Promjena boje Mozzarelle tijekom pečenja

Mišić, Ivana

Master's thesis / Diplomski rad

2016

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:109:781262

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Repository of the Faculty of Food Technology Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
PREHRAMBENO-TEHNOLOŠKI FAKULTET OSIJEK

Ivana Mišić

PROMJENA BOJE MOZZARELLE TIJEKOM PEČENJA

DIPLOMSKI RAD

Osijek, listopad 2016.

TEMELJNA DOKUMENTACIJSKA KARTICA

DIPLOMSKI RAD

Sveučilište Josipa Jurja Strossmayera u Osijeku
Prehrambeno-tehnološki fakultet Osijek
Zavod za prehrambene tehnologije
Katedra za mljekarstvo
Franje Kuhača 20, 31000 Osijek, Hrvatska

Diplomski sveučilišni studij Prehrambeno inženjerstvo

Znanstveno područje:	Biotehničke znanosti
Znanstveno polje:	Prehrambena tehnologija
Nastavni predmet:	Tehnologija mlijeka i mliječnih proizvoda
Tema rada	je prihvaćena na X. redovitoj sjednici Fakultetskog vijeća Prehrambeno-tehnološkog fakulteta Osijek u akademskoj godini 2015./2016. održanoj 12. srpnja 2016.
Mentor:	dr. sc. *Mirela Lučan*, znan. sur.
Komentor:	doc. dr. sc. *Jasmina Lukinac Čačić*

Promjena boje Mozzarelle tijekom pečenja

Ivana Mišić, 311-DI

Sažetak:

Budući da je boja svojstvo prehrambenog proizvoda koje se prvo uočava od velike je važnosti jer može stvoriti pozitivno odnosno negativno mišljenje o proizvodu. Cilj ovog diplomskog rada je pratiti promjenu boje sira Mozzarella tijekom pečenja, primjenom računalne analize slike i kolorimetra. Uzorci sira Mozzarella su prikupljeni na tržištu. Promjene boje tijekom pečenja su određivane u uobičajenim uvjetima pečenja pizze (200 °C/5 min). Također su analizirana i fizikalno-kemijska, te senzorska svojstva uzoraka. Ukupna promjena boje kao i faktor posmeđivanja donje površine uzoraka, analizirani pomoću računalne analize slike, su imali niže vrijednosti nego na površini sira. Rezultati metode bodovanja i deskriptivna analiza pokazali su visoku prihvatljivost svih uzoraka, osobito nakon pečenja kada su i ocjene bile veće. Ukupni rezultati su pokazali da metoda računalne analize slike objektivnija od kolorimetra obzirom da obuhvaća cijelu površinu uzoraka.

Ključne riječi: Mozzarella, boja, posmeđivanje, računalna analiza slike, kolorimetar

Rad sadrži:
64 stranica
26 slika
11 tablica
7 priloga
17 literaturnih referenci

Jezik izvornika: Hrvatski

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

1.	prof. dr. sc. *Jovica Hardi*	predsjednik
2.	dr. sc. *Mirela Lučan,* znan. sur.	član-mentor
3.	doc. dr. sc. *Jasmina Lukinac Čačić*	član-komentor
4.	doc. dr. sc. *Krešimir Mastanjević*	zamjena člana

Datum obrane: 10. listopada 2016.

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 Dairy
Franje Kuhača 20, HR-31000 Osijek, Croatia

Graduate program Food engineering

Scientific area:	Biotechnical sciences
Scientific field:	Food technology
Course title:	Dairy Technology
Thesis subject	was approved by the Faculty of Food Technology Osijek Council at its session no. X held on July 12, 2016.
Mentor:	*Mirela Lučan*, PhD,
Co-Mentor:	*Jasmina Lukinac Čačić*, PhD, assistant prof.

Browning of Mozzarella during the baking

Ivana Mišić, 311-DI

Summary:
Since the colour is characteristic of food product that is first observed, it is of great importance and it can create positive or negative feedback on product. The aim of this study was to monitor the colour changes of Mozzarella cheeses during the baking with application of digital image analysis and colorimeter. Samples of Mozzarella cheeses were collected from super markets. Changes of colour during baking were observed at regular pizza baking conditions (200 °C/5 min). Also, physicochemical and sensory properties of samples were analysed. The total colour change and browning factor of the bottom of the samples, analysed by computer vision, was lower than in samples surface. The results of the scoring method and descriptive analysis showed high acceptability of all samples, especially after the baking process when the scores were higher. Overall results show that the digital image analysis includes the entire sample surface, and is more objective than the colorimeter.

