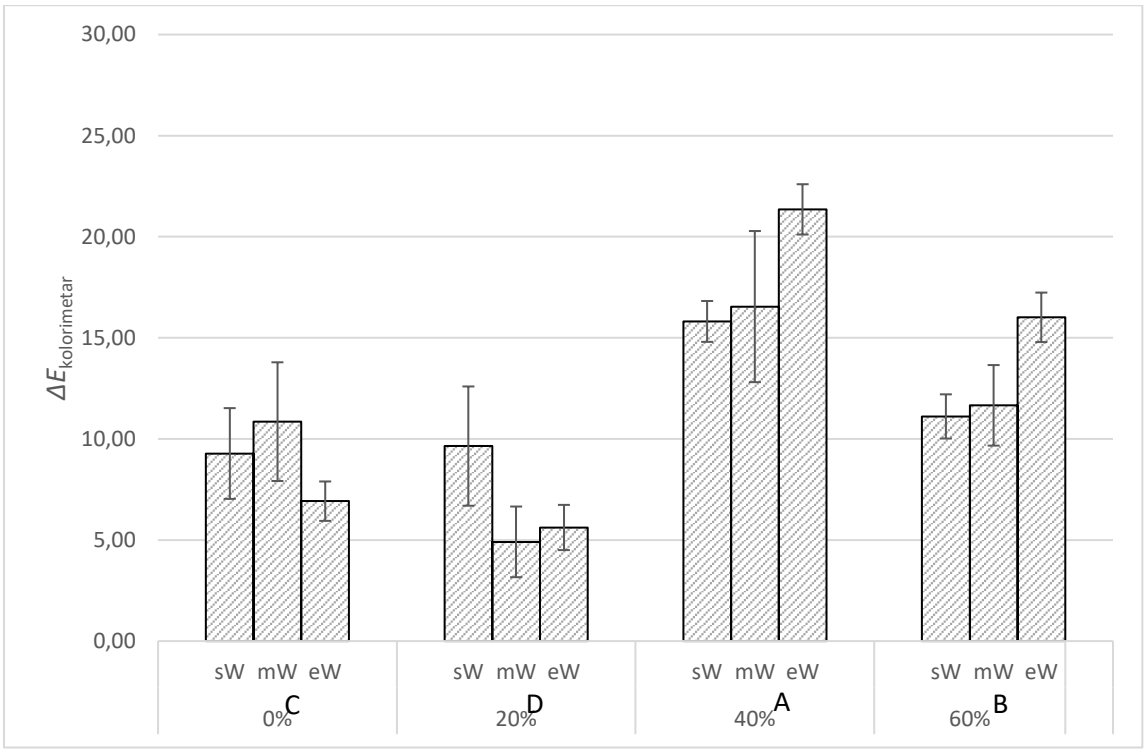
Slika 38. Vrijednosti kromatske komponente žuto-plave boje b* površine čajnog peciva



Slika 39. Vrijednosti kromatske komponente žuto-plave boje b* usitnjenog čajnog peciva



Slika 40. Promjena boje površine čajnog peciva



Slika 41. Promjena boje usitnjenog čajnog peciva

Tablica 13. Koeficijenti korelacije, R i determinacije R^2 utjecaja vrste dodatka na parametre boje

Površina uzorka (računalna analiza slike)				
Parametar	*L**	*a**	*b**	ΔE_{CVS}
R^2	0,960	0,631	0,898	0,831
R	**0,980**	0,794	**0,948**	0,911
Donji dio uzorka (računalna analiza slike)				
Parametar	*L**	*a**	*b**	ΔE_{CVS}
R^2	0,888	0,817	0,862	0,986
R	0,942	**0,904**	0,929	**0,993**
Površina uzorka (kolorimetar)				
Parametar	*L**	*a**	*b**	$\Delta E_{kolorimetar}$
R^2	0,806	0,720	0,579	0,627
R	0,898	0,849	0,761	0,792
Usitnjeni uzorak (kolorimetar)				
Parametar	*L**	*a**	*b**	$\Delta E_{kolorimetar}$
R^2	0,963	0,879	0,910	0,834
R	0,963	0,879	0,911	0,835

Tablica 14. Vrijednosti parametara boje čajnog peciva

Metoda	Varijabla	Minimum	Maximum	Sr. vrijednost	Std. devijacija
Računalna analiza slike	*L**	46,397	64,178	**53,293**	± 5,795
	*a**	0,321	4,051	**2,328**	± 1,102
	*b**	23,394	29,537	**26,427**	± 1,569
	$\Delta E_{CVS(površina)}$	6,859	19,177	**12,914**	± 3,488
	*L**	38,716	53,452	**45,055**	± 4,414
	*a**	5,545	9,623	**7,398**	± 1,192
	*b**	21,910	30,362	**25,780**	± 2,369
	$\Delta E_{CVS(donji\ dio)}$	9,417	26,090	**14,329**	± 6,065
Kolorimetar	*L**	53,500	69,810	**60,640**	± 4,254
	*a**	-2,610	6,840	**1,310**	± 2,478
	*b**	27,420	36,100	**31,986**	± 2,348
	$\Delta E_{kolorimetar\ (površina)}$	7,514	25,871	**17,642**	± 4,593
	*L**	47,380	73,270	**59,260**	± 7,971
	*a**	-2,650	1,260	**-1,048**	± 1,152
	*b**	20,130	31,090	**26,797**	± 2,564
	$\Delta E_{kolorimetar\ (usitnjeni)}$	3,808	22,903	**11,643**	± 5,125

