Primjena računalne analize slike u praćenju boje čajnog peciva s dodatkom šećera različite granulacije

Solje, Lucija

Master's thesis / Diplomski rad

2015

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:109:596206

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Repository of the Faculty of Food Technology Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

PREHRAMBENO-TEHNOLOŠKI FAKULTET OSIJEK

Lucija Solje

PRIMJENA RAČUNALNE ANALIZE SLIKE U PRAĆENJU BOJE ČAJNOG PECIVA S DODATKOM ŠEĆERA RAZLIČITE GRANULACIJE

DIPLOMSKI RAD

Osijek, rujan, 2015

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

Znanstveno područje: Biotehničke znanosti
Znanstveno polje: Prehrambena tehnologija
Nastavni predmet: Modeliranje i upravljanje u prehrambeno-tehnološkim procesima
Tema rada je prihvaćena na IX. sjednici Fakultetskog vijeća Prehrambeno-tehnološkog fakulteta Osijek održanoj 21. 05. 2015.
Mentor: *dr. sc. Jasmina Lukinac Čačić, doc.*
Komentor: *dr. sc. Daliborka Koceva Komlenić, izv. prof.*

PRIMJENA RAČUNALNE ANALIZE SLIKE U PRAĆENJU BOJE ČAJNOG PECIVA S DODATKOM ŠEĆERA RAZLIČITE GRANULACIJE

Lucija Solje, 243-DI

Sažetak:
Zadatak ovog diplomskog rada bio je ispitati utjecaj različite granulacije šećera na promjenu boje čajnog peciva tijekom 10 minuta pečenja. Uzorci su pečeni na 180 ℃, 205 ℃ i 230 °C. Za mjerenje boje čajnog peciva korištena je računalna analiza slike. Uzorci su proizvedeni u laboratorijskim uvjetima kojima je dodan šećer različite granulacije (veličina kristala 800 µm, 1000 µm i šećer u prahu). Svaki uzorak je skeniran, slike obrađene računalnom analizom slike pomoću programa *ImageJ*. Dobiveni rezultati ukupne promjene boje čajnog peciva prikazani su grafički, rezultati svjetline tablično te su korišteni za određivanje kinetičkih parametara (konstanta brzine promjene boje) kod modela reakcija nultog, prvog i drugog reda. Iz rezultata je vidljivo da tijekom pečenja dolazi do tamnjenja čajnog peciva (uslijed Maillardovih reakcija i karamelizacije). Prosječne vrijednosti ukupne promjene boje svih uzoraka čajnog peciva najmanje su kod granulacije šećera od 1000 µm pri svim temperaturama pečenja. Nakon provedenog modeliranja, promjena boje čajnog peciva s dodatkom šećera u prahu te šećera granulacije 800 µm najbolje je opisana matematičkim modelom nultog reda pri svim temperaturama pečenja. Promjena boje uzoraka čajnog peciva s dodatkom šećera granulacije 1000 µm pri 180 °C najbolje je opisana nelinearnim oblikom matematičkim modela drugog reda, te nultog reda pri temperaturama pečenja 205 i 230 °C.

Ključne riječi: čajno pecivo, granulacija šećera, boja, računalna analiza slike, kinetički modeli

Rad sadrži: 42 stranice
15 slika
8 tablica
30 literaturnih reference

Jezik izvornika: Hrvatski

Sastav Povjerenstva za obranu:

1. dr. sc. *Sandra Budžaki,* doc. — predsjednik
2. dr. sc. *Jasmina Lukinac Čačić,* doc. — član-mentor
3. dr. sc. *Daliborka Koceva Komlenić,* izv. prof. — član-komentor
4. dr. sc. *Frane Čačić Kenjerić,* doc. — zamjena člana

Datum obrane: 30. rujan, 2015.

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
Department of Cereal Processing Technologies
Franje Kuhača 20, HR-31000 Osijek, Croatia

Scientific area: Biotechnical sciences
Scientific field: Food technology
Course title: Modeling and management in food technology processes
Thesis subject was approved by the Faculty Council of the Faculty of Food Technology at its session no. IX held on May 21, 2015.
Mentor: *Jasmina Lukinac Čačić*, PhD, assistant prof.
Co-supervisor: *Daliborka Koceva Komlenić*, PhD, associate prof.

APPLICATION OF DIGITAL IMAGE ANALYSIS FOR OBSERVATION OF COOKIES COLOUR PREPARED WITH DIFFERENT SUGAR GRANULATION

Lucija Solje, 243-DI

Summary:
The aim of this research was to investigate the influence of different sugar granulation on colour change of cookies during 10 minutes of baking at three different temperatures. The samples were baked at 180, 205 and 230 °C. To determine the colour change of samples digital image analysis was used. Samples were produced in the laboratory conditions with sugar crystal size of 800 µm, 1000 µm and powdered sugar. Each sample was scanned, and images were processed by using *ImageJ* program. Results of the colour changes are shown graphically and in tables. Modelling of cookies browning kinetics during baking was investigated by using zero-, first- and second-order kinetics models. Cookies surface lightness were used to determine kinetics parameters (browning rate constant) for models of reactions of zero, first and second order. The results show that during the baking samples surface become darker due to the Maillard reaction and caramelization. According to the obtained results, the smallest average values of total colour difference had samples with the sugar crystal size of 1000 µm for all baking temperatures. After performed modelling, the colour change of cookies with the addition of sugar powder and sugar crystal size of 800 µm were best described with zero order mathematical model for all tested baking temperatures. The colour change of cookies with the sugar crystal size 1000 µm were best described with the linear form of second order mathematical model at baking temperature 180 °C, and zero order mathematical order at baking temperatures 205 and 230 °C.

Key words: cookies, sugar granulation, colour, digital image analysis, kinetics models

Thesis contains: 42 pages
15 figures
8 tables
30 references

Original in: Croatian

Defense committee:

1. *Sandra Budžaki*, PhD, assistant prof. — chair person
2. *Jasmina Lukinac Čačić*, PhD, assistant prof. — Supervisor
3. *Daliborka Koceva Komlenić*, PhD, associate prof. — Co-supervisor
4. *Frane Čačić Kenjerić*, PhD, assistant prof. — stand-in

Defense date: September, 30 2015

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

Zahvaljujem se svojoj mentorici doc. dr. sc. Jasmini Lukinac Čačić na stručnoj pomoći i savjetima tijekom izrade ovog diplomskog rada.

Veliku zahvalnost dugujem ljudima koji su vjerovali u mene, podržavali me kroz sve godine studiranja, te zajedno sa mnom čekali da na svom putu stignem do cilja. Stoga prije svega zahvaljujem svojim roditeljima, sestri, bratu i prijateljima.

POPIS OZNAKA, KRATICA I SIMBOLA

AACC	Approved methods of the American Association of Cereal Chemists
ΔE	Ukupna promjena boje
CVS	Računalni vid (eng. *Computer Vision System*)
L^*	Parametar CIE$L^*a^*b^*$ prostora boje - svjetlina (eng. *lightness*)
R	Koeficijent korelacije, statistički parametar
AARDE	Srednja relativna pogreška, statistički parametar
0L	Reakcija promjene boje nultog reda
1NL	Reakcija promjene boje prvog reda; nelinearni oblik
1L	Reakcija promjene boje prvog reda; linearni oblik
2NL	Reakcija promjene boje drugog reda; nelinearni oblik
2L	Reakcija promjene boje drugog reda; linearni oblik
k	Konstanta brzine reakcije
RGB	RGB model boja (engl. *Red Green Blue*)
CMYK	CMYK model boja (engl. *Cyan Magenta Yellow Key*)

Sadržaj

1. UVOD 1

2. TEORIJSKI DIO 4

2.2. PROSTOR BOJA 8

2.3. RAZVOJ BOJE ČAJNOG PECIVA 10

2.4. ODREĐIVANJE BOJE ČAJNOG PECIVA 11

2.5. SUSTAV ZA RAČUNALNU ANALIZU SLIKE 11

2.6. ImageJ 13

3. EKSPERIMENTALNI DIO 14

3.1. ZADATAK 15

3.2. MATERIJALI 15

3.3. METODE 16

3.3.1. Proces proizvodnje čajnog peciva 16

3.3.2. Mjerenje boje čajnog peciva 17

3.3.3. Modeliranje kinetike promjene boje čajnog peciva tijekom pečenja 21

4. REZULTATI I RASPRAVA 23

4.1. REZULTATI ODREĐIVANJA BOJE ČAJNOG PECIVA 24

4.2. MODELIRANJE KINETIKE PROMJENE BOJE ČAJNOG PECIVA TIJEKOM PEČENJA 32

5. ZAKLJUČCI 37

6. LITERATURA 39

1. UVOD

Vanjski izgled čajnog peciva je prvo i najuočljivije svojstvo kvalitete. Kontroliranjem razvoja boje čajnog peciva i postizanjem što pravilnijeg oblika utječe se na svojstva kvalitete, no direktno i na same potrošače. 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). U ovim reakcijama mogu nastati i nepoželjni produkti s potencijalnim mutagenim djelovanjem (akrilamid, AA i hidroksimetilfurfural, HMF i furfural), a dolazi i do gubitka nutritivne vrijednosti proizvoda. 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.)

Prema Pravilniku o keksima i keksima srodnim proizvodima (NN br. 73, 2005.), ovi proizvodi se definiraju kao proizvodi određenih prehrambenih i senzorskih svojstava, dobiveni od mlinskih proizvoda, vode, masnoća, šećera, škroba te drugih sirovina i aditiva, tehnološkim postupcima miješenja, gnjetenja, tučenja, oblikovanja, pečenja i drugim postupcima.

Nastanak smeđe boje keksa i keksu srodnih proizvoda, pa tako i čajnog peciva ovisi o sastavu tijesta, odnosno tipu upotrijebljenog brašna, udjelu i aktivitetu vode, udjelu šećera, granulaciji šećera, pH vrijednosti i dr.

S druge strane brzina razvoja boje čajnog peciva varira i o procesnim uvjetima tijekom pečenja, kao temperatura i vrijeme pečenja koje je potrebno optimirati kako bi se postigla odgovarajuća boja proizvoda.

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 (HMF i furfurala), dok se indirektne metode zasnivaju na principu mjerenja količine reflektirane svjetlosti s površine analiziranog

uzorka uređajima kao što su kolorimetar, kromametar, a u novije vrijeme i sustav za računalnu analizu slike što potvrđuju brojna istraživanja. (Purlis, i Salvadori 2007., 2009.c; Purlis 2010., Ramirez-Jimenez i sur., 2000.a, 2000.b; van Boekel, 1996., 2008.)