Key words: Mozzarella, browning, colour, digital image analysis, colorimeter

Thesis contains:
64 pages
26 figures
11 tables
7 supplements
17 references

Original in: Croatian

Defense committee:

1.	*Jovica Hardi*, PhD, prof.	chair person
2.	*Mirela Lučan*, PhD	supervisor
3.	*Jasmina Lukinac Čačić*, PhD, assistant prof.	co-supervisor
4.	*Krešimir Mastanjević*, PhD, assistant prof.	stand-in

Defense date: October 10, 2016

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

Sadržaj

1. UVOD ... 1

2. TEORIJSKI DIO ... 3

2.1. SIR ... 4

2.1.1. Struktura sira ... 4

2.1.2. Proizvodnja ... 5

2.1.3. Podjela ... 5

2.2. MOZZARELLA ... 7

2.2.1. Proizvodnja ... 7

2.2.2. Promjena boje Mozzarelle tijekom pečenja ... 10

2.3. BOJE I PROSTOR BOJA ... 11

2.3.1. RGB prostor boja ... 11

2.3.2. CIE*L*a*b** prostor boja ... 12

2.3.3. Računalna analiza slike ... 13

3. EKSPERIMENTALNI DIO ... 15

3.1. ZADATAK ... 16

3.2. MATERIJAL I METODE ... 17

3.2.1. Materijal ... 17

3.2.2. Određivanje kemijskog sastava sira ... 18

3.2.3. Određivanje pH vrijednosti sira ... 19

3.2.4. Određivanje vrijednosti aktiviteta vode ... 19

3.2.5. Analiza boje ... 20

3.2.6. Senzorska analiza ... 26

3.2.7. Statistička obrada rezultata ... 32

4. REZULTATI I RASPRAVA ... 33

4.1. FIZIKALNO-KEMIJSKA SVOJSTVA SIRA ... 34

4.2. BOJA UZORAKA ... 36

4.2.1. Rezultati dobiveni kolorimetrom ... 36

4.2.2. Rezultati dobiveni računalnom analizom slike ... 38

4.2.3. Ukupna promjena boje i posmeđivanje uzoraka tijekom pečenja ... 40

4.3. SENZORSKA SVOJSTVA ... 42

4.4. REZULTATI DESKRIPTIVNE ANALIZE ... 47

5. ZAKLJUČCI ... 51

6. LITERATURA ... 55

7. PRILOZI ... 57

1. UVOD

Sir je jedan od osnovnih prehrambenih proizvoda. Definira se kao svježi ili zreli proizvod dobiven grušanjem mlijeka (sirutke, stepke, vrhnja ili njihove kombinacije) uz izdvajanje sirutke (tekućine nastale tijekom obrade gruša, sporedni proizvod) (Tratnik, 1988).

Ovisno o samom procesu proizvodnje, ali i o mnogim drugim parametrima postoji mnogo vrsta sireva, a jedan od njih je i Mozzarella.

Mozzarella je tradicionalni sir od razvučenog gruša koji se izvorno proizvodi od bivoljeg mlijeka. Stara, izvorna Mozzarella potječe iz okolice Rima, a u 15. stoljeću se zvala jednostavno mozza. Danas se Mozzarella proizvodi isključivo od kravljeg mlijeka, pogotovo ona koja se proizvodi izvan Italije. Kuglastog je ili ovalnog oblika, a može biti različite veličine. Relativno je mekan sir s visokim postotkom vode, visokoelastičan je i gumenaste strukture, a pakira se uvijek u salamuri ili vlastitoj sirutci. Izvorno se proizvodila u malim grudicama promjera do 6 cm, u obliku jaja. Karakterizira ju velika sposobnost razvlačenja gruša pa se često koristi kao dodatak pečenim jelima (pizza, lazanje, tjestenine).

Boja je često svojstvo prehrambenih proizvoda koje se prvo uočava i direktno pretvara u pozitivan ili negativan predznak ukupne kvalitete proizvoda (Lukinac-Čačić, 2012). U ovom diplomskom radu boju smo određivali na dva načina: uz pomoć kolorimetra, te uz pomoć računalne analize slike. Osim boje određivali smo i kemijski sastav, aktivitet vode, pH vrijednost, te smo ispitivali i senzorska svojstva sira.

Cilj ovog diplomskog rada je praćenje boje Mozzarelle tijekom pečenja te obrada rezultata pomoću računalne analize slike koja se pokazala kao točnija, objektivnija i učinkovitija s obzirom na „kontaktne“ klasične metode.

2. TEORIJSKI DIO

2.1. SIR

Sir je jedan od najvažnijih proizvoda mliječne industrije, a nastaje koagulacijom proteina u mlijeku. Postoje stotine različitih tipova sira ovisno o teksturi i okusu sira, vrsti mlijeka i bakterija korištenih u proizvodnji, samom načinu proizvodnje, itd.

Prema Pravilniku o sirevima i proizvodima od sireva (MPRRR, 2013), sirevi su svježi proizvodi ili proizvodi s različitim stupnjem zrelosti koji se proizvode odvajanjem sirutke nakon koagulacije mlijeka (kravljeg, ovčjeg, kozjeg, bivoljeg mlijeka i/ili njihovih mješavina), vrhnja, sirutke, ili kombinacijom navedenih sirovina. U proizvodnji sireva dopuštena je upotreba mljekarskih kultura, sirila i/ili drugih odgovarajućih enzima za koagulaciju i/ili dopuštenih kiselina za koagulaciju.