5. RASPRAVA

U ovom diplomskom radu prikazani su rezultati ispitivanja utjecaja različitih udjela vode te zamjene dijela pšeničnog brašna pogačom bundeve na parametre boje čajnog peciva. Ispitivanje se provodilo s udjelima vode 7,11% (sW), 9,20% (wW) i 11,30% (eW) i dodacima pogače bundeve u udjelima 20%, 40% i 60%, a navedene smjese su se koristile za izradu čajnog peciva prema standardnoj AACC metodi 10- 50D. Boja uzoraka čajnog peciva određena je objektivno dvjema metodama: računalnom analizom slike i kolorimetrom. Mjereni parametri (*L*, a*, b**) CIE*L*a*b** modela boje poslužili su za određivanje ukupne promjene boje analiziranih uzoraka (Δ*E*).

5.1. REZULTATI MJERENJA BOJE ČAJNOG PECIVA RAČUNALNOM ANALIZOM SLIKE

Eksperimentalni podaci mjerenja boje dobiveni računalnom analizom slike prikazani su **Tablicama 5 - 8** i grafički **Slikama 26 - 33** kao parametri CIE*L*a*b** modela boja i kao ukupna promjena boje (Δ*E*) na površini i donjem dijelu uzoraka čajnog peciva.

Na **Slikama 26 - 33** prikazan je utjecaj udjela dodatka pogače buče (0%, 20%, 40% i 60%) na parametre boje (*L*, a*, b** i ΔE_{CVS}) mjerene računalnom analizom slike. Prikazani podaci su srednja vrijednost ± standardna devijacija; vrijednosti označene istim slovima nisu statistički značajno različite (p<0,05) prema Fisher-ovom LSD testu najmanje značajne razlike. U **Tablicama 6 i 8** prikazan je utjecaj udjela vode (sW, wW i eW) na parametre boje čajnog peciva (površinu i donji dio) mjerenu računalnom analizom slike.

Iz rezultata analize varijance i Fisher-ovog LSD testa najmanje značajne razlike može se zaključiti kako udio vode nema statistički značajan utjecaj na parametre boje čajnog peciva. Iz rezultata analize varijance prikazanih u **Tablici 5** odnosno **Tablici 7** vidljivo je da na sve promatrane parametre boje površine, odnosno donjeg dijela čajnog peciva (*L*, a*, b** i ΔE_{CVS}) mjerene računalnom analizom slike postoji statistički značajan utjecaj (p<0,05) udjela dodatka pogače buče.

Iz rezultata Fisher-ovog LSD testa najmanje značajne razlike utjecaj dodatka pogače buče na svjetlinu površine, odnosno donjeg dijela čajnog peciva prikazanih **Slikama 26 i 27**, može se

zaključiti kako postoji statistički značajna razlika između uzoraka čajnog peciva od čistog pšeničnog brašna te onog s različitim udjelom buče. Vrijednosti svjetline kretale su se u rasponu *L**= 47,40 - 63,44 na površini uzorka, odnosno *L**= 39,31 - 52,40 na donjem dijelu uzoraka čajnog peciva. Najveće vrijednosti svjetline na površini i donjem dijelu imali su uzorci čajnog peciva od pšeničnoga brašna. Također, vrijednosti svjetline opadale su proporcionalno porastom udjela pogače buče na površini i donjem dijelu čajnog peciva što znači da su uzorci s većim udjelom pogače buče bili tamniji. Ukupno gledajući vrijednosti svjetline, manje vrijednosti imali su uzorci s donje strane u odnosu na površinu, što upućuje na zaključak da je donji dio uzoraka bio tamniji neovisno o vrsti i udjelu dodatka.

Slika 28 prikazuje utjecaj dodatka pogače buče na kromatsku komponentu zeleno-crvene boje (*a**) površine čajnog peciva. Iz dobivenih rezultata može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s dodatkom buče postoji statistički značajna razlika, također među uzorcima čajnog peciva s udjelom buče od 40% i 60% ne postoji statistički značajna razlika. **Slika 29** prikazuje utjecaj dodatka pogače buče na kromatsku komponentu zeleno-crvene boje (*a**) donjeg dijela čajnog peciva. Iz dobivenih rezultata može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s dodatkom buče postoji statistički značajna razlika, također među uzorcima čajnog peciva s udjelom buče od 20% i 40% ne postoji statistički značajna razlika. Vrijednosti kromatske komponente *a** bile su pozitivne i kretale su se u rasponu *a**= 0,83 – 3,76 na površini uzorka, odnosno *a**= 6,04 – 9,38 na donjem dijelu uzoraka čajnog peciva.Najveće vrijednosti boje kromatske komponente *a** zabilježene su kod uzoraka čajnog peciva s pšeničnim brašnom mjerene na površini i na donjem dijelu uzorka, u odnosu na one s dodatkom pogače buče. Uspoređujući boju uzoraka s dodatkom buče, kromatska komponenta zeleno-crvene boje imala je pozitivne vrijednosti i opadala je porastom udjela dodatka buče, što znači da su uzorci s većim udjelom pogače buče bili u domeni zelene boje.