U ovom radu ispitan je utjecaj granulacije šećera na promjenu boje čajnog peciva računalnom analizom slike, te je provedeno modeliranje kinetike promjene boje primjenom metode najmanjih kvadrata.

2. TEORIJSKI DIO

2.1. BOJA

Osjet boje predstavlja psihofizički doživljaj koji ovisi o izvoru svjetlosti, psihološkim i fiziološkim uvjetima promatrača i karakteristikama objekta koji se promatra. Često je boja svojstvo prehrambenih proizvoda koje se prvo uočava i direktno pretvara u pozitivan ili negativan predznak ukupne kvalitete proizvoda. (Lukinac Čačić, 2012.)

U tehnološkom smislu boja je svojevrsni indikator mogućih anomalija ili oštećenja proizvoda koja nastaju tijekom prerade, proizvodnje i skladištenja. (Pedreschi i sur., 2007.a, 2007.b)

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.)

Smisao za boje razmjerno se nedavno pojavio u povijesti ljudskog roda. Djeca i primitivni narodi razlikuju vrlo malo boja, ili ih barem teško imenuju. Stari narodi bili su vrlo siromašni u označavanju i imenovanju boja, no s razvojem industrije boja i tkanina, tiskarstva, kozmetike itd., razvijao se i taj smisao. Izvorno su boje nazivane prema predmetima za koje su bile karakteristične.

Osvijetljeni objekt može ukupnu svjetlost ili dio ukupne svjetlosti koja je pala na njegovu površinu, reflektirati, apsorbirati ili propustiti, ovisno o njegovoj prirodi, geometriji i površini. U praksi je ta svjetlost ograničena na dio spektra koji je vidljiv ljudskom oku, tj. na elektromagnetne valove duljine vala 380 - 770 nm (Hsien-Che, 2005.; Pomeranz i Meloan, 1994.). Dio tih valnih duljina 380 - 770 nm pripada vidljivoj svjetlosti, a svakoj valnoj duljini unutar tog raspona pripada jedna od boja. Cijeli spektar boja zastupljen je u bijeloj svjetlosti koja do nas dolazi sa Sunca. Cijeli raspon mogućih valnih duljina elektromagnetskog vala zovemo spektar.(Matoničkin, 2007.)

Boje se mogu definirati svojim uobičajenim imenima, no ipak postoje tri atributa koji uže definiraju svaku boju:

- ton boje ili tonalnost boje (engl. *hue*),
- zasićenost ili saturacija (engl. *saturation*),
- svjetlina ili luminancija (engl. *lightness*).

Ton boje označava vrstu boje. Definira se kao kromatska kvaliteta boje, odnosno kvaliteta kojom se jedna boja razlikuje od druge. Ton boje označava vrstu boje i definira se kao kromatska kvaliteta boje. Po tonu razlikujemo jednu boju 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 2.1.** Prikazuje kromatske boje.

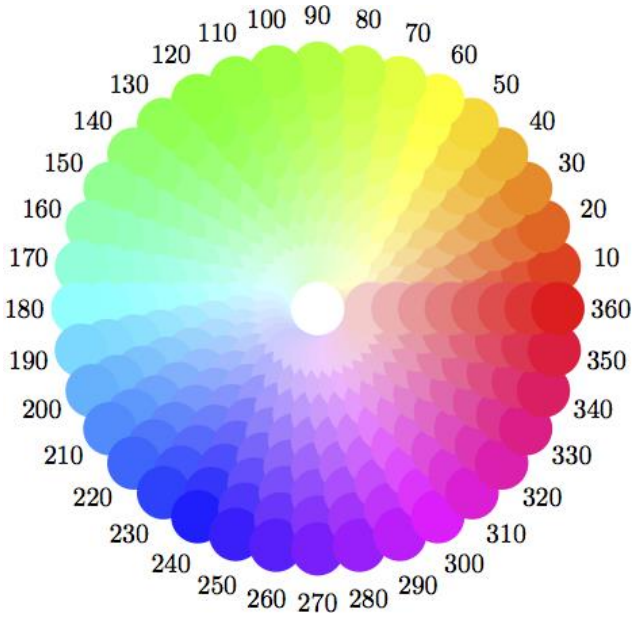

Slika 2.1. *Kromatske boje*

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. **Slika 2.2**. prikazuje akromatske boje.

Slika 2.2. *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. Svjetlina je osobina kromatske boje koja je usporediva sa svjetlinom sive akromatske boje. Svjetlina se također izražava u postocima od 0 % do 100 %. Vrijednost 0 % će dati crnu, a 100 % bijelu boju. **Slika 2.3.** prikazuje svjetlinu boje.

Slika 2.3. *Svjetlina boje (0 - 100 %)*

Zasićenost boje je stupanj čistoće boje, koji se određuje udjelom akromatskih boja (crna, siva, bijela) u kromatskim bojama (crvena, narančasta, žuta, zelena, itd.). 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 2.4.** prikazuje zasićenost boje. (Russ, 2007.)

Slika 2.4. *Zasićenost boje (0 - 100 %)*

2.2. PROSTOR BOJA

Prostor boja ili model boja je način pomoću kojeg se definiraju, stvaraju i vizualiziraju boje. Prostori boja su trodimenzionalni modeli, uz pomoć kojih je moguće pobliže odrediti i vizualizirati sve vidljive boje i one koje se mogu koristiti u određenom reprodukcijskom sistemu. Osnovna podjela prostora boja je na:

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

2.2.1. RGB prostor boja

Kod RGB prostora boja, slika se boja piksela određuje na osnovu tri komponente R (crvene), G (zelene) i B (plave). Vrijednosti ovih komponenti RGB slike se pamte u samoj matrici slike. Dakle, matrica slike je dimenzija *m* x *n* x 3, gdje su *m* i *n* broj vrsta, odnosno kolona matrice slike. Može se smatrati da se treća dimenzija sastoji od tri ravni čijom kombinacijom se dobivaju boje piksela. (Puglia, 2000.) **Slika 2.5.** Prikazuje RGB prostor boja.

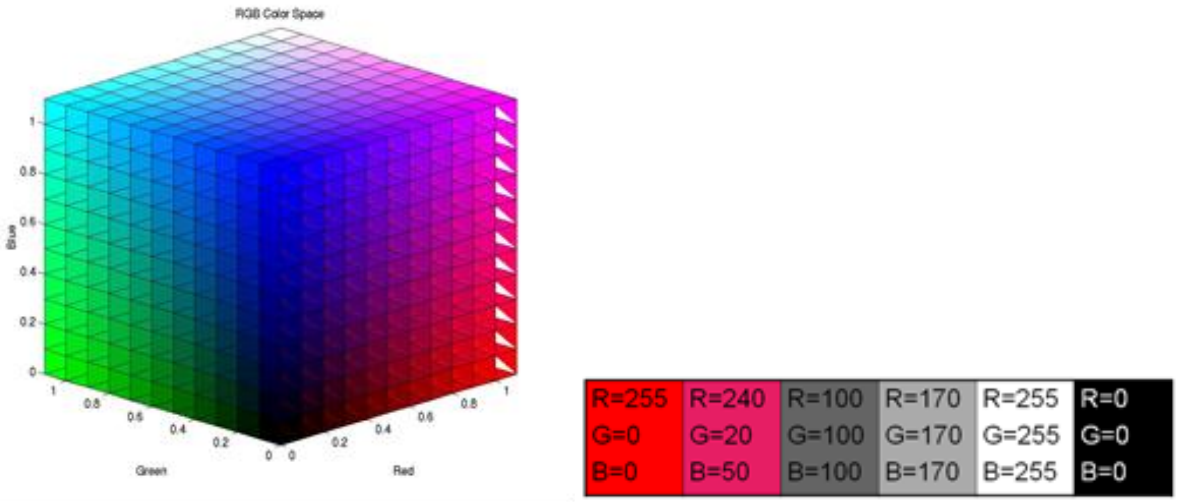

Slika 2.5. *RGB prostor boja*

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

CIE*L*a*b** je trodimenzionalni prostor boja baziran na percepciji boje standardnog promatrača. Smatra se neovisnim o uređaju. Numeričke vrijednosti u CIELAB sustavu opisuju sve boje koje može razlikovati svako zdravo ljudsko oko. CIE*L*a*b** prostor boja je opisan pomoću tri komponente: svjetlina ***L**** koja je akromatska komponenta i dvije kromatske komponente, ***a**** komponenta koja je odnos između crvene i zelene boje (negativne vrijednosti označavaju zelenu, a pozitivne crvenu) i ***b**** komponente koja je odnos plave i žute (negativne vrijednosti za plavu, a pozitivne za žutu). Svjetlina se mjeri od 1 do 100 po vertikalnoj osi, gdje je 1 vrijednost za crnu, a 100 za bijelu. (Strgar Kurečić, 2007.) **Slika 2.6.** prikazuje CIE*L*a*b** prostor boje.

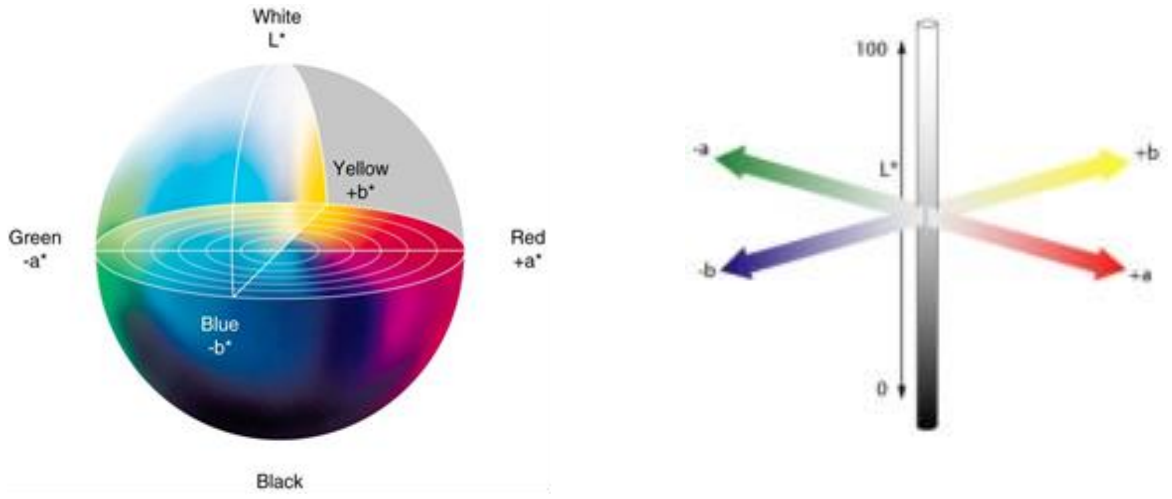

Slika 2.6. *CIEL*a*b* prostor boja*

2.3. RAZVOJ BOJE ČAJNOG PECIVA

Smeđa boja na površini čajnog peciva se razvija tokom pečenja, kao rezultat različitih toplinskih procesa u samom tijestu. To su procesi neenzimskog posmeđivanja kao što su Maillardove reakcije (između šećera i aminokiselina), karamelizacija (degradacija šećera pri povišenim temperaturama), te želatinizacija škroba, denaturacija proteina.