2.1.1. Struktura sira

Za proizvodnju sira najznačajniji sastojak je bjelančevina kazein zbog svojih svojstava (elektronegativnost, netopljivost u vodi te sposobnost koagulacije kod pH 4,6). Kazein je složena bjelančevina koja u svom sastavu sadrži fosfor. Osim kazeina, u mlijeku se nalaze i proteini sirutke koji potječu iz krvi i mliječnih žlijezda. Proteini sirutke su albumin (35%) i globulin (10-15%) i topljivi su u vodi, ali ne koaguliraju kod pH 4,6. Posljedica prisutnosti veće količine kazeina (80%) u odnosu na proteine sirutke (20%) u mlijeku je oblikovanje čvršćeg, viskoznijeg gruša (Tratnik, 1998).

Kazein se u svježem mlijeku nalazi u obliku micela. Prosječna micela kazeina sadrži 400-500 podjedinica submicela koje se spajaju pomoću iona kalcija ili kalcij fosfata čineći tako složenu strukturu, micelu kazeina globularnog oblika (Perko, 2015).

Stabilnost kazeina ovisi u prvom redu o temperaturi i kiselosti mlijeka te količini kalcijevih iona tj. kalcijevog fosfata u mlijeku, itd. Da bi izazvali koagulaciju proteina potrebno je ukloniti ove čimbenike stabilnosti što se u praksi provodi djelovanjem kiselina ili proteolitičkih enzima. Zagrijavanje mlijeka na 140 ^{o}C tijekom 20 minuta, sniženje pH te povišenje koncentracije kalcijevih iona (Ca^{2+}) dovodi do agregacije kazeina i oblikovanje trodimenzionalne mreže gela (Tratnik, 1998).

Kazein igra najvažniju ulogu u formiranju strukture sira, što pokazuje **Slika 1**. Globule masti se ponašaju kao punila unutar proteinske mreže i povećavaju čvrstoću gela, dok je kalcij

vezan za micele kazeina u obliku kalcijevog fosfata, a njegova uloga je povezivanje kazeinata u trodimenzionalnu mrežu gela (Shmidt, 1982).

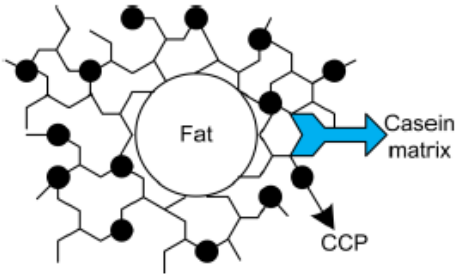

Legenda: Fat – mast; Casein matrix – matriks kazeina; CCP – kazein-fosfopeptid

Slika 1 Trodimenzionalna struktura mreže gela

2.1.2. Proizvodnja

Kao što je ranije rečeno, bit proizvodnje sira je provedba koagulacije proteina kazeina, odnosno sirenje ili grušanje mlijeka, i oblikovanje sirnog gruša u sirno zrno, uz izdvajanje nastale sirutke i eventualno soljenje sira, nakon čega se dobiva svježi nezreli sir koji se podvrgava zrenju u zrionici (ili u salamuri) da bi nastao zreli sir željenih svojstava (Tratnik, 1998).

Osnovni preduvjet za dobivanje kvalitetnog sira je upotreba kvalitetnog mlijeka. Osim o kvaliteti sirovine, kvaliteta sira ovisi i o obradi mlijeka te o provedbi tehnološkog procesa proizvodnje (Slačanac, 2016).

2.1.3. Podjela

Sireve možemo podijeliti prema:

1. vrsti proteina:

- kazeinski sirevi (proizvedeni od mlijeka),
- albuminski sirevi (proizvedeni od sirutke),
- mješoviti sirevi (mlijeko + sirutka);

2. vrsti mlijeka:

- kravlji, ovčji, kozji, bivolji i sirevi od mješavine kravljeg s nekom drugom vrstom mlijeka;

3. načinu grušanja:

- kiseli sir (djelovanjem kiseline – mliječno-kiselog vrenja),
- slatki sir (djelovanjem enzimskih pripravaka – sirila),
- mješoviti sir (djelovanjem kiseline i enzima sirila);

4. udjelu mliječne masti u suhoj tvari sira:

- vrlo masni sirevi (više od 60%),
- punomasni sirevi (45-60%),
- polumasni sirevi (25-45%),
- malomasni sirevi (10-25%),
- posni sirevi (manje od 10%);

5. udjelu vode u bezmasnoj suhoj tvari sira:

- jako tvrdi sirevi (manje od 50%),
- tvrdi sirevi (49-56%),
- polutvrdi sirevi (54-63%),
- polumeki sirevi (61-69%),
- meki, svježi sirevi (više od 67%);

6. sličnom procesu proizvodnje (autohtona tehnologija);

7. prema načinu zrenja:

- svježi sirevi bez zrenja,
- zrenje u zrionici,
- zrenje u salamuri,
- čedarizacija,
- zrenje sirne grude,
- zrenje umotanih sireva u posebnoj foliji (Slačanac, 2016).