Slika 30 prikazuje utjecaj dodatka pogače buče na kromatsku komponentu plavo-žute boje (*b**) površine čajnog peciva. Iz rezultata Fisher-ovog LSD testa najmanje značajne razlike može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s različitim udjelom buče postoji statistički značajna razlika. **Slika 31** prikazuje utjecaj dodatka pogače buče na kromatsku komponentu plavo-žute boje (*b**) donjeg dijela čajnog peciva. Iz dobivenih rezultata može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog

pšeničnog brašna te onog s dodatkom buče postoji statistički značajna razlika. Vrijednosti kromatske komponente *b** bile su pozitivne i kretale su se u rasponu *b**= 23,86 – 28,56 na površini uzorka, odnosno *b**= 22,44 – 29,14 na donjem dijelu uzoraka čajnog peciva. Najveće vrijednosti boje kromatske komponente *b** zabilježene su kod uzoraka čajnog peciva s pšeničnim brašnom, u odnosu na one s dodatkom pogače buče. Uspoređujući boju uzoraka s dodatkom buče, kromatska komponenta plavo-žute boje imala je pozitivne vrijednosti i opadala je porastom udjela dodatka buče, što znači da su uzorci s većim udjelom pogače buče bili u domeni žute boje.

Slika 32 prikazuje utjecaj dodatka pogače buče na ukupnu promjenu boje donjeg dijela čajnog peciva. Iz rezultata Fisher-ovog LSD testa najmanje značajne razlike može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s različitim udjelom buče postoji statistički značajna razlika, također među uzorcima čajnog peciva od pšeničnog brašna i s udjelom buče od 40% ne postoji statistički značajna razlika.
Slika 33 prikazuje utjecaj dodatka pogače buče na ukupnu promjenu boje donjeg dijela čajnog peciva. Iz rezultata Fisher-ovog LSD testa najmanje značajne razlike može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s različitim udjelom buče postoji statistički značajna razlika, također među uzorcima čajnog peciva s udjelom buče od 40% i 60% ne postoji statistički značajna razlika.
Prema Mokrzycki i Tatol (2012) ukupna promjena boje bila je jasno uočljiva za ljudsko oko $\Delta E > 5$, vrijednosti su se kretale u rasponu ΔE = 7,66 - 17,94 na površini uzorka te ΔE = 9,77 - 24,81 na donjem dijelu uzoraka te je ovisila o udjelu dodatka buče. Prema rezultatima ukupne promjene boje uzoraka od pšeničnog brašna i onog s dodatkom pogače buče, veće razlike uočene su na donjem dijelu u odnosu na površinu uzoraka čajnog peciva.

5.2 REZULTATI MJERENJA BOJE ČAJNOG PECIVA KOLORIMETROM

Eksperimentalni podaci mjerenja boje dobiveni kolorimetrom prikazani su tablično **Tablicama 9 – 12** i grafički **Slikama 34 – 41** kao parametri CIE*L*a*b** modela boja i kao ukupna promjena boje (ΔE). Prikazani podaci su srednja vrijednost ± standardna devijacija; vrijednosti označene

istim slovima nisu statistički značajno različite (p<0,05) prema Fisher-ovom LSD testu najmanje značajne razlike.

Tablica 10 i 12 prikazuje rezultate analize varijance utjecaja udjela vode (sW, wW i eW) na parametre boje čajnog peciva (površinu i usitnjeni uzorak) mjerenu kolorimetrom. Iz rezultata Fisher-ovog LSD testa najmanje značajne razlike može se zaključiti kako udio vode nema statistički značajan utjecaj na parametre boje čajnog peciva. Iz rezultata analize varijance prikazanih u **Tablici 9 i 11** vidljivo je da na sve promatrane parametre boje površine čajnog peciva te usitnjenog čajnog peciva (L^*, a^*, b^* i $\Delta E_{kolorimetar}$) mjerene kolorimetrom postoji statistički značajan utjecaj (p<0,05) udjela dodatka pogače buče.

Slika 34 prikazuje utjecaj dodatka pogače buče na svjetlinu površine čajnog peciva. Iz rezultata Fisher-ovog LSD testa najmanje značajne razlike može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s različitim udjelom buče postoji statistički značajna razlika. Isti zaključak može se izvesti gledajući rezultate na **Slici 35** kod usitnjenih uzoraka čajnog peciva.

Vrijednosti svjetline kretale su se u rasponu L^* = 55,42 – 67,29 na površini uzorka, odnosno L^* = 47,61 – 73,23 usitnjenih uzoraka čajnog peciva. Uspoređujući utjecaj vrste dodatka, veće vrijednosti svjetline imali su uzorci čajnog peciva od pšeničnoga brašna. Veće vrijednosti svjetline upućuju na zaključak da su uzorci čajnog peciva od pšeničnog brašna svjetliji u odnosu na one s dodatkom buče. Nadalje, vrijednosti svjetline opadale su proporcionalno porastom udjela pogače buče kako na površini uzoraka tako i kod usitnjenih uzoraka čajnog peciva.