U procesu pečenja, temperatura na površini neprekidno raste i prvo dolazi do stvaranja tanke i elastične kore koja sprječava brže prodiranje topline do sredine tijesta. Kada temperatura dostigne 100 °C počinje isparavanje vode. Povišena temperatura i nizak udio vode utječu na stvaranje najprije svijetlih, žutih dekstrina, a zatim dolazi do stvaranja smeđe boje kao rezultat karamelizacije i Maillardovih reakcija. Daljnjim povećanjem temperature doći će do nastanka nepoželjne crne porozne mase. Maksimalna brzina razvoja boje na površini proizvoda događa se pri vrijednostima aktiviteta vode 0,7 – 0,8 i temperaturi iznad 120 °C (Purlis i Salvadori, 2009.c; Capuano i sur., 2008.).

Maillardove reakcije su reakcije između reducirajućih šećera i aminokiselina u kojoj osim razvoja arome i boje što su poželjna svojstva, mogu nastati i nepoželjni produkti poput hidroksimetilfurfurala, HMF i akrilamida, AA, sa potencijalnim mutagenim djelovanjem (Martins i sur., 2001.). Karamelizacija je proces degradacije šećera uslijed djelovanja povišene temperature, što ima za posljedicu promjenu boje i arome proizvoda. Promjena boje površine proizvoda smatra se bitnim parametrom determinacije završetka pečenja. (Purlis, i Salvadori 2007., 2009.c; Purlis 2010., Ramirez-Jimenez i sur., 2000.a, 2000.b; van Boekel, 1996., 2008.)

2.4. ODREĐIVANJE BOJE ČAJNOG PECIVA

Boja namirnice je prva karakteristika proizvoda koju potrošač uočava prilikom odabira. U tehnološkom smislu boja je svojevrsni indikator mogućih anomalija ili oštećenja proizvoda koja nastaju tijekom prerade, proizvodnje i skladištenja (Pedreschi i sur., 2007.a, 2007.b).

Do danas su razvijene brojne metode za praćenje boje na površini proizvoda. Metode se dijele na direktne i indirektne. Direktne metode usmjerene su na kvantitativno praćenje produkata Maillardovih reakcija i karamelizacije (AA, HMF i furfurala) (Ramirez-Jimenez, 2000.b), dok se indirektne metode zasnivaju na principu mjerenja reflektirane količine svjetlosti s površine analiziranog uzorka različitim mjernim uređajima. 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, no uspješno se koriste za određivanje boje homogenih uzoraka. Za objektivnu analizu, određivanje boje istog uzorka potrebno provesti na više različitih mjesta na uzorku. (Pletney, 2007.; Zeng i sur., 2007.; Magdić i sur., 2009.). Iz tog razloga, u novije vrijeme koristi se sustav za računalnu analizu slike. (Brosnan i Sun, 2002., 2004.; Zeng i sur., 2007.; Magdić i sur., 2006.) Računalna analiza slike može obuhvatiti cjelokupnu površinu uzorka, što ju čini objektivnijom i preciznijom metodom. (Mendoza i sur., 2006.)

2.5. SUSTAV ZA RAČUNALNU ANALIZU SLIKE

Boja površine uzorka primjenom računalne analize slike određuje se beskontaktno. Primjenom odgovarajućih računalnih algoritama moguće je dobiti vrlo točne i pouzdane informacije o promjeni boje proizvoda koje nastaju tijekom proizvodnje. Ova metoda za praćenje boje može se koristiti kao alat za automatsko vođenje procesa u industriji (za

vizualni pregled procesa proizvodnje) te time poboljšati ukupnu kvalitetu proizvoda. Prednost sustava za analizu slike, nad praćenjem boje ljudskim okom je objektivnost i kontinuiranost u procjeni boje. Sustav za analizu slike boju uzorka registrira s tri senzora boje, a sastoji se od tri najvažnija elementa: rasvjete, fotoaparata i računala. Slike dobivene skeniranjem uzoraka mogu obrađuju se slijedećim programima:

- *ImageJ* 1.43u (Wayne Rasband, National Institute of Health, USA)
- *Adobe Photoshop CS4 Extended 11.0* (Adobe Systems Incorporated, USA)
- *IrfanView* (Irfan Skiljan, Vienna)

2.5.1. Rasvjeta

Rasvjeta (engl. *illuminant*) ili vrsta svjetlosti predstavlja vrlo važan element kod računalne analize slike, obzirom da boja analiziranog uzorka (prehrambenog proizvoda) ovisi o količini svjetlosti koja se reflektira s površine uzorka. (Hsien-Che, 2005.)

Izvor svjetlosti je fizički realizirano zračenje (svijeća, lampa, sunce), kojeg karakteriziraju svojstva raspodjele spektralnog zračenja i temperature boje svjetlosti. Različiti izvori svjetla imaju različitu raspodjelu relativne energije zračenja. Osvijetljeni objekti prenose primljenu svjetlosti apsorpcijom, refleksijom i propuštanjem, te se razlika boja pojedinih uzoraka prati određivanjem razlike u količini reflektirane svjetlosti s njegove površine. Kut između osi objektiva fotoaparata te izvora svjetlosti koja osvjetljava uzorak trebao bi biti oko 45° (Yam i sur., 2004.).

2.5.2. Skener

Skener je ulazni uređaj za digitalizaciju, tj. neposredan unos slika, crteža ili teksta, najčešće s papira na računalo. Slike čajnih peciva dobili smo skeniranjem pojedinačnih peciva uz pomoć skenera. Tako dobivene slike čajnih peciva moguće je obraditi u nizu različitih programa. Jedan od njih je i *ImageJ*.

Princip rada skenera zasniva se na pretvorbi svjetlosti, koja se odbije od predmeta skeniranja (čajnog peciva) u električne impulse. Slika koja se želi unijeti u računalo osvjetljava se ugrađenim izvorom svjetlosti. Zrake svjetlosti koje se odbiju o predmet usmjeravaju se sustavom leća i ogledala prema senzorima svjetlosti za pretvorbu u električnu struju. Slika se pri tom postupku dijeli u točke i što je više tih točaka, to će slika biti veće kvalitete. Broj očitanih točaka naziva se razlučivost ili rezolucija.

2.6. ImageJ

ImageJ je program za računalnu analizu slike u kojem je moguće prikazati, urediti, analizirati, spremati i printati slike od 8, 16 i 32 bita. U programu je moguće izračunati područje i vrijednost piksela, izmjeriti udaljenosti i kutove, a sadrži i opcije za podešavanje kontrasta, izoštravanje, poravnavanje i dr. 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.

Makro naredbe (engl. *macros*) su nizovi naredbi/jednostavni programi koji omogućavaju automatizirano izvođenje funkcija. Zapisani su u .txt datoteci kao “običan” tekst, u makro jeziku (baziran na Javi) koji se interpretira u *ImageJ*-u, te omogućuju implementaciju automatiziranih naredbi povezivanjem postojećih funkcija u *ImageJ*-u.

3. EKSPERIMENTALNI DIO

3.1. ZADATAK

Zadatak ovog diplomskog rada bio je ispitati utjecaj različite granulacije šećera (veličina kristala < 800 μm, > 1000 μm i šećer u prahu) na promjenu boje čajnog peciva tijekom pečenja. Uzorci su pečeni 10 minuta na 180 ℃, 205 ℃ i 230 °C, te se pratila promjena boje tijekom svake minute pečenja. Za određivanje boje čajnog peciva korištena je računalna analiza slike. S ciljem modeliranje kinetike promjene boje čajnog peciva u ovom radu primijenjeni su kinetički modeli reakcija nultog, prvog i drugog reda. Parametri kinetičkih modela izračunati su metodom nelinearne regresije pomoću programa *Mathcad* primjenom metode najmanjih kvadrata. Svi uzorci obrađeni u ovom diplomskom radu napravljeni su u laboratorijskim uvjetima.

3.2. MATERIJALI

- Receptura: prema AACC 10-50D (AACC, 2000a),
- 450,0 g pšeničnog brašna (14 % vlage, Tena T550, oštro)
- 128,0 g shortening-a (margarin)
- 260,0 g šećera (kristal šećera)
- 4,2 g NaCl
- 5,0 g $NaHCO_3$ (1,11 % natrijevog hidrogenkarbonata)
- 66,0 g otopine glukoze (otopinu glukoze: 8,9 glukoze otopiti u 150 cm^3 destilirane vode)
- 32,0 g destilirane vode

3.3. METODE

3.3.1. Proces proizvodnje čajnog peciva

Čajna peciva dobivena i analizirana tokom priprave ovog diplomskog rada pripremljena, oblikovana i pečena su u laboratorijskim uvjetima od sirovina kupljenih u lokalnim trgovinama. Sirovine su vagane na laboratorijskoj vagi (Ohaus Adventurer Pro AV4102) prema recepturi AACC metode 10-50D (AACC, 2000a).