Tablica 1 Podjela sireva prema sličnom procesu proizvodnje (Tratnik, 1998)

PREMA NAČINU PROIZVODNJE	*VRSTA SIRA*
tip Cheddar	Cheddar, Parmesan, Kačkavalj, **Mozzarella**
tip Emmentaler	Emmentaler, Gryere
tip Edam	Edamac, Gouda, Trapist, Livanjski sir
tip Roquefort	Roquefort, Gorgonzola, Stilton
tip Camambert	Camambert, Brie
tip Limburger	Limburger, Romadur
tip sira u salamuri	Fetta, Domiati, Halloumi

2.2. MOZZARELLA

Sir koji zauzima jednu trećinu svjetske potrošnje svih sireva je Mozzarella pa ju smatramo najomiljenijim sirom u svijetu. Najčešće se koristi kao „preljev“ za pizzu. Ubraja se u *pasta filata* porodicu koja potječe iz Italije, a izvorno se proizvodi od bivoljeg mlijeka. Karakterizira ju glatka, meka i kremasta struktura, te blago slatko-kiseli okus. Čuva se u salamuri, te ima kratak rok trajanja, pa se danas sve češće proizvodi od kravljeg mlijeka. Mozzarella proizvedena od kravljeg mlijeka ima duži rok trajanja, ali i nešto drugačija svojstva: teža je, ima veći udio suhe tvari, te gumenastiju strukturu (Xixiu Ma, 2013).

Mozzarellu karakterizira velika sposobnost razvlačenja gruša pa je upravo zbog toga nezamjenjiv dodatak pečenim jelima, osobito pizzi (Xixiu Ma, 2013).

2.2.1. Proizvodnja

Jedan od najpoznatijih predstavnika sira parenog tijesta tj. *pasta filata* sira je Mozzarella. Tehnologija proizvodnje *pasta filata* sireva se bazira na postupku čedarizacije (bez soljenja;

odvajanje sirutke od gruša) gdje gruš sazrije, uključujući rezanje na rezance te kuhanje i rastezanje tijesta da bi se postigla elastično-vlaknasta svojstva (Tratnik, 1998).

Kao što je prikazano na shemi proizvodnje Mozzarelle na **Slici 2**, u prvom koraku se u pasterizirano i standardizirano (postignuto dodavanjem obranog mlijeka u prahu ili vrhnja do specifičnog omjera proteina i masti) mlijeko dodaju starter kulture (bitne jer određuju sposobnost sira za rastezanje, posmeđivanje, topljenje i izlučivanje masti) te se zatim vrši sirenje koje se provodi enzimski uz pomoć kimozina. Nastali gruš se prebacuje na čedarizaciju gdje gruš zrije, a zrela se sirna masa reže na rezance i transportira u napravu za kuhanje – rastezanje (vrućom vodom na 50-60 ^{o}C). Plastični gruš tada ide na oblikovanje i soli se kako bi se postiglo što kraće salamurenje. Oblikovani sir zatim ide na očvršćivanje i hlađenje hladnom vodom koja se raspršuje iznad sira. Na kraju hlađenja sir se oslobađa iz kalupa i uranja u hladnu salamuru. Sirevi se tada mogu pakirati u plastičnu ambalažu u koju se dodaje dio salamure (Xixiu Ma, 2013).