Slika 36 prikazuje utjecaj dodatka pogače buče na kromatsku komponentu zeleno-crvene boje (a^*) površine čajnog peciva. Iz dobivenih rezultata može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s dodatkom buče postoji statistički značajna razlika, također među uzorcima čajnog peciva s udjelom buče od 40% i 60% ne postoji statistički značajna razlika.

Slika 37 prikazuje utjecaj dodatka pogače buče na kromatsku komponentu zeleno-crvene boje (a^*) usitnjenih uzoraka čajnog peciva. Iz dobivenih rezultata može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s dodatkom buče postoji statistički značajna razlika, također među uzorcima čajnog peciva s udjelom buče od 20% i 40% ne postoji statistički značajna razlika. Vrijednosti kromatske komponente a^* kretale su se u

rasponu *a** = - 1,48 – 4,78 na površini uzorka, odnosno *a**= -2,63 – 1,14 kod usitnjenih uzoraka čajnog peciva.

Uspoređujući vrijednosti boje kromatske komponente *a** na površini uzoraka čajnog peciva, pozitivne vrijednosti imali su uzorci s pšeničnim brašnom te najmanjim udjelom buče (20%), dok su negativne vrijednosti imali uzorci s udjelima pogače buče od 40% i 60%. Ukoliko su vrijednosti kromatske komponente *a** pozitivne, uzorci se nalaze u domeni crvene boje, dok negativne vrijednosti ukazuju na domenu zelene boje. Vrijednosti boje kromatske komponente *a** usitnjenih uzoraka čajnog peciva s dodatkom pogače buče bile su negativne. Za razliku od njih uzorci od pšeničnog brašna bili su u domeni crvene boju na što upućuju pozitivne vrijednosti kromatske komponente *a**.

Slika 38 prikazuje utjecaj dodatka pogače buče na kromatsku komponentu plavo-žute boje (*b**) površine čajnog peciva. Može se zaključiti kako postoji statistički značajna razlika između uzoraka od čistog pšeničnog brašna te onih s udjelima buče od 40% i 60%. Među uzorcima od čistog pšeničnog brašna i udjela buče od 20% ne postoji statistički značajna razlika.

Slika 39 prikazuje utjecaj dodatka pogače buče na kromatsku komponentu plavo-žute boje (*b**) usitnjenih uzoraka čajnog peciva. Iz dobivenih rezultata može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s dodatkom buče postoji statistički značajna razlika. Vrijednosti kromatske komponente *b** bile su pozitivne i kretale su se u rasponu *b**= 28,42 – 34,94 na površini uzorka, odnosno *b**= 22,60 – 31,03 kod usitnjenih uzoraka čajnog peciva. Pozitivne vrijednosti kromatske komponente *b** ukazuju na boju uzoraka u domeni žute boje.

Slika 40 prikazuje utjecaj dodatka pogače buče na ukupnu promjenu boje površine čajnog peciva. Iz rezultata Fisher-ovog LSD testa najmanje značajne razlike može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s različitim udjelom buče postoji statistički značajna razlika. **Slika 41** prikazuje utjecaj dodatka pogače buče na ukupnu promjenu boje usitnjenih uzoraka čajnog peciva. Iz rezultata može se zaključiti kako kod smjesa za proizvodnju čajnog peciva od čistog pšeničnog brašna te onog s različitim udjelom buče postoji statistički značajna razlika.

Ukupna promjena boje bila je jasno uočljiva za ljudsko oko Δ*E* > 5 kod većine uzoraka kojima je boja mjerena kolorimetrom. Vrijednosti ukupne promjene boje kretale su se u rasponu ΔE = 10,37 – 22,39 na površini uzorka te Δ*E*= 4,91 – 21,35 kod usitnjenih uzoraka te je ovisila

o udjelu dodatka buče. Prema rezultatima ukupne promjene boje uzoraka od pšeničnog brašna i onog s dodatkom pogače buče, veće razlike uočene su na površini uzoraka čajnog peciva u odnosu na usitnjene uzorke.

Usporedba metoda mjerenja boje čajnog peciva

Prikladnost pojedinog parametra boje i metode mjerenja boje za predviđanje utjecaja vrste dodatka na promjenu boje uzoraka čajnog peciva potvrđivala se korištenjem statističkih pokazatelja, a primijenjeni su: koeficijent korelacije, R i koeficijent determinacije R^2 (**Tablice 13 - 14**). Potpuno (idealno) slaganje između eksperimentalnih i modelom predviđenih vrijednosti bilo bi potvrđeno s vrijednostima 1 za oba parametra. Prema rezultatima, računalna analiza slike pokazala se kao bolja metoda za predviđanje promjene svjetline (*L**) i kromatske komponente *b** na površini uzoraka, odnosno za predviđanje ukupne promjene boje (ΔE) i kromatske komponente *a**.