U posudu miksera prvo se doda izvagana masnoća, zatim se zasebno važu brašno, šećer, NaCl, $NaHCO_3$, otopina glukoze i destilirana voda. Odvaga sirovina za izradu jedne mase čine šaržu, čija veličina ovisi o ukupnoj masi sirovina koje su propisane AACC metodom. Izvagane sirovine (margarin, šećer, NaCl, $NaHCO_3$) su stavljene u posudu miksera, i miješaju se brzinom 1 (najsporije) tijekom tri minute. Za miješanje se koriste žičane mutilice miksera. Svake minute je potrebno zaustaviti mikser, i sastrugati sastojke sa stjenki posude, kako bi se svi sastojci ravnomjerno izmiješali. Nakon završetka miješanja potrebno je dodati otopinu glukoze i destiliranu vodu, te nastaviti miješanje brzinom 1 tijekom jednu minutu, a potom još jednu minutu brzinom 2 (srednja brzina miksera). Nakon što su se sirovine sjedinile, dodati ukupnu količinu brašna te sadržaj nastaviti miješati dvije minute brzinom 1 pri čemu je potrebno svakih trideset sekundi sastrugati sastojke sa stjenke posude. Dobiveno tijesto sakupiti ručno i okruglo oblikovati, staviti u PVC vrećicu te staviti u hladnjak (8°C) tijekom 30 – 60 minuta. Nakon što se tijesto ohladi važe se cjelokupna masa tijesta, razvalja se valjkom za tijesto na debljinu 7 mm u dva poteza valjka za tijesto (naprijed - nazad). Zatim se izrežu okrugli oblici tijesta promjera 60 mm (≈27g). Od svakog uzorka se ostavlja jedan komad oblikovanog tijesta nepečen, a 10 komada tijesta se peku jedan po jedan u pećnici od 1 minute pa do 10 minute. Sondama za praćenje temperature kontrolirana je temperatura u pećnici. Oblikovano tijesto peče se 10 minuta pri različitim temperaturama (180, 205 i 230 °C). Nakon pečenja čajno pecivo potrebno je hladiti 30 minuta pri sobnoj temperaturi. Nakon hlađenja svako pojedino čajno pecivo smo skenirali.

3.3.2. Mjerenje boje čajnog peciva

Mjerenje boje uzoraka računalnom analizom slike provedeno je u nekoliko koraka. Prvi korak je digitalizacija uzoraka (skeniranje) pomoću skenera Epson Perfection V500 Photo (Epson America, Inc., USA). Skener je smješten u tamnu komoru kako bi se postigli kontroliranu uvjeti rasvjete (komora ne dopušta osvjetljavanje uzoraka drugim izvorom svjetlosti). Nakon digitalizacije, slike su spremljene u TIFF formatu. Sijedeći korak je obrada i analiza slike računalnim programima *Adobe Photoshop* i *ImageJ*. Prvi dio obrade slike je segmentacija uzorka na slici te brisanje podloge (pomoću programa *Adobe Photoshop*) kako bi se kvantitativno opisao fotografirani uzorak pomoću izdvojenih podataka (u ovom slučaju parametri boje) i potom slijedi njena daljnja obrada u *ImageJ* programu. Kao rezultat mjerenja boje uzoraka čajnog peciva dobivaju se vrijednosti R, G i B prostora boja u svakoj točci na slici koje su potom prevedene u CIE$L^*a^*b^*$ prostor boja (prema jednadžbama 3.1 - 3.9). Mjerenje boje provedeno je na površini te donjem dijelu uzoraka čajnog peciva.

Određena boja je definirana određenim mjestom u CIE$L^*a^*b^*$ prostoru boja. Trodimenzionalni prostor predstavljaju tri međusobno okomite osi koje su označene kao L^*, a^* i b^*, a pri čemu je:

- L^* koordinata svjetline s podjelom od 0 (crna) do 100 (bijela);
- a^* koordinata obojenja s pozitivnim i negativnim smjerom tj. vektorom crvene boje, $+a^*$ (engl. *redness*) i vektorom za komplementarnu zelenu boju, $-a^*$ (engl. *grenness*);
- b^* koordinata obojenja s pozitivnim i negativnim smjerom tj. vektorom žute boje, $+b^*$ (eng. *yellowness*) i vektorom komplementarne plave boje, $-b^*$ (engl. *blueness*).

Pretvorba iz RGB u CIE$L^*a^*b^*$ prostor boja napravljena je prema slijedećim jednadžbama (Leon i sur., 2006.; Mendoza, 2006.):

$$R' = \frac{R}{255}; \qquad R' \begin{cases} \text{ako je}\left(R' > 0{,}04045\right)\text{onda vrijedi } R' = \left[\dfrac{\left(R + 0{,}055\right)}{1{,}055}\right]^{2,4} \\ \text{u protivnom vrijedi } R' = \left(\dfrac{R}{12{,}92}\right) \end{cases} \tag{3.1}$$

$$G' = \frac{G}{255}; \qquad G' \begin{cases} \text{ako je}\left(G' > 0{,}04045\right)\text{onda vrijedi } G' = \left[\dfrac{\left(R + 0{,}055\right)}{1{,}055}\right]^{2,4} \\ \text{u protivnom vrijedi } G' = \left(\dfrac{G}{12{,}92}\right) \end{cases} \tag{3.2}$$

$$B' = \frac{B}{255}; \qquad B' \begin{cases} \text{ako je}\left(B' > 0{,}04045\right)\text{onda vrijedi } B' = \left[\dfrac{\left(B + 0{,}055\right)}{1{,}055}\right]^{2,4} \\ \text{u protivnom vrijedi } B' = \left(\dfrac{B}{12{,}92}\right) \end{cases} \tag{3.3}$$

$$\begin{aligned} R' &= R' \cdot 100 \\ G' &= G' \cdot 100 \\ B' &= B' \cdot 100 \end{aligned} \tag{3.4}$$

$$\begin{aligned} X' &= R' \cdot 0{,}4124 + G' \cdot 0{,}3576 + B' \cdot 0{,}1805 \\ Y' &= R' \cdot 2126 + G' \cdot 0{,}7152 + B' \cdot 0{,}0722 \\ Z' &= R' \cdot 0{,}0193 + G' \cdot 0{,}1192 + B' \cdot 0{,}9505 \end{aligned} \tag{3.5}$$

$$X' = \frac{X}{X_n}; \qquad X' \begin{cases} \text{ako je}\left(X' > 0{,}008856\right)\text{onda vrijedi}\left(X'\right)^{1/3} \\ \text{u protivnom vrijedi } X' = \left(7{,}787 \cdot X'\right) + \left(\dfrac{16}{116}\right) \end{cases} \tag{3.6}$$

$$Y' = \frac{Y}{Y_n}; \qquad Y' \begin{cases} \text{ako je}\left(Y' > 0{,}008856\right)\text{onda vrijedi}\left(Y'\right)^{1/3} \\ \text{u protivnom vrijedi } Y' = \left(7{,}787 \cdot Y'\right) + \left(\dfrac{16}{116}\right) \end{cases} \tag{3.7}$$

$$Z' = \frac{Z}{Z_n}; \qquad Z' \begin{cases} \text{ako je}\left(Z' > 0{,}008856\right)\text{onda vrijedi}\left(Z'\right)^{1/3} \\ \text{u protivnom vrijedi } Z' = \left(7{,}787 \cdot Z'\right) + \left(\frac{16}{116}\right) \end{cases} \tag{3.8}$$

$$\begin{aligned} L^* &= \left(116 \cdot Y'\right) - 16 \\ a^* &= 500 \cdot \left(X' - Y'\right) \\ b^* &= 200 \cdot \left(Y' - Z'\right) \end{aligned} \tag{3.9}$$

Udaljenost između dvije točke u koordinatnom sustavu (razlika između dvije boje) izračunava se i definira kao fizikalna vrijednost tj. ukupna promjena boje, a odnos između izračunate vrijednosti ΔE i tolerancije ljudskog oka za uočavanje razlike između boja dana je u **Tablici 3.1** i ona je važan indikator promjene boje u procesima enzimskog i neenzimskog posmeđivanja. (Leon i sur., 2006.; Pedreschi i sur., 2007.; Wee i sur., 2006.)

Prema izmjerenim vrijednostima boje uzoraka (L^*, a^* i b^*) izračunata je ukupna promjena boje (ΔE) prema jednadžbi 3.10 (pri čemu L_0^*, a_0^* i b_0^* predstavljaju početne vrijednosti boje uzoraka).

$$\Delta E = \sqrt{\left(L_0^* - L^*\right)^2 + \left(a_0^* - a^*\right)^2 + \left(b_0^* - b^*\right)^2} \tag{3.10}$$

Tablica 3.1 Odnos između izračunate vrijednosti ukupne promjene boje (ΔE) i tolerancije ljudskog oka za uočavanje razlike između boja

ΔE	**oznaka**
<0,2	nije uočljiva
0,2-1	vrlo slabo uočljiva
1-3	slabo uočljiva
3-6	uočljiva
>6	vrlo uočljiva

Kako bi se provela automatizirana analiza slike uzoraka napravljena je makro naredba u programa *ImageJ* (engl. *macro*), a prikaz koda dan je u nastavku odlomka

Kod programa za provedbu računalne analize boje čajnog peciva u ImageJ-u:

```
requires("1.33n");
  dir = getDirectory("Choose a Directory ");
  list = getFileList(dir);
  run("Set Measurements...",
     "  mean display redirect=None decimal=3");
  roi = "";
  start = getTime();
  titles = newArray(list.length);
  run("Clear Results");
  setBatchMode(true); // runs up to 20 times faster
  j = 0;
  for (i=0; i<list.length; i++) {
      path = dir+list[i];
      if (endsWith(path, ".roi"))
          roi = path;
      else {
          open(path);
          title = getTitle();
          titles[j++] = title;
          //print(i+"  "+title);
run("Duplicate...", "title=dno_000m-1.tif");
run("8-bit");
setThreshold(0, 254);
run("Create Selection");
close();
run("RGB Split");
          measure(""+title+" (red)", roi);
          measure(""+title+" (green)", roi);
          measure(""+title+" (blue)", roi); }}
  reformatResults(titles);
  //print((getTime()-start)/1000);
  function measure(title, roi) {
      selectImage(title);
      if (roi!="") open(roi);
run("Restore Selection");// !!! bitno !!!
```

3.3.3. Modeliranje kinetike promjene boje čajnog peciva tijekom pečenja

Pri odabiru kinetičkih modela uzeti su u obzir slijedeći kriteriji:

- jednostavnost modela,
- obuhvaćanje malog broja parametara i
- zadovoljavanje kriterija točnosti.

Tablica 3.2. *Pregled kinetičkih modela rabljenih u kinetičkoj analizi*

Model	Kinetički model	Parametri modela	Broj jednadžbe
Nulti red	$L^* = L_0^* - k_{0NL} \cdot t$	k_{0L}	(3.11)
Prvi red nelinearna	$L^* = L_0^* \exp\left(-k_{1NL} \cdot t\right)$	k_{1NL}	(3.12)
Prvi red linearna	$\ln L^* = \ln L_0^* - k_{1L} \cdot t$	k_{1L}	(3.13)
Drugi red nelinearna	$L^* = \dfrac{L_0^*}{1 + L_0^* \cdot k_{2NL} \cdot t}$	k_{2NL}	(3.14)
Drugi red linearna	$\dfrac{1}{L^*} = \dfrac{1}{L_0^*} + k_{2L} \cdot t$	k_{2L}	(3.15)

Parametri modela određeni su nelinearnom regresijom eksperimentalnih podataka primjenom metode najmanjih kvadrata u programu *Mathcad* (**tablica 3.2**), a slaganje eksperimentalnih i izračunatih vrijednosti (prema navedenim modelima) određeno je pomoću statističkih parametara (R, AARD). Aproksimacija podataka modelom je bolja što su niže vrijednosti AARD ($\rightarrow 0$) te više vrijednosti za R ($\rightarrow 1$).