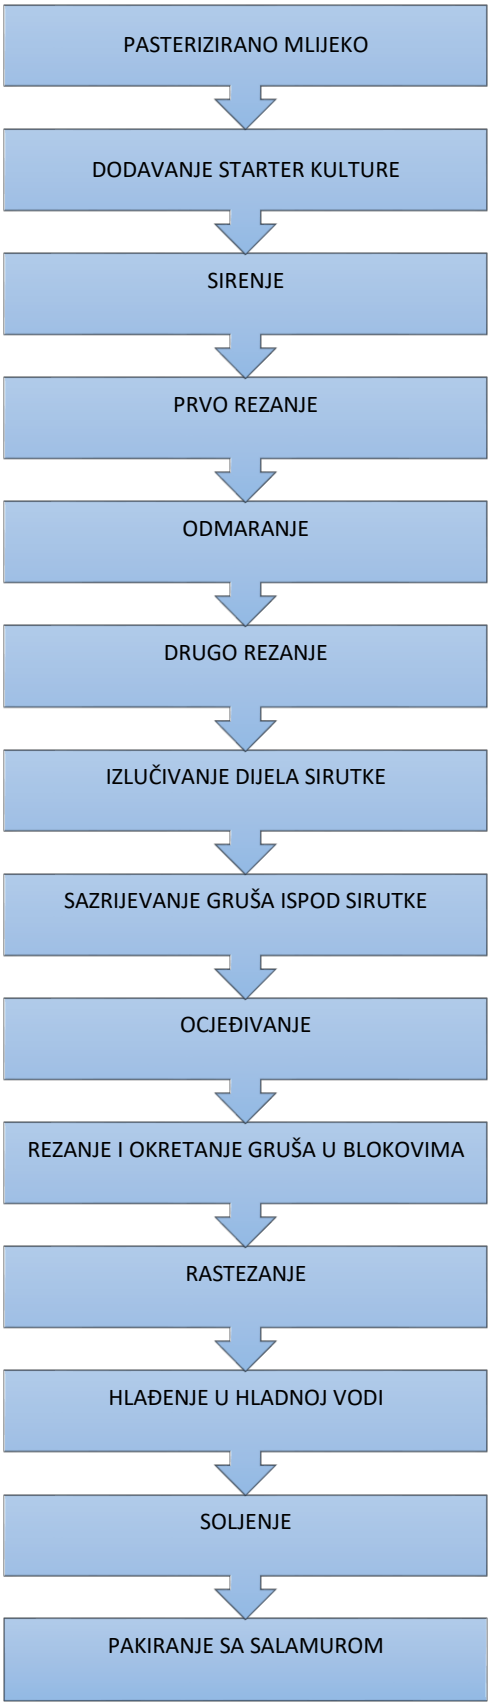

Slika 2 Shema proizvodnje Mozzarelle

2.2.2. Promjena boje Mozzarelle tijekom pečenja

Tijekom pečenja dolazi do posmeđivanja Mozzarella sira (**Slika 3**). Posmeđivanje je posljedica Maillardovih reakcija između zaostalih šećera i aminokiselina. Intenzitet posmeđivanja ovisi o vremenu pečenja, temperaturi te reakcijama između aminokiselina i ugljikohidrata u siru. Najčešće se promatra na pizzi ili prilikom zagrijavanja sira u vodenoj kupelji.

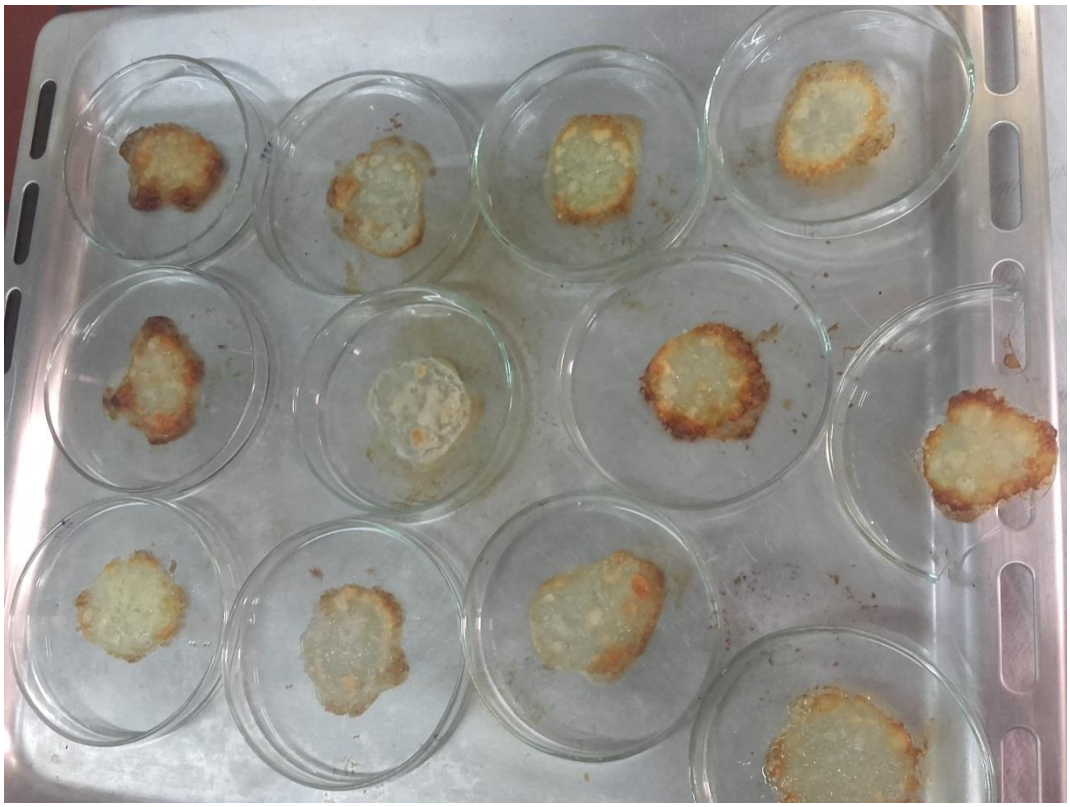

Slika 3 Promjena boje Mozzarelle tijekom pečenja

2.3. BOJE I PROSTOR BOJA

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

Prostor boja ili model boja je način pomoću kojeg se definiraju, stvaraju i vizualizuraju boje. Postoji mnogo prostora boja i svaki se koristi za različite namjene. Osnovna podjela prostora boja je na:

- aditivni prostori boja kod kojih se boja dobiva zbrajanjem pojedinih komponenti i oni su ovisni o uređaju (npr. RGB ili CMY);
- subtraktivni prostor boja kod kojih se boja dobiva oduzimanjem pojedinih komponenti i oni su neovisni o uređaju (to su CIE prostori boja kao npr. CIEXYZ te izvedeni prostori CIE*L*a*b** ili CIE*L*u*v**) (Lukinac-Čačić, 2012).

2.3.1. RGB prostor boja

RGB prostor boja definiran je pomoću tri aditivna primara: crvene, zelene i plave boje. Svaka boja u tom prostoru nastaje zbrajanjem pojedinih komponenata te tri boje. Kao što vidimo na **Slici 4**, RGB model predstavljen je pomoću kocke, gdje crvena boja predstavlja x-os, zelena boja y-os, a plava boja z-os (Lukinac-Čačić, 2012; Puglia,2000).