6. ZAKLJUČCI

U radu je ispitan utjecaj različitih udjela vode te zamjene dijela pšeničnog brašna pogačom bundeve na parametre boje čajnog peciva. S ciljem predviđanja i kontrole razvoja boje čajnog peciva tijekom pečenja, boja uzoraka mjerena je dvjema metodama: računalnom analizom slike i kolorimetrom. Ovim metodama izmjerena je količina reflektirane svjetlosti sa površine uzoraka, te su rezultati prikazani kao parametri CIE*L*a*b** modela boja. Iz dobivenih rezultata može se zaključiti slijedeće:

- udio vode nema statistički značajan utjecaj na parametre boje, dok su udio i vrsta dodatka imali su statistički značajan utjecaj na parametre boje čajnog peciva
- različit udio dodatka pogače buče statistički značajno utječe na promjenu svjetline uzoraka čajnog peciva neovisno o metodi mjerenja boje (računalna analiza slike ili kolorimetar). Povećanjem udjela dodatka pogače buče, uzorci čajnog peciva bili su tamniji
- uzorci čajnog peciva od pšeničnog brašna imaju najveće vrijednosti parametra *L** (63,44 ±1,22 mjerene računalnom analizom slike; 67,29 ±1,09 mjerene kolorimetrom) te su oni svjetliji u odnosu na one s dodatkom pogače buče (39,31 ±0,54 mjerene računalnom analizom slike; 47,61 ±0,21 mjerene kolorimetrom). Najmanje vrijednosti svjetline imali su uzorci s donje strane čajnog peciva i usitnjeni uzorci (najtamniji uzorci)
- vrijednosti parametara boje *a** mjerene računalnom analizom slike bile su pozitivne kod svih uzoraka, odnosno ti uzorci se nalaze u domeni crvene boje. Vrijednosti parametara boje *a** mjerene kolorimetrom bile su pozitive kod uzoraka od pšeničnog brašna i negativne kod uzoraka s dodatkom pogače buče, što upućuje na domenu zelene boje uzoraka
- prema rezultatima ukupne promjene boje uzoraka od pšeničnog brašna i onog s dodatkom pogače buče, veće razlike uočene su na površini uzoraka čajnog peciva u odnosu na usitnjene uzorke
- ukupna promjena boje bila je jasno uočljiva za ljudsko oko te je ovisila o udjelu dodatka buče. Prema rezultatima ukupne promjene boje uzoraka od pšeničnog brašna i onog s dodatkom pogače buče, veće razlike uočene su na donjem dijelu u odnosu na površinu uzoraka čajnog peciva

7. LITERATURA

Allen E, Triantaphillidou S: *The manual of photography 10th edition*, Elsevier Ltd, Oxford, UK, 2011.

AACC 10-50D (2000) Baking Quality of Cookie Flour. Approved Methods of the American Association of Cereal Chemists, 10th ed. AACC, St. Paul.

Berns RS: *Billmeyer and Saltzman's Principles of Color Technology, 3rd edition.* John Wiley & Sons, New York, 2000.

Brkan, B: *Katalog bučinog ulja*, Ivanić-Grad, 2013.

Brosnan T, Sun DW: Improving quality inspection of food products by computer vision-a review. *Journal of Food Engineering*, 61(1): 3-16, 2004.

Brosnan T, Sun DW: Inspection and grading of agricultural and food products by computer vision system-a review. *Computers and electronics in Agriculture*, 36(2-3): 193-213, 2002.

Commission Internationale de l'Eclairage (CIE). *Colorimetry. 3rd Edition*. Publ. CIE 15.3:2004 ISBN 3 901 906 33 9. (2004) Bureau Central de la CIE, Vienna, Austria.

Dumovski F, Milas Z: *Priručnik o proizvodnji i upotrebi stočne hrane – krme*. Hrvatsko agronomsko društvo, Zagreb, 2004.

El-Zaart: Images thresholding using ISODATA technique with gamma distribution. *Pattern Recognition and Image Analysis,* 20 (1): 29-41, 2010.

Fairchild MD: *Color Appearance Models, Chichester,* UK: John Wiley & Sons, Ltd, 2013 URL: http://ivanych.net/doc/ColorAppearanceModels_Fairchild.pdf [datum pristupa: 1.2.2018.]

Filko D: Robusna lokalizacija mobilnog robota zasnovana na vizualnim obilježjima ravninskih segmenata. *Doktorska disertacija.* Elektrotehnički fakultet, Osijek, 2013.

Gavrilović, M: *Tehnologija konditorskih proizvoda*. Zavod za izdavanje udžbenika Novi Sad, Novi Sad, 2011.

Gavrilović M: *Tehnologija konditorskih proizvoda*. Zavod za izdavanje udžbenika Novi Sad, Novi Sad, 2003.

Gokmen V, Aca O, Arribas-Lorenzo G, Morales, FJ: Investigating the correlation between acrylamide content and browning ratio of model cookies. *Journal of Food Engineering*, 87(3): 380-385, 2008.

Gokmen V, Acar OC, Koksel H, Acar J: Effects of dough formula and baking conditions on acrylamide and hydroxymethylfurfural formation in cookies. *Food Chemistry,* 104 (3): 1136-1142, 2007.

Gonzales-Barron U, Butler F: A comparison of seven thresholding techniques with the k-means clustering algorithm for measurement of bread-crumb features by digital image analysis. *Journal of Food Engineering,* 74: 268-278, 2006.