Koeficijent korelacije

$$R = \sqrt{1 - \frac{\sum_{i=1}^{N}\left(L^*_{pre,i} - L^*_{eks,i}\right)^2}{\sum_{i=1}^{N}\left(L^*_{eks,i} - L^*_{eks,sr}\right)^2}} \quad (3.16)$$

Srednja relativna pogreška [%]

$$AARD = \frac{100}{N} \cdot \sum_{i=1}^{N}\left|\frac{L^*_{eks,i} - L^*_{pre,i}}{L^*_{eks,i}}\right| \quad (3.17)$$

Modeliranje kinetike promjene boje čajnog peciva tijekom pečenja napravljeno je na eksperimentalnim podacima uzoraka čajnih peciva pečenim na temperaturi 180, 205 i 230 °C. Određivani parametri modela su red reakcije i konstanta brzine reakcije, s obzirom da je red reakcije definiran odabirom modela; regresijom je procjenjivana konstanta brzine promjene boje, *k.*

4. REZULTATI I RASPRAVA

4.1. REZULTATI ODREĐIVANJA BOJE ČAJNOG PECIVA

Eksperimentalni podaci dobiveni računalnom analizom slike prikazani su i interpretirani u obliku tablica i grafova. Grafički su prikazani rezultati ukupne promjene boje (ΔE) čajnog peciva tijekom vremena pečenja od 10 minuta. Uzorci se međusobno razlikuju obzirom na temperaturu pečenja (180, 205 i 230 °C) te granulaciju šećera (šećer u prahu, kristali veličine < 800 µm, kristali veličine > 1000 µm).

Na **Slikama 4.1 - 4.3** su prikazani rezultati ukupne promjene boje (ΔE) čajnog peciva s dodatkom šećera u prahu tijekom 10 minuta pečenja pri različitim temperaturama pečenja. Rezultati pokazuju da ukupna promjena boje raste tijekom pečenja te je najveća u 10-toj minuti pečenja za sve promatrane uzorke. Uspoređujući ukupnu promjenu boje uzoraka pri različitim temperaturama pečenja, najmanju ukupnu promjenu boje pokazali su uzorci pečeni na 180 °C

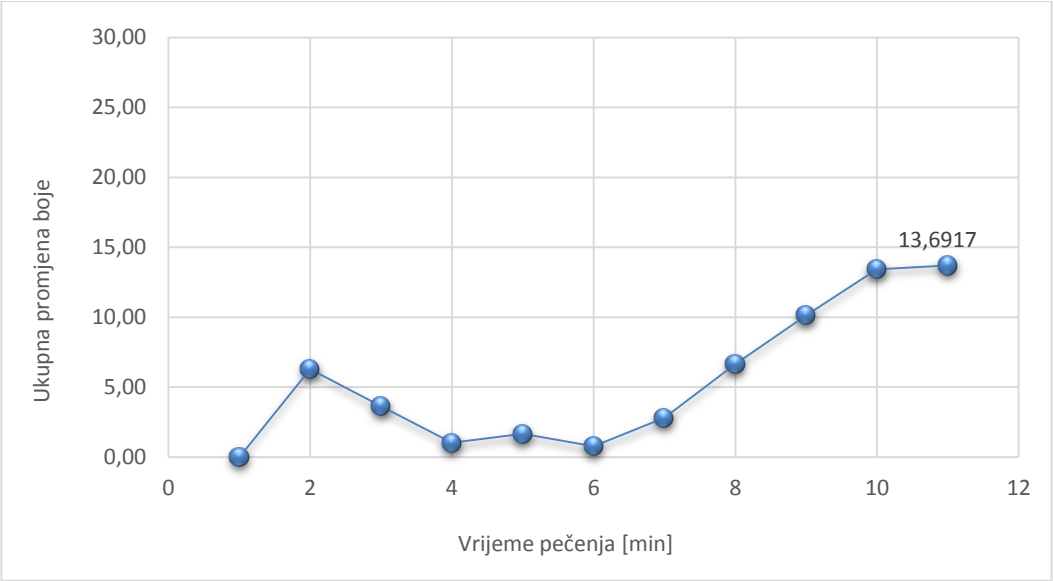

Slika 4.1 *Ukupna promjena boje čajnog peciva sa dodatkom šećera u prahu tijekom pečenja na temperaturi od 180 °C*

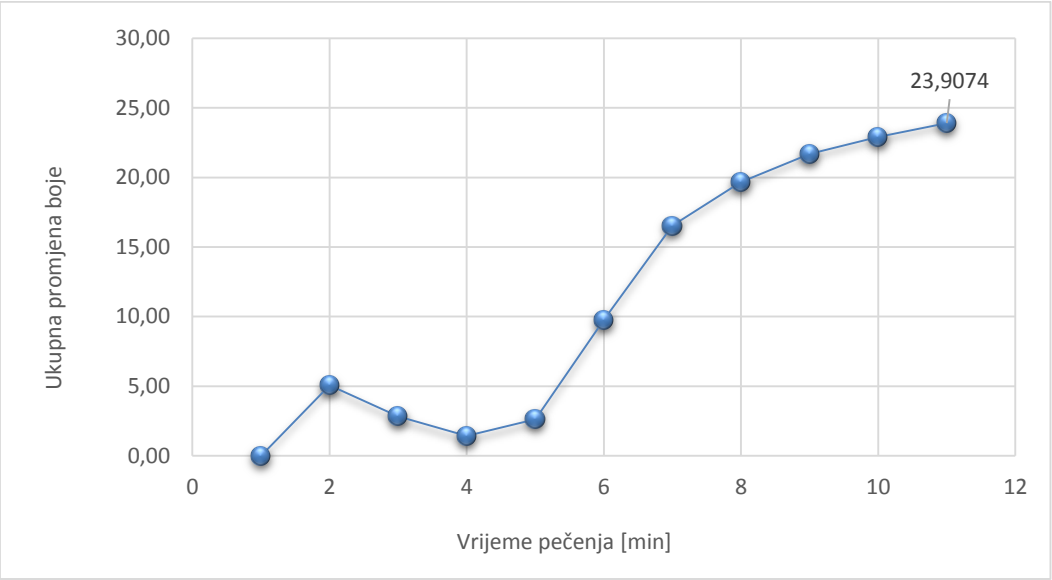

Slika 4.2 *Ukupna promjena boje čajnog peciva sa dodatkom šećera u prahu tijekom pečenja na temperaturi od 205 °C*

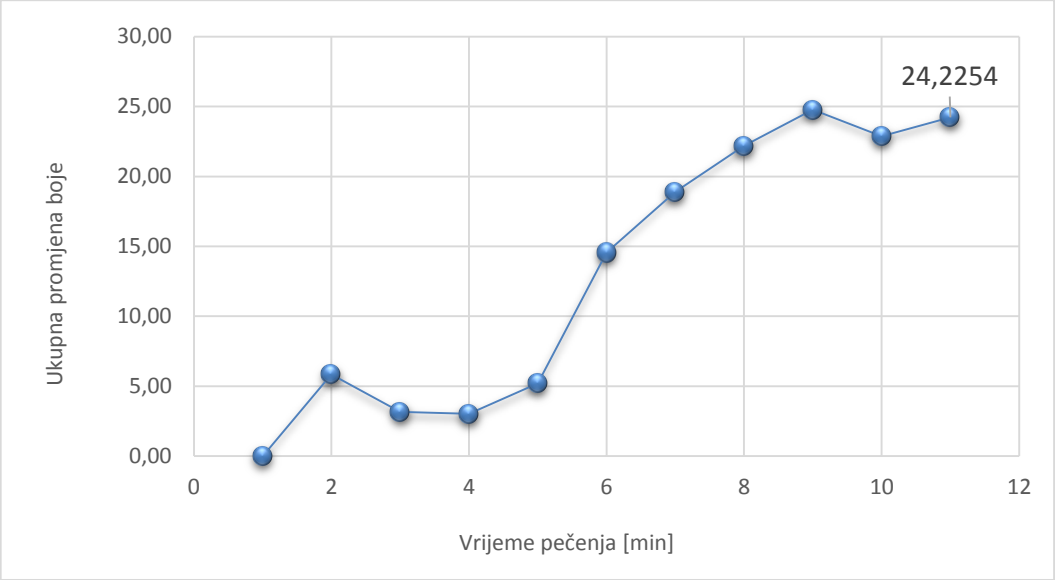

Slika 4.3 *Ukupna promjena boje čajnog peciva sa dodatkom šećera u prahu tijekom pečenja na temperaturi od 230 °C*

Na **Slikama 4.4 - 4.6** su prikazani rezultati ukupne promjene boje (ΔE) čajnog peciva s dodatkom šećera granulacije 800 μm tijekom 10 minuta pečenja pri različitim temperaturama pečenja. Rezultati pokazuju da ukupna promjena boje raste tijekom pečenja te je najveća u 10-toj minuti pečenja za sve promatrane uzorke.

Uspoređujući ukupnu promjenu boje uzoraka pri različitim temperaturama pečenja, najmanju ukupnu promjenu boje pokazali su uzorci pečeni na 180 °C.