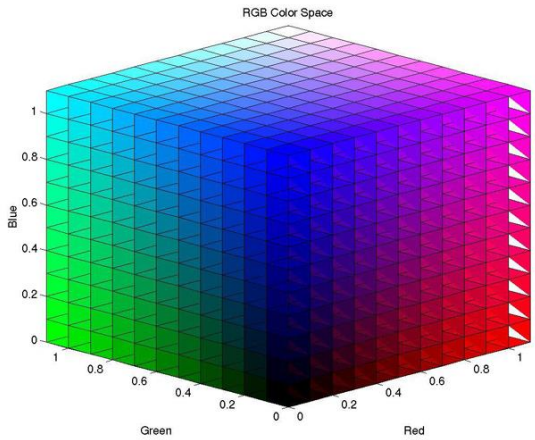

Slika 4 Prikaz modela RGB prostora boja

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

Trodimenzionalni prostor koji je baziran na percepciji boje standardnog promatrača. Ovaj model se sastoji od tri komponente, a prednost ovog sustava je uvođenje svjetline kao treće dimenzije, što vidimo i na **Slici 5**. U CIE*L*a*b** sustavu boje su opisane pomoću tri osi: dvije kromatske, *a** komponenta odnos između crvene i zelene boje (negativne vrijednosti označavaju zelenu, a pozitivne crvenu), i *b** komponenta odnos između žute i plave boje (negativne vrijednosti za plavu, a pozitivne za žutu). Treća os (akromatska os) u ovom sustavu boje predstavlja *L** komponentu tj. svjetlinu. Vrijednosti svjetline kreću se u rasponu od 0 do 100, gdje je 0 vrijednost za crnu, a 100 za bijelu boju (**Slika 5**) (Hsien-Che, 2005).

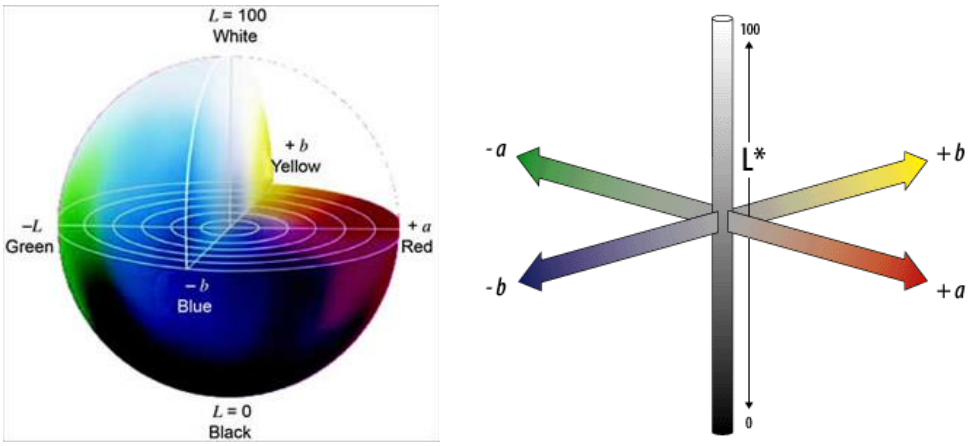

Slika 5 Prikaz modela CIE*L*a*b** prostora boja

2.3.3. Računalna analiza slike

U tradicionalnim procjenama kvalitete mliječnih proizvoda se primjenjuju dva osnovna pristupa: fizikalno-kemijski i organoleptički. To su laboratorijske metode koje se odnose na dugotrajno istraživanje, posebnu opremu i materijale te visokokvalificirane stručnjake. Kod velikog broja rezultata procjene se temelje na subjektivnoj procjeni stručnjaka, čime rezultati ovise o znanju i iskustvu stručnjaka, kao i o njihovoj sposobnosti da interpretiraju rezultate. Nedostatak ovih klasičnih metoda je objektivnost u procjeni.

Stoga se počelo tražiti nove metode koje bi bile objektivne, precizne te učinkovite. Neke od njih su računalna analiza slike i spektralne analize jer svojim naprednim tehnološkim rješenjima daju potpunu objektivnost u procjeni (Dimitrov i Mladenov, 2012).

Računalna analiza slike (engl. *Digital image analysis*, DIA) je nedestruktivna metoda analize. Boja površine uzorka određuje se beskontaktno, na način da se uzorak fotografira te nakon digitalizacije slijedi obrada slike primjenom različitih računalnih programa. Računalni programi za analizu slike koriste različite algoritme kojima se „izdvajaju“ potrebne informacije sa slike. Glavna podjela algoritama je na strukturne (morfološke) i one koji objekte na slici klasificiraju prema boji ili intenzitetu sive nijanse (engl. *threshold*). Primjenom tih algoritama moguće je dobiti vrlo točne i pouzdane informacije o promjeni boje proizvoda. Računalna analiza slike uspješno se primjenjuje u mnogim industrijskim granama zbog brzine, preciznosti, objektivnosti, kontinuiranosti i ponovljivosti rezultata. Sustav za analizu slike sastoji se od tri najvažnija elementa: rasvjete, fotoaparata i računala. U prehrambenoj industriji upotrebljava se za analiziranje: oblika i veličine rezanaca sira, teksture prehrambenih proizvoda, sadržaja mesnog i masnog tkiva u komadima mesa te udjela šupljina u pekarskim proizvodima (Lukinac-Čačić, 2012; Pranjić, 2005).