Hodge JE: Chemistry of Browning Reactions in Model Systems. *Agricultural and Food Chemistry,* 1(15): 928-943, 1953.

Hoseney RC: *Principles of cereal scince and tehnology*, AACC, Inc.St. Paul Minesota, USA, 1994.

Hsien-Che L: *Introduction to Color Imaging Science*. Cambridge University Press, New York, 2005.

ISO 659 (2009) Oilseeds — Determination of oil content (Reference method).

Jacobo-Valenzuela N, Marostica-Junior MR, Zauzeta-Morales JJ, Gallegos-Infante JA: Physicochemical, technological properties, and health-benefits of Cucurbita moschata Duchense vs. Cehualca. *Food Research International* 44: 2587-2593, 2011.

Kalavathi PA: Thresholding Method for Color Image Binarization. *SSRG International Journal of Computer Science and Engineering*, 1(7):31-40, 2014.

Kent NL, Evers AD: *Technology of cereals*. Elsevier Science Ltd., UK, 1994.

Kheng LW: *In proceedings Kheng 2002 Color SA*, 2002: URL:https://www.comp.nus.edu.sg/~leowwk/papers/colordiff.pdf [datum pristupa 20.01.2018.]

Leon K, Mery D, Pedreschi D, Leon D. Color measurement in L*a*b* units from RGB digital images. *Food Research International,* 39: 1084-1091, 2006.

Lukinac-Čačić, J.: Matematičko modeliranje i optimiranje kinetike promjene boje kruha tijekom pečenja. *Doktorski rad*. Prehrambeno-tehnološki fakultet, Osijek, 2012.

Manley D: *Biscuit, cracker and cookie recipes for the food industry 1st edition*. Woodhead publishing Limited, Abington Hall, UK, 2000.

Manley D: *Biscuit packaging and storage*, Woodhead Publishing Ltd, Cambridge, UK, 1998.

Memarsadeghi N, Netanyahu NS, LeMoigne J: A Fast Implementation of the ISODATA Clustering Algorithm, *International Journal of Computational Geometry and Applications,* 17(1): 2057-2059, 2007.

Mendoza F, Dejmek P, Aguilera JM*:* Calibrated color measurements of agricultural foods using image analysis. *Postharvest Biology and Technology*, 41(3): 285-295, 2006.

Mokrzycki WS, Tatol M: Color difference Delta E - A survey. *Machine Graphics and Vision,* 20(4): 383-411, 2011.

Moslavac T, Jokić S, Jurić T, Krajna H, Konjarević A, Muhamedbegović B, Šubarić D: Utjecaj prešanja koštice buče i dodatka antioksidanasa na iskorištenje i oksidacijsku stabilnost hladno prešanog ulja*. Glasnik Zaštite Bilja,* 40 (6): 86-97, 2017.

Pedreschi F, Leon J, Mery D, Moyano P, Pedreschi R, Kaack K, Grandby K: Color development and acrylamide content of pre-dried potato chip*, Journal of Food Engineerings*, 79(3): 786-793, 2007a.

Pedreschi F, Bustos O, Mery D, Moyano P, Kaack K, Granby K: Color kinetics and acrylamide formation in NaCl soaked potato chips. *Journal of Food Engineering*, 79(3): 989-997, 2007b.

Pedreschi F, Leon J, Mery D, Moyano P: Development of a computer vision system to measure the color of potato chips. *Food Research International,* 39(10): 1092-1098, 2006.

Pletney VN: *Focus on Food Engineering Research and Developments.* Nova Science Publishers, Inc., New York, 2007.

Pomeranz Y, Meloan CE: *Measurement of color*. U Food Analysis: Theory and Practice. Y.M.C.E. Pomeranz. (ur.), New York, 1994.

Pravilnik o žitaricama i proizvodima od žitarica. NN, br. 81/2016.

Purlis E: Browning development in bakery product - A review*. Journal of Food Engineering,* 99(3): 239-249, 2010.

Purlis E, Salvadori VO: Modelling the browning of bread during baking*. Food Research International,* 42(7): 865-870, 2009.

Purlis E, Salvadori VO: Bread browning kinetics during baking. *Journal of Food Engineering,* 80(4): 1107-1115, 2007.

Ramírez-Jiménez A, Guerra-Hernández E, García-Villanova B: Browning indicators in bread. *Journal of Agricultural and Food Chemistry*, 48(9): 4176-4181, 2000.

Ridler TW, Calvard S: Picture thresholding using an iterative selection method. *IEEE Transactions on Systems, Man and Cybernetics*, 8(8): 630-632, 1978.

Russ JC, Neal FB: *The image Processing Handbook, 7th edition*. Taylor & Francis Group, New York, 2007.

Sanchez-Cuevas M, Aguilar-Ponce RM, Tecpanecatl-Xihuitl L: A Comparison of Color Models for Color Face Segmentation. *Procedia Technology*, 7: 134-141, 2013.

Schanda J: *CIE Colorimetry*, in Colorimetry: Understanding the CIE System (ed J. Schanda), John Wiley & Sons, Inc., Hoboken, USA, 2007.