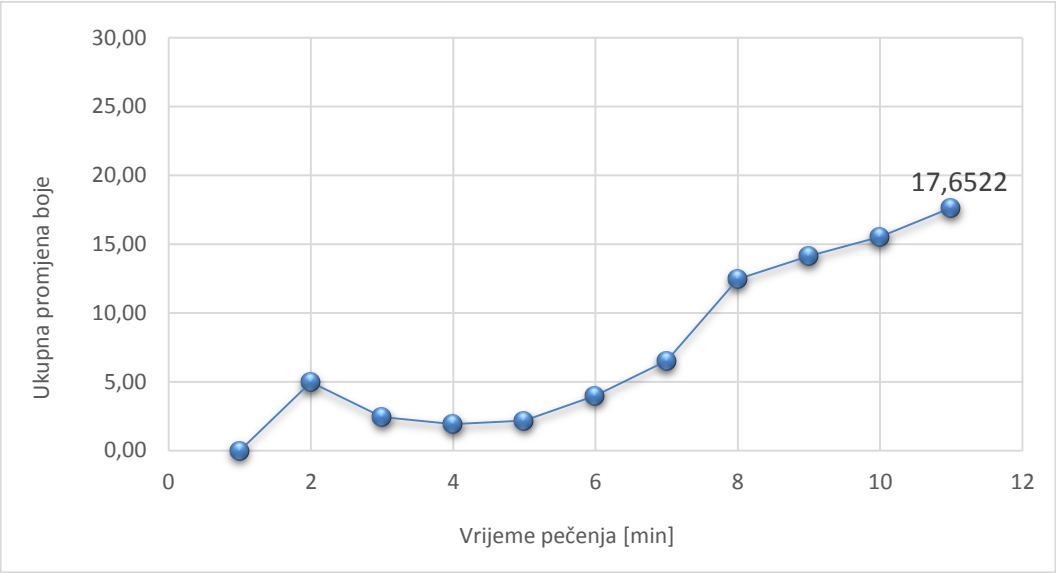

Slika 4.4 *Ukupna promjena boje čajnog peciva sa dodatkom šećera granulacije 800 μm tijekom pečenja na temperaturi od 180 °C*

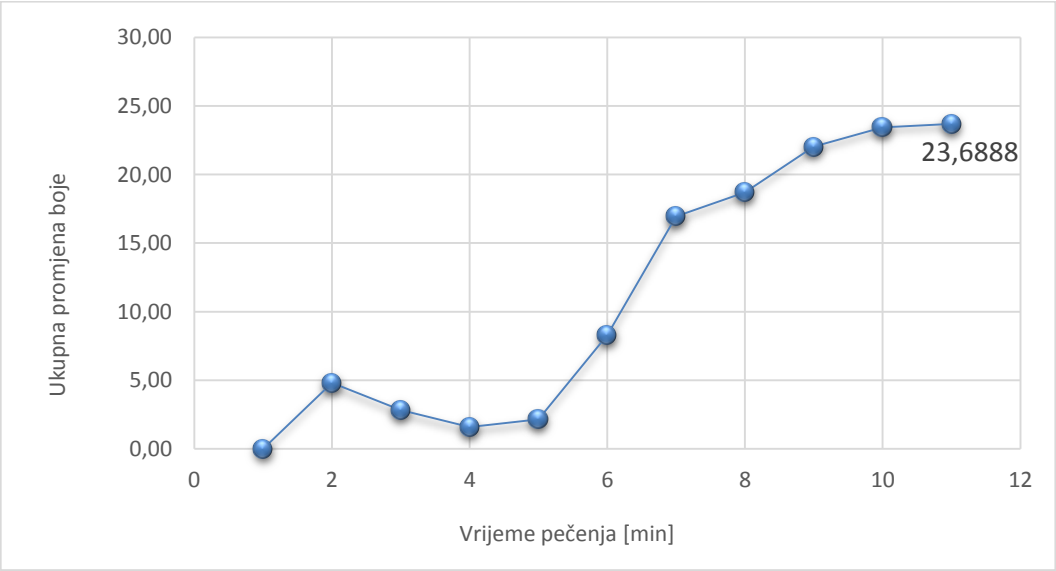

Slika 4.5 *Ukupna promjena boje čajnog peciva sa dodatkom šećera granulacije 800 μm tijekom pečenja na temperaturi od 205 °C*

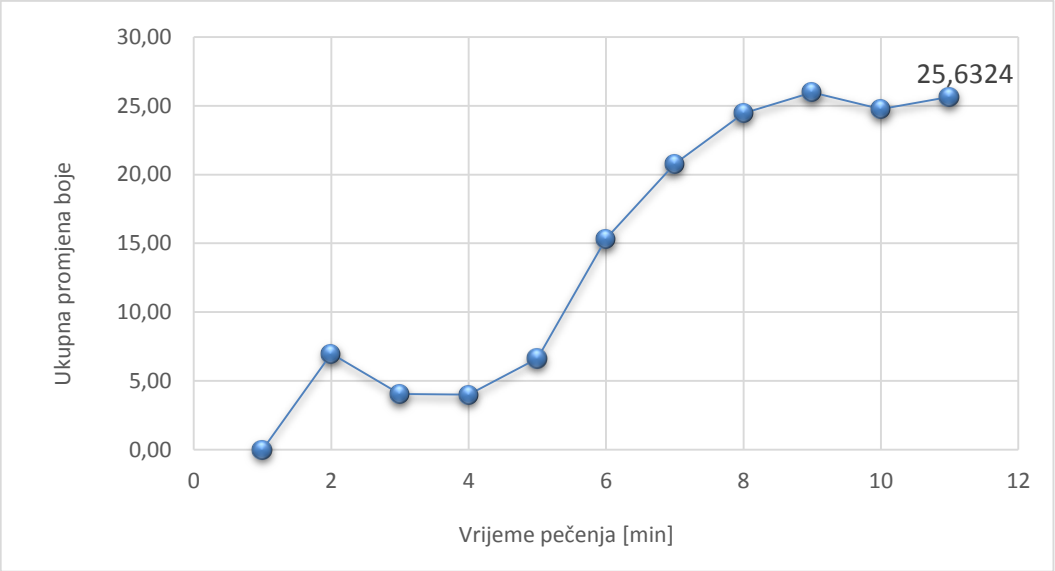

Slika 4.6 *Ukupna promjena boje čajnog peciva sa dodatkom šećera granulacije 800 μm tijekom pečenja na temperaturi od 230 °C*

Na **Slikama 4.7 - 4.9** su prikazani rezultati ukupne promjene boje (ΔE) čajnog peciva s dodatkom šećera granulacije 1000 μm tijekom 10 minuta pečenja pri različitim temperaturama pečenja. Rezultati pokazuju da ukupna promjena boje raste tijekom pečenja te je najveća u 10-toj minuti pečenja za sve promatrane uzorke. Uspoređujući ukupnu promjenu boje uzoraka pri različitim temperaturama pečenja, najmanju ukupnu promjenu boje pokazali su uzorci pečeni na 180 °C.

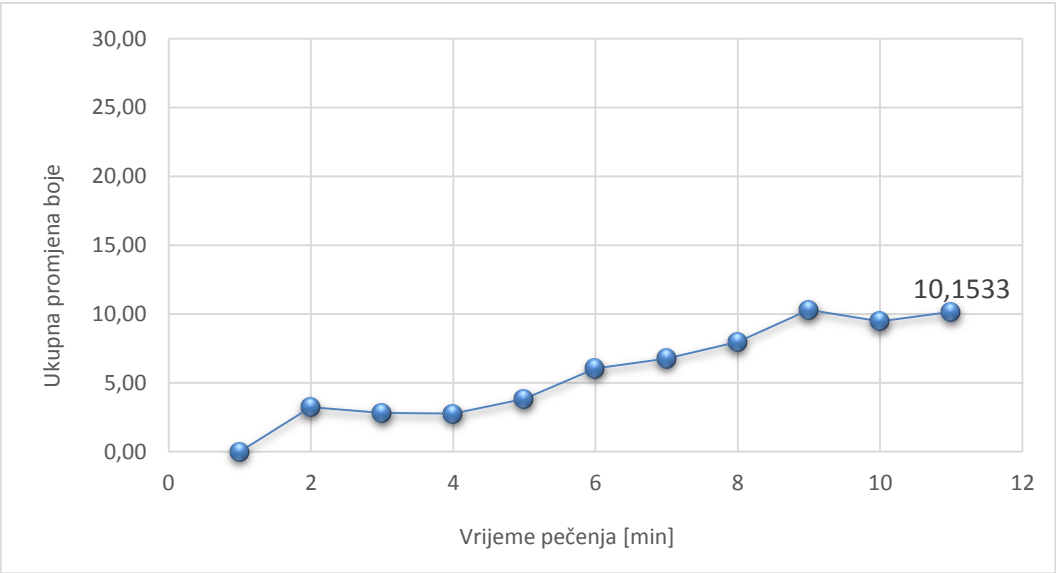

Slika 4.7 *Ukupna promjena boje čajnog peciva sa dodatkom šećera granulacije 1000 μm tijekom pečenja na temperaturi od 180 °C*

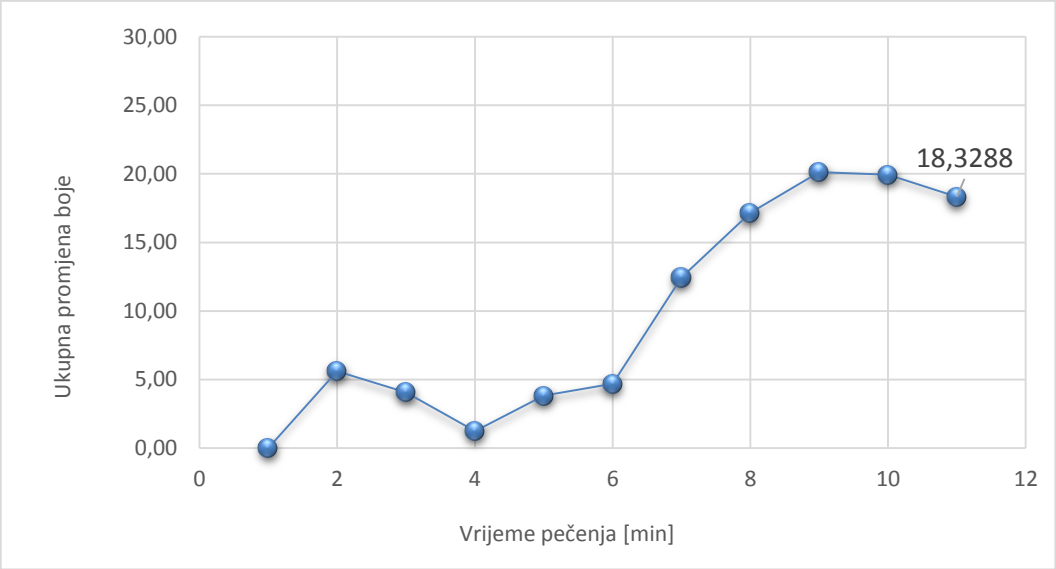

Slika 4.8 *Ukupna promjena boje čajnog peciva sa dodatkom šećera granulacije 1000 µm tijekom pečenja na temperaturi od 205 °C*