3. EKSPERIMENTALNI DIO

3.1. ZADATAK

Zadatak ovog diplomskog rada bilo je praćenje promjene boje različitih uzoraka Mozzarelle prikupljenih na tržištu tijekom pečenja uz pomoć kolorimetra i računalne analize slike. Uz to je ispitan sastav i kemijska svojstva.

U sklopu diplomskog rada provedene su sljedeće analize:

- analiza kemijskog sastava sira,
- pH vrijednost analiziranih sireva,
- aktivitet vode u analiziranim sirevima,
- ispitivanje boje sireva prije i poslije pečenja pomoću kolorimetra,
- računalna analiza slika boje prije i nakon pečenja,
- senzorska analiza sira,
- statistička obrada rezultata.

3.2. MATERIJAL I METODE

3.2.1. Materijal

Na tržištu je prikupljeno šest različitih uzoraka Mozzarelle koji su prikazani na **Slici 6**, a podaci s deklaracije su dani u **Tablici 2**,

Slika 6 Prikupljeni uzorci Mozzarelle

Tablica 2 Nutritivna vrijednost prikupljenih podataka na 100 g

		Nutritivna vrijednost na 100g							Masa	
Proizvod (uzorak)		Energija (kJ/kcal)	Masti (g)	Zasićene MK (g)	Ugljikohidrati (g)	Šećeri (g)	Proteini (g)	Sol (g)	Neto (g)	Ocijeđena (g)
1.	Glabani Mozzarela di Bufala Campana	276/66	24,00		1,00		14,00	0,70	235,00	125,00
2.	Galbani Mozzarela	989/238	18,00	12,50	2,00	1,00	17,00	0,70	225,00	125,00
3.	Galbani Mozzarela light	690/165	9,00	6,30	2,00	1,00	19,00	0,38	210,00	125,00
4.	Meggle Mozzarela	1014/244	18,50	12,50	0,40	0,40	19,00	0,38	200,00	125,00
5.	K plus Mozzarela	1026/247	19,00	12,00	1,00	1,00	18,00	0,50	220,00	100,00
6.	Zott Mozzarela	1029/248	19,00	12,90	1,50	1,50	17,50	0,60	200,00	125,00

Analize su provedene prije pečenja te nakon pečenja od 5 minuta na 200 °C.

3.2.2. Određivanje kemijskog sastava sira

Određivanje kemijskog sastava uzoraka sira provedeno je u uređaju FoodScan Analyser (Foss, Danska) koji je i prikazan na **Slici 7**. Uzorci su prvo homogenizirani u mikseru, a zatim su punjeni u posudice mjernog tijela do vrha (80 g) i postavljeni u posebnu komoru za uzorke. U komori se nakon zatvaranja pokreće mjerenje. Ovom metodom u Mozzarelli su određeni udio vode, proteina, mliječne masti i NaCl.

Slika 7 FoodScan^{TM} Lab

3.2.3. Određivanje pH vrijednosti sira

pH vrijednost uzoraka Mozzarella sira ispitana je s pH metrom (ProfiLine pH metar 3210, **Slika 8**) prema službenoj metodi AOAC 962.19. Ubodnom iglom pH metra u ocijeđenoj masi Mozzarella sireva izračunate su pH vrijednosti.

Slika 8 ProfiLine pH metar 3210

3.2.4. Određivanje vrijednosti aktiviteta vode

Aktivitet vode (a_w) određen je uređajem Rotronic HygroLab 3 pri sobnoj temperaturi kao što je prikazano na **Slici 9**.

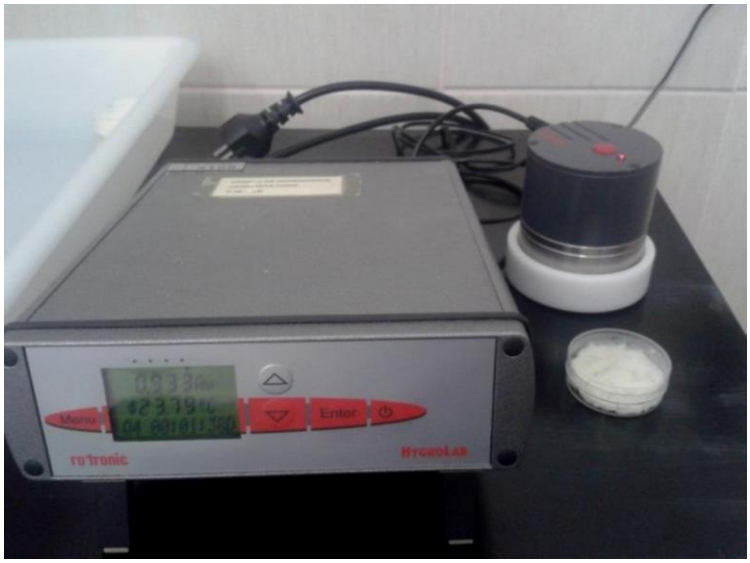

Slika 9 HygroLab 3

3.2.5. Analiza boje

Boja Mozzarelle mjerena je dvjema metodama: kolorimetrom (Hunter-Lab Mini ScanXE) korištenjem CIE*L*a*b** prostora boja i računalnom analizom slike (DIA) korištenjem RGB prostora boja koji je radi usporedbe rezultata preveden u CIE*L*a*b** prostor boja.