Stokes M, Anderson M, Chandrasekar S, Motta R: *A Standard Default Color Space for the Internet – sRGB*, 1996. URL: http://www.w3.org/Graphics/Color/sRGB.html [datum pristupa: 11.3.2012.]

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

Strgar Kurečić M: *Formati zapisa slikovnih datoteka*. Grafički fakultet, 2014.

Strgar Kurečić M: Uvođenje CGRT testne karte boja za karakterizaciju digitalnog fotografskog sustava. *Doktorska disertacija*. Grafički fakultet, Zagreb, 2007.

van Boekel, M: Kinetic modeling of food quality: a critical review. *Comprehensive Reviews in Food Science and Food Safety,* 7(1): 144-158, 2008.

van Boekel M: Statistical aspects of kinetic modeling for food science problems. *Journal of Food Science*, 61(3): 477-486, 1996.

Wahlby U, Skjöldebrand C: Reheating characteristics of crust formed on buns, and crust formation*. Journal of Food Engineering,* 53(2): 177-184, 2002.

Web(1): Gonzalez, R. C., Woods, R. E., "*Digital Image processing*", Pearson Prentice Hall, 2008. URL: http://web.ipac.caltech.edu/staff/fmasci/home/astro_refs/Digital_Image_Processing_3rdEdtruncated.pdf [datum pristupa: 30.1.2018.].

Web (2): *Chromatic Wheel*. URL: https://openclipart.org/detail/181641/chromatic-wheel-1 [datum pristupa: 30.1.2018.].

Web (3): URL: https://ryanainsworthimedia.wordpress.com/2013/09/18/computer-arts-entry-3/ [datum pristupa: 30.1.2018.].

Web (4): *Building effective color scale*. URL: https://visual.ly/blog/building-effective-color-scales/ [datum pristupa: 30.1.2018.].

Web (5): *Wikipedia članak o RGB modelu boja*, RGB color model. URL: http://en.wikipedia.org/wiki/RGB_color_model [datum pristupa: 20.01.2018.].

Web (6): *Wikipedia članak o HSV modelu boja, HSL i HSV*. URL: http://en.wikipedia.org/wiki/HSL_and_HSV [datum pristupa: 20.01.2018.].

Web (7): Martin A: *Lab Colour Space and Delta E Measurements*. Chapter 4. Colour Management in the Graphic Technologies. U *Graphic Design and Print Production Fundamentals*. URL: https://opentextbc.ca/graphicdesign/chapter/4-4-lab-colour-space-and-delta-e-measurements/ [datum pristupa: 20.01.2018.].

Web (8): *Kolorimetar Konica Minolta CR-400*
URL:http://sensing.konicaminolta.asia/products/cr-400-410-chroma-meter-difference-with-colorimeter [datum pristupa: 20.01.2018.].

Web (9): *Nastavak za mjerenje boje praškastih materijala*. Konica Minolta CR-A50.
URL: http://www.aquateknica.com/product/colorimetro-procesador-datos-konica-minolta-cr-400/ [datum pristupa: 20.01.2018.].

Web (10): *Sjemenka buče*. URL: http://www.lamba.hr/lmb/wp-content/uploads/2012/01/bundeva-sjemenke.2.jpg [datum pristupa: 1.2.2018.].

Web (11): *Izgled sjemenki buče*.URL: https://www.stimuls.info/le-variet-di-semi-di-zucca-i.html [datum pristupa: 1.2.2018.].

Web (12): *Različite vrste buče*. URL: https://www.pinterest.com/pin/336784878368198563/ [datum pristupa: 1.2.2018.].

Yam KL, Papadakis SE: A simple digital imaging method for measuring and analyzing color of food surfaces. *Journal of Food Engineering*, 61(1): 137-142, 2004.

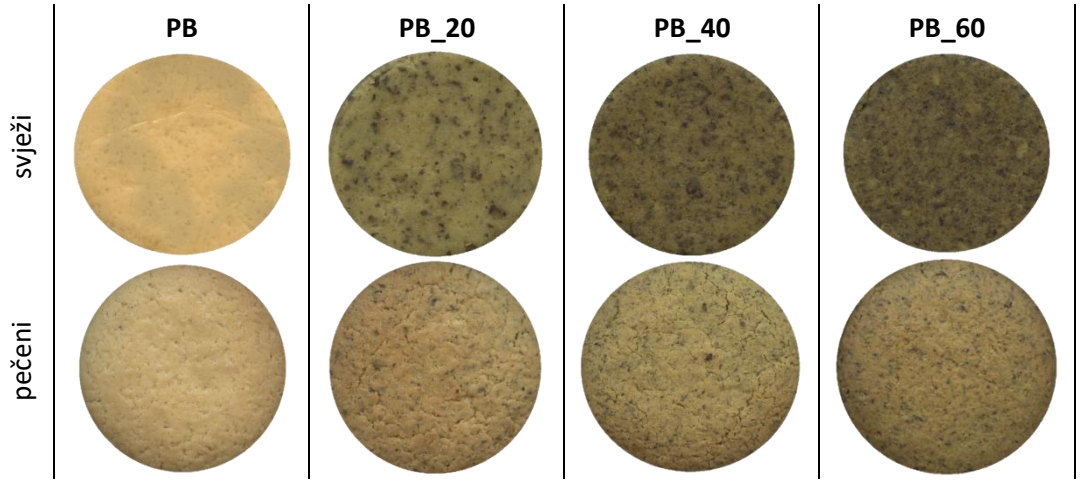
Zang J, Datta AK: Mathematical modeling of bread baking process. *Journal of Food Engineering*, 75(1): 78-89, 2006.