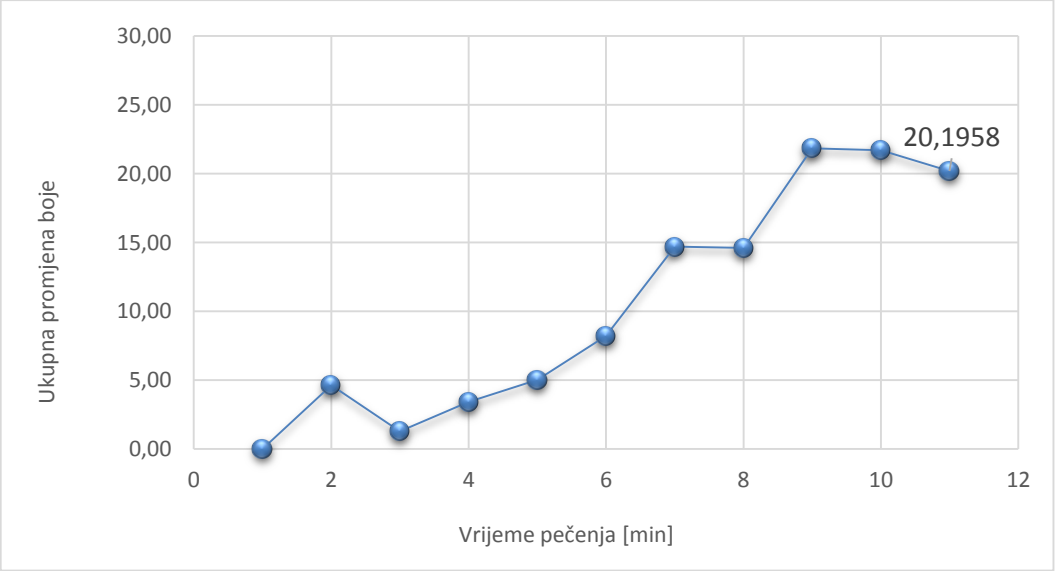

Slika 4.9 *Ukupna promjena boje čajnog peciva sa dodatkom šećera granulacije1000 µm tijekom pečenja na temperaturi od 230 °C*

Rezultati prosječne vrijednosti ukupne promjene boje pokazuju da je pri temperaturi pečenja 180 °C izmjerena najveća ukupna promjena boje kod uzorka s granulacijom šećera od 800 μm. Pri temperaturi 205 i 230 °C najveća ukupna promjena boje izmjerena je kod uzoraka s dodatkom šećera u prahu. Prosječne vrijednosti ukupne promjene boje svih uzoraka čajnog peciva najmanje su kod granulacije šećera od 1000 μm pri svim temperaturama pečenja

Tablica 4.1 *Vrijednosti parametara boje* ***površine*** *čajnog peciva sa dodatkom šećera u prahu (SP)*

Vrijeme pečenja [min]	Temperatura pečenja								
	180 °C			205 °C			230 °C		
	*L**	*a**	*b**	*L**	*a**	*b**	*L**	*a**	*b**
0	78,696	2,120	25,177	77,973	2,197	23,609	76,312	2,511	23,859
1	77,617	2,059	27,836	77,693	2,341	26,264	74,750	3,064	25,394
2	77,269	2,232	26,125	77,139	2,094	25,872	74,398	2,297	25,925
3	76,255	2,158	25,079	75,999	2,218	25,013	72,014	1,772	26,085
4	75,723	2,939	25,455	73,393	2,567	26,143	68,790	1,206	28,879
5	73,767	2,769	25,417	72,590	0,325	31,564	66,038	4,521	33,508
6	73,204	2,462	27,488	65,966	4,644	33,070	61,026	7,435	32,762
7	71,580	0,510	30,203	62,525	6,720	32,419	57,177	9,145	31,613
8	70,624	2,264	31,456	60,235	7,648	31,890	55,670	9,411	29,367
9	66,871	3,942	31,140	58,418	7,939	30,725	54,037	8,845	30,474
10	66,377	3,969	30,812	57,529	8,529	30,674	53,402	9,292	29,603

Tablica 4.2 *Vrijednosti parametara boje* ***površine*** *čajnog peciva sa dodatkom šećera granulacije 800 µm (S800)*

Vrijeme pečenja [min]	Temperatura pečenja								
	180 °C			205 °C			230 °C		
	*L**	*a**	*b**	*L**	*a**	*b**	*L**	*a**	*b**
0	77,860	2,348	23,812	76,815	2,348	23,812	76,232	-2,493	22,678
1	77,834	2,253	26,384	76,014	2,008	27,049	75,748	-2,971	25,612
2	77,603	2,170	26,212	75,914	2,079	25,720	75,680	-2,810	26,150
3	75,914	2,389	24,736	73,861	2,142	25,096	73,686	-1,998	26,635
4	75,584	2,560	24,774	72,887	2,275	25,961	69,433	-1,582	29,260
5	74,945	2,798	27,279	72,367	0,401	31,276	67,450	3,678	34,012
6	71,670	1,102	30,147	65,397	5,619	34,461	61,434	7,536	33,933
7	70,000	2,558	33,610	63,062	6,481	34,135	56,500	9,494	31,823
8	68,477	3,954	34,046	58,771	8,209	32,800	55,810	10,188	31,401
9	67,271	5,104	34,333	56,891	8,919	31,559	54,946	9,195	31,538
10	64,132	6,625	33,419	56,492	9,060	31,148	54,849	9,858	31,151

Tablica 4.3 *Vrijednosti parametara boje* ***površine*** *čajnog peciva sa dodatkom šećera granulacije 1000 µm (S1000)*

Vrijeme pečenja [min]	Temperatura pečenja								
	180 °C			205 °C			230 °C		
	*L**	*a**	*b**	*L**	*a**	*b**	*L**	*a**	*b**
0	75,487	3,283	25,107	75,008	2,400	24,764	74,090	3,007	26,066
1	74,480	2,516	28,246	74,933	2,758	26,156	73,246	3,229	27,822
2	73,559	2,089	27,652	74,927	2,220	26,784	71,014	2,472	27,230
3	72,444	2,171	25,920	74,502	2,417	26,009	70,647	2,049	27,999
4	70,952	2,331	26,355	71,408	2,046	28,579	70,593	1,936	29,530
5	70,180	2,629	29,168	69,507	1,930	29,409	66,302	0,144	33,635
6	70,048	2,598	29,056	68,832	2,282	34,544	63,666	5,893	35,189
7	70,029	0,202	32,404	64,453	6,201	35,300	63,253	5,891	35,355
8	69,024	2,193	33,692	61,899	7,876	33,991	55,438	9,789	30,460
9	68,493	2,347	32,640	60,296	7,430	33,911	53,799	9,868	30,888
10	68,417	2,456	33,323	60,175	6,598	33,996	53,451	9,213	31,439

4.2. MODELIRANJE KINETIKE PROMJENE BOJE ČAJNOG PECIVA TIJEKOM PEČENJA

U ovom radu provedeno je modeliranje kinetike promjene boje čajnog peciva sa dodatkom šećera različite granulacije pri temperaturama pečenja 180, 205 i 230 °C. Modeliranje kinetike određenog procesa ima važnu ulogu u dizajniranju procesa budući da daje nužne informacije o brzini reakcije ili nastajanju određenih promjena kao funkcije eksperimentalnih varijabli. Pri odabiru proizvoda potrošač najprije zamjećuje vanjski izgled proizvoda što podrazumijeva boju i oblik. Promjena boje na površini proizvoda, osim velikog utjecaja na odabir tijekom kupovine, bitna je i kao indikator drugih (sekundarnih) promjena koje se događaju u hrani tijekom procesa pečenja (primjerice razvoj arome, nastanak nepoželjnih toksičnih supstanci poput AA, smanjenje nutritivne vrijednosti proteina i slično).

Promjena boje uzoraka izražena je parametrima boje L^*, a^* *i* b^*odnosno kao ukupna promjena boje (ΔE). Iako su mjerenjem dobivena sva tri parametra boje CIE$L^*a^*b^*$ modela, za procjenu kinetike promjene boje u obzir je uzet samo parametar L^*. Brojna istraživanja potvrđuju primjenu parametra L^* uzorka za opisivanje dinamike procesa razvoja boje, budući da njegova vrijednost korelira s utjecajem parametara proizvodnje čajnog peciva (temperatura i vrijeme pečenja).

Za opisivanje kinetike razvoja boje uzoraka ispitani su kinetički modeli reakcija nultog, prvog i drugog reda prema jednadžbama (**3.11 – 3.15**). Na osnovu veličina modela (promjene svjetline u funkciji vremena, reda reakcije te konstante brzine reakcije) moguće je procijeniti brzinu razvoja boje površine čajnog peciva tijekom pečenja. Parametri modela određeni su nelinearnom regresijom eksperimentalnih podataka primjenom metode najmanjih kvadrata (**Tablica 4.4 – 4.6**) u programu *Mathcad,* te su na osnovu njih konstruirane krivulje brzine promjene boje koje su uspoređene sa eksperimentalnim podacima. Uspješnost primjene odabranih matematičkih modela analizirana je na osnovi više statističkih kriterija. U ovom radu prikazani su koeficijent korelacije (R), koji bi idealnom slučaju imao vrijednost 1, te srednja relativna pogreška (AARD).

Tablica 4.4 *Rezultati kinetičkih parametara (uzorak: čajno pecivo sa dodatkom šećera u prahu)*

Temperatura pečenja	180 °C	205 °C	230 °C
Parametar			
		Nulti red	
k_{CVS} [min^{-1}]	**1,1024**	**1,9620**	**2,3895**
R	**0,9677**	**0,9472**	**0,9779**
AARD	**1,1938**	**2,9987**	**2,3816**
		Prvi red, linearni	
k_{CVS} [min^{-1}]	0,0149	0,0284	0,0362
R	0,9605	0,9407	0,9728
AARD	0,3082	0,7774	0,6134
		Prvi red, nelinearni	
k_{CVS} [min^{-1}]	0,0148	0,0277	0,0356
R	0,9620	0,9359	0,9706
AARD	1,3001	3,3616	2,5926
		Drugi red, linearni	
k_{CVS} [min^{-1}]	2,0271E-04	4,1517E-04	5,5398E-04
R	0,9525	0,9334	0,9659
AARD	1,4486	3,6904	2,9641
		Drugi red, nelinearni	
k_{CVS} [min^{-1}]	1,9776E-04	3,8924E-04	5,2863E-04
R	0,9561	0,9236	0,9601
AARD	1,3892	3,7339	3,1410

Tablica 4.5 *Rezultati kinetičkih parametara (uzorak: čajno pecivo sa dodatkom šećera granulacije 800)*

Temperatura pečenja	180 °C	205 °C	230 °C
Parametar			
Nulti red			
k_{CVS} [min^{-1}]	**1,1166**	**1,9257**	**2,2752**
R	**0,9410**	**0,9418**	**0,9550**
AARD	**1,6791**	**3,0095**	**3,3772**
Prvi red, linearni			
k_{CVS} [min^{-1}]	0,0154	0,0284	0,0344
R	0,9341	0,9333	0,9500
AARD	0,4198	0,8004	0,8459
Prvi red, nelinearni			
k_{CVS} [min^{-1}]	0,0151	0,0275	0,0337
R	0,9334	0,9295	0,9466
AARD	1,8010	3,4281	3,5493
Drugi red, linearni			
k_{CVS} [min^{-1}]	2,1206E-04	4,2136E-04	5,2364E-04
R	0,9265	0,9239	0,9439
AARD	1,9344	3,8674	3,8099
Drugi red, nelinearni			
k_{CVS} [min^{-1}]	2,0394E-04	3,9248E-04	4,9563E-04
R	0,9256	0,9163	0,9355
AARD	1,9189	3,8098	3,9219

Tablica 4.6 *Rezultati kinetičkih parametara (uzorak: čajno pecivo sa dodatkom šećera granulacije 1000)*

Temperatura pečenja	180 °C	205 °C	230 °C
Parametar			
Nulti red			
k_{CVS} [min^{-1}]	08734	**1,4032**	**1,9414**
R	0,8040	**0,9391**	**0,9514**
AARD	1,5299	**2,5081**	**3,1208**
Prvi red, linearni			
k_{CVS} [min^{-1}]	0,0121	0,0205	0,0298
R	0,8069	0,9334	0,9387
AARD	0,3407	0,6351	0,8676
Prvi red, nelinearni			
k_{CVS} [min^{-1}]	0,0122	0,0200	0,0290
R	0,7171	0,9301	0,9391
AARD	1,7823	2,7276	3,5770
Drugi red, linearni			
k_{CVS} [min^{-1}]	1,6761E-04	2,999E-04	4,6157E-04
R	0,8092	0,9272	0,9245
AARD	1,3586	2,8898	4,1020
Drugi red, nelinearni			
k_{CVS} [min^{-1}]	**1,7033E-04**	2,8558E-04	4,3065E-04
R	**0,8308**	0,9207	0,9260
AARD	**1,4054**	2,9276	3,9831

Za sve ispitane modele srednja relativna pogreška (AARD) bila je manja od 5 % pri svim temperaturama pečenja (**Tablica 4.4 - 4.6**). Relativno niske vrijednosti AARD potvrđuju prikladnost korištenih matematičkih modela za opisivanje kinetike posmeđivanja čajnog peciva. Izračunate vrijednosti konstanti brzine reakcije promjene boje (*k*) proporcionalno rastu, porastom temperature pečenja za sve uzorke (**Tablice 4.4 – 4.6)**. Porastom temperature pečenja proporcionalno raste konstanta brzine razvoja boje površine čajnog peciva što je za očekivati obzirom da boja na površini uzorka nastaje uslijed reakcija neenzimskog posmeđivanja (karamelizacije te Maillardovih reakcija) kada je na površini uzorka postignuta temperatura iznad 110 °C.

Nelinearni oblik kinetičkog modela nultog reda najbolje opisuje eksperimentalne podatke boje većine uzoraka (najveće vrijednosti koeficijenta korelacije, R). Iznimka su uzorci čajnog peciva s dodatkom šećera granulacije 1000 μm pri temperaturi pečenja 180 °C koje najbolje opisuje nelinearni oblik kinetičkog modela drugog reda.

5.ZAKLJUČCI

Na osnovu rezultata dobivenih računalnom analizom slike uzoraka čajnog peciva pečenih 10 minuta na 180, 205 i 230 °C, mogu se izvesti sljedeći zaključci:

- Rezultati pokazuju da ukupna promjena boje raste tijekom pečenja te je najveća u 10-toj minuti pečenja za sve promatrane uzorke.
- Rezultati prosječne vrijednosti ukupne promjene boje pokazuju da je pri temperaturi pečenja od 180 ℃ izmjerena najveća ukupna promjena boje kod uzorka s granulacijom šećera od 800 μm.
- Pri temperaturi pečenja od 205 °C i 230 °C najveća ukupna promjena boje izmjerena je kod uzoraka s dodatkom šećera u prahu.
- Prosječne vrijednosti ukupne promjene boje svih uzoraka čajnog peciva najmanje su kod granulacije šećera od 1000 μm pri svim temperaturama pečenja

Na osnovu rezultata (R, AARD) dobivenih pomoću kinetičkih modela reakcija nultog, prvog i drugog reda, mogu se izvesti sljedeći zaključci:

- Za sve ispitane modele srednja relativna pogreška (AARD) bila je manja od 5 % pri svim temperaturama pečenja
- Na osnovu veličina modela (promjene svjetline u funkciji vremena, reda reakcije te konstante brzine reakcije) moguće je procijeniti brzinu razvoja boje površine čajnog peciva tijekom pečenja. Relativno niske vrijednosti AARD potvrđuju prikladnost korištenih matematičkih modela za opisivanje kinetike posmeđivanja čajnog peciva
- Porastom temperature pečenja proporcionalno raste konstanta brzine razvoja boje površine čajnog peciva što je za očekivati obzirom da boja na površini uzorka nastaje uslijed reakcija neenzimskog posmeđivanja (karamelizacije te Maillardovih reakcija) kada je na površini uzorka postignuta temperatura iznad 110 °C
- Nelinearni oblik kinetičkog modela nultog reda najbolje opisuje eksperimentalne podatke boje većine uzoraka (najveće vrijednosti koeficijenta korelacije, R). Iznimka su uzorci čajnog peciva s dodatkom šećera granulacije 1000 μm pri temperaturi pečenja 180 °C koje najbolje opisuje nelinearni oblik kinetičkog modela drugog reda.

6. LITERATURA

1. **Capuano, E., Ferrigno, A., Acampa, I., Ait-Ameur, L., Fogliano, V.** Characterization of the Maillard reaction in bread crisps. *European Food Research Technology*, 2008.
2. **Elektrotehnički fakultet,** Digitalna obrada slike
3. **Hodge, J.E.** Chemistry of Browning Reactions in Model Systems. *Agricultural and Food Chemistry*, 1953.
4. **Hsien-Che L**.: Introduction to Color Imaging Science. Cambridge University Press, New York, 2005.
5. **Goran Matoničkin**, Elektromagnetni valovi u nastavi fizike, Zagreb 2007.
6. **Leon, K., Mery, D., Pedreschi, F., Leon, J.** Color measurement in $L^*a^*b^*$ units from RGB digital images. *Food Research International*., 2006.
7. **Maja Strgar Kurečić,** Kontrola boja -od percepcije do mjerenja
8. **Martins, S.I.F.S., Jongen, W.M.F., van Boekel, M.A.J.S.** A review of Maillard reaction in food and implications to kinetic modeling. *Trends in Food Science & Technology*, 2001.
9. **Mendoza, F., Dejmek, P., Aguilera, J.M.** Calibrated color measurements of agricultural foods using image analysis. *Postharvest Biology and Technology,* 2006.
10. **Magdić, D., Lukinac, J., Jokić, S., Čačić Kenjerić, F., Bilić, M., Velić, D.** Impact analysis of different chemical pre-treatments on colour of apple discs during drying process. *Croatian Journal of Food Science and Technology.*, 2009.
11. **Pedreschi, F., Leon, J., Mery, D., Moyano, P., Pedreschi, R., Kaack, K., Grandby, K.** Color development and acrylamide content of pre-dried potato chips. *Journal of Food Engineering*, 2007a.
12. **L. Hsien-Che**: Introduction to Color Imaging Science. Cambridge University Press, New York, 2005.
13. **Lukinac-Čačić, J.:** Matematičko modeliranje i optimiranje kinetike promjene boje kruha tijekom pečenja. Doktorski rad. Prehrambeno-tehnološki fakultet, Osijek, 2012.
14. **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,* 2007b

15. **Pedreschi, F., Leon, J., Mery, D., Moyano, P.** Development of a computer vision system to measure the color of potato chips. *Food Research International.*, 2006
16. **Pomeranz, Y., Meloan C.E**.: Measurement of color. U Food Analysis: Theory and Practice. Y.M.C.E. Pomeranz. (ur.), New York, 1994.
17. **Pravilnik o keksima i keksima srodnim proizvodima** (NN, br. 73/2005 i 69/2008)
18. Puglia S.: Technical Primer U Handbook for Digital Projects: A Management Tool for Preservation and Access Maxine K. Sitts.(ur.) Northeast Document Conservation Center, 2000. URL:http://www.nedcc.org/resources/digitalhandbook/dman.pdf (15.07.2015.)
19. **Purlis, E., Salvadori, V.O.** Bread browning kinetics during baking. *Journal of Food Engineering*, 2007.
20. **Purlis, E., Salvadori, V.O.** Modelling the browning of bread during baking. *Food Research International.* 2009c.
21. **Purlis, E.** Browning development in bakery product - A review*. Journal of Food Engineering*, 2010.
22. **Ramirez-Jimenez, A., Garcia-Villanova, B., Guerra-Hernandez, E.** Hydroxymethylfurfural and methylfurfural content of selected bakery products. *Food Research International*. 2000a.
23. **Ramírez-Jiménez, A., Guerra-Hernández, E., García-Villanova, B**. Browning indicators in bread. *Journal of Agricultural and Food Chemistry*, 2000b.
24. **Russ J.C.**: The image Processing Handbook, Taylor & Francis Group, New York, 2007.
25. **van Boekel, M.A.J.S.** Statistical aspects of kinetic modeling for food science problems. *Journal of Food Science*, 1996.
26. **van Boekel, M.A.J.S.** Kinetic modeling of food quality: a critical review. *Comprehensive Reviews in Food Science and Food Safety,* 2008.
27. **Wahlby, U., Skjöldebrand, C**. Reheating characteristics of crust formed on buns, and crust formation. Journal of Food Engineering, 2002.
28. **Wee, A.G., Lindsey, D.T., Kuo, S., Johnston, W.M.** Color accuracy of commercial digital cameras for use in denistry. *Dental Material*. 2006.

29. **Yam, K.L., Papadakis, S.E.** A simple digital imaging method for measuring and analyzing color of food surfaces. *Journal of Food Engineering*, 2004
30. **Zhang ,L., Lucas, T., Doursat, C., Flick, D. , Wagner, M.** Effects of crust constraints on bread expansion and CO_2 release. *Journal of Food Engineering*, 2007.