8. PRILOZI

Prilog 1. Tablica tisimulusnih referentnih vrijednosti parametara X, Y i Z za različit izvor rasvjete i standardnog promatrača [CIE1986.]

Observer	2° (CIE 1931)			10° (CIE 1964)			Note
Illuminant	X_2	Y_2	Z_2	X_{10}	Y_{10}	Z_{10}	
A	109.850	100.000	35.585	111.144	100.000	35.200	Incandescent/tungsten
B	99.0927	100.000	85.313	99.178;	100.000	84.3493	Old direct sunlight at noon
C	98.074	100.000	118.232	97.285	100.000	116.145	Old daylight
D50	96.422	100.000	82.521	96.720	100.000	81.427	ICC profile PCS
D55	95.682	100.000	92.149	95.799	100.000	90.926	Mid-morning daylight
D65	95.047	100.000	108.883	94.811	100.000	107.304	Daylight, sRGB, Adobe-RGB
D75	94.972	100.000	122.638	94.416	100.000	120.641	North sky daylight
E	100.000	100.000	100.000	100.000	100.000	100.000	Equal energy
F1	92.834	100.000	103.665	94.791	100.000	103.191	Daylight Fluorescent
F2	99.187	100.000	67.395	103.280	100.000	69.026	Cool fluorescent
F3	103.754	100.000	49.861	108.968	100.000	51.965	White Fluorescent
F4	109.147	100.000	38.813	114.961	100.000	40.963	Warm White Fluorescent
F5	90.872	100.000	98.723	93.369	100.000	98.636	Daylight Fluorescent
F6	97.309	100.000	60.191	102.148	100.000	62.074	Lite White Fluorescent
F7	95.044	100.000	108.755	95.792	100.000	107.687	Daylight fluorescent, D65 simulator
F8	96.413	100.000	82.333	97.115	100.000	81.135	Sylvania F40, D50 simulator
F9	100.365	100.000	67.868	102.116	100.000	67.826	Cool White Fluorescent
F10	96.174	100.000	81.712	99.001	100.000	83.134	Ultralume 50, Philips TL85
F11	100.966	100.000	64.370	103.866	100.000	65.627	Ultralume 40, Philips TL84
F12	108.046	100.000	39.228	111.428	100.000	40.353	Ultralume 30, Philips TL83

Prilog 2. Prikaz uzoraka čajnog peciva



Prilog 3. Kod programa za konverziju boja različitih modela

Standard-RGB → XYZ

//**sR**, **sG** and **sB** (Standard RGB) input range = 0 ÷ 255
//**X**, **Y** and **Z** output refer to a D65/2° standard illuminant.

```
var_R = ( sR / 255 )
var_G = ( sG / 255 )
var_B = ( sB / 255 )

if ( var_R > 0.04045 ) var_R = ( ( var_R + 0.055 ) / 1.055 ) ^ 2.4
else                   var_R = var_R / 12.92
if ( var_G > 0.04045 ) var_G = ( ( var_G + 0.055 ) / 1.055 ) ^ 2.4
else                   var_G = var_G / 12.92
if ( var_B > 0.04045 ) var_B = ( ( var_B + 0.055 ) / 1.055 ) ^ 2.4
else                   var_B = var_B / 12.92

var_R = var_R * 100
var_G = var_G * 100
var_B = var_B * 100

X = var_R * 0.4124 + var_G * 0.3576 + var_B * 0.1805
Y = var_R * 0.2126 + var_G * 0.7152 + var_B * 0.0722
Z = var_R * 0.0193 + var_G * 0.1192 + var_B * 0.9505
```

XYZ → CIELAB

//**Reference-X**, **Y** and **Z** refer to specific illuminants and observers.
// **X**, **Y** and **Z** output refer to a D65/2° standard illuminant.

```
var_X = X / Reference-X
var_Y = Y / Reference-Y
var_Z = Z / Reference-Z

if ( var_X > 0.008856 ) var_X = var_X ^ ( 1/3 )
else                    var_X = ( 7.787 * var_X ) + ( 16 / 116 )
if ( var_Y > 0.008856 ) var_Y = var_Y ^ ( 1/3 )
else                    var_Y = ( 7.787 * var_Y ) + ( 16 / 116 )
if ( var_Z > 0.008856 ) var_Z = var_Z ^ ( 1/3 )
else                    var_Z = ( 7.787 * var_Z ) + ( 16 / 116 )

CIE-L* = ( 116 * var_Y ) - 16
CIE-a* = 500 * ( var_X - var_Y )
CIE-b* = 200 * ( var_Y - var_Z )
```

Prilog 4. Izgled sjemenki buče (Web 11)



Prilog 5. Različite vrste buče (Web 12)