3.2.5.1 Određivanje boje kolorimetrom

Ispitivanje boje je provedeno pomoću uređaja Hunter-Lab Mini ScanXE (A60-1010-615 Model Colorimeter, Hunter-Lab, Reston, VA, USA) (**Slika 10**).

Određivana su tri parametra boje *L**, *a** i *b** u sljedećim rasponima boja:

- *a** - zeleno (-*a**) ili crveno (+*a**),
- *b** - plavo (-*b**) ili žuto (+*b**),
- *L** - svjetlo (*L** = 100) ili tamno (*L** = 0) (Tuntragul, 2010).

Određivanje boje rađeno je na sobnoj temperaturi (20±2 ^{o}C) u 5 ponavljanja.

Slika 10 Hunter-Lab Mini ScanXE

3.2.5.2 Određivanje boje računalnom analizom slike

Svaki uzorak je skeniran, a slika obrađena računalnom analizom slike pomoću *ImageJ* (ver.1.51d) programa. Za skeniranje uzoraka korišten je skener EPSON PERFECTION V500 photo (Epson America, Inc.) koji vidimo na **Slici 11**. Skeniranje je odrađeno u kontrolnim uvjetima (tamna komora), odnosno u prostoru koji ne propušta nikakav vanjski izvor svjetlosti pri rezolucijii skenera od 600 dpi, dubini boje od 24 bita u RGB modelu boja. Slike su pohranjene u TIFF formatu. Sljedeći korak je obrada i analiza slike računalnim programom *ImageJ* (**Slika 12**). Prvi dio obrade slike je segmentacija uzoraka na slici te brisanje podloge kako bi se kvantitativno opisao uzorak pomoću izdvojenih podataka (RGB parametri boje) i potom slijedi preračunavanje dobivenih vrijednosti RGB prostora boja u CIE*L*a*b** prostor boja. Mjerenje boje provedeno je na površini te donjem dijelu uzoraka Mozzarelle u tri ponavljanja.

Slika 11 Skener EPSON PERFECTION V500 photo

ImageJ (ver.1.51d; National Institute of Mental Health, Bethesda, Maryland, USA) je program za analizu slike u kojem je moguće prikazati, urediti, analizirati, spremiti i printati slike od 8, 16 i 32 bita. U programu je moguće izračunati područje i vrijednost piksela, izmjeriti udaljenost i kutove, a sadrži i opcije za podešavanje kontrasta, izoštravanje, poravnanje i dr.

Kao rezultat mjerenja boje Mozzarelle dobivaju se vrijednosti R, G i B prostora boja koje su potom prevedene u CIE*L*a*b** prostor boja (prema jednadžbama od 3.1-3.9).

Pretvorba iz RGB u CIE*L*a*b** prostor boja napravljena je prema sljedećim jednadžbama (Lukinac-Čačić, 2012):

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

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

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

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

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

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

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

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

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

Udaljenost između dvije točke u koordinatnom sustavu (razlika između dvije boje) izračunava se i definira kao fizikalna vrijednost, tj. ukupna promjena boje (Δ*E)*, a odnos između izračunate vrijednosti Δ*E* i tolerancije ljudskog oka za uočavanje razlike između boja dana je u **Tablici 3** i ona je važan indikator promjene boje u procesima enzimskog i neenzimskog posmeđivanja (Lukinac-Čačić, 2012).

Prema izmjerenim vrijednostima boje uzoraka (*L**, *a**, *b**) izračunata je ukupna promjena boje prema jednadžbi 3.10 (pri čemu L_0^*, a_0^*, b_0^* predstavljaju vrijednosti boje prije pečenja 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 Odnos između izračunate vrijednosti (Δ*E*) i tolerancije ljudskog oka za uočavanje 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 programu *ImageJ* (macro), a prikaz koda dan je u nastavku odlomka:

```
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 !!!
run("Measure");
    close();}
 function reformatResults(titles) {
    n = nResults/3;
    reds = newArray(n);
    greens = newArray(n);
    blues = newArray(n);
    for (i=0; i<n; i++) {
       reds[i] = getResult("Mean", i*3);
       greens[i] = getResult("Mean", i*3+1);
       blues[i] = getResult("Mean", i*3+2);}
    run("Clear Results");
    for (i=0; i<n; i++) {
       setResult("Label", i, titles[i]);
       setResult("Red", i, reds[i]);
       setResult("Green", i, greens[i]);
       setResult("Blue", i, blues[i]);}
     updateResults()}
```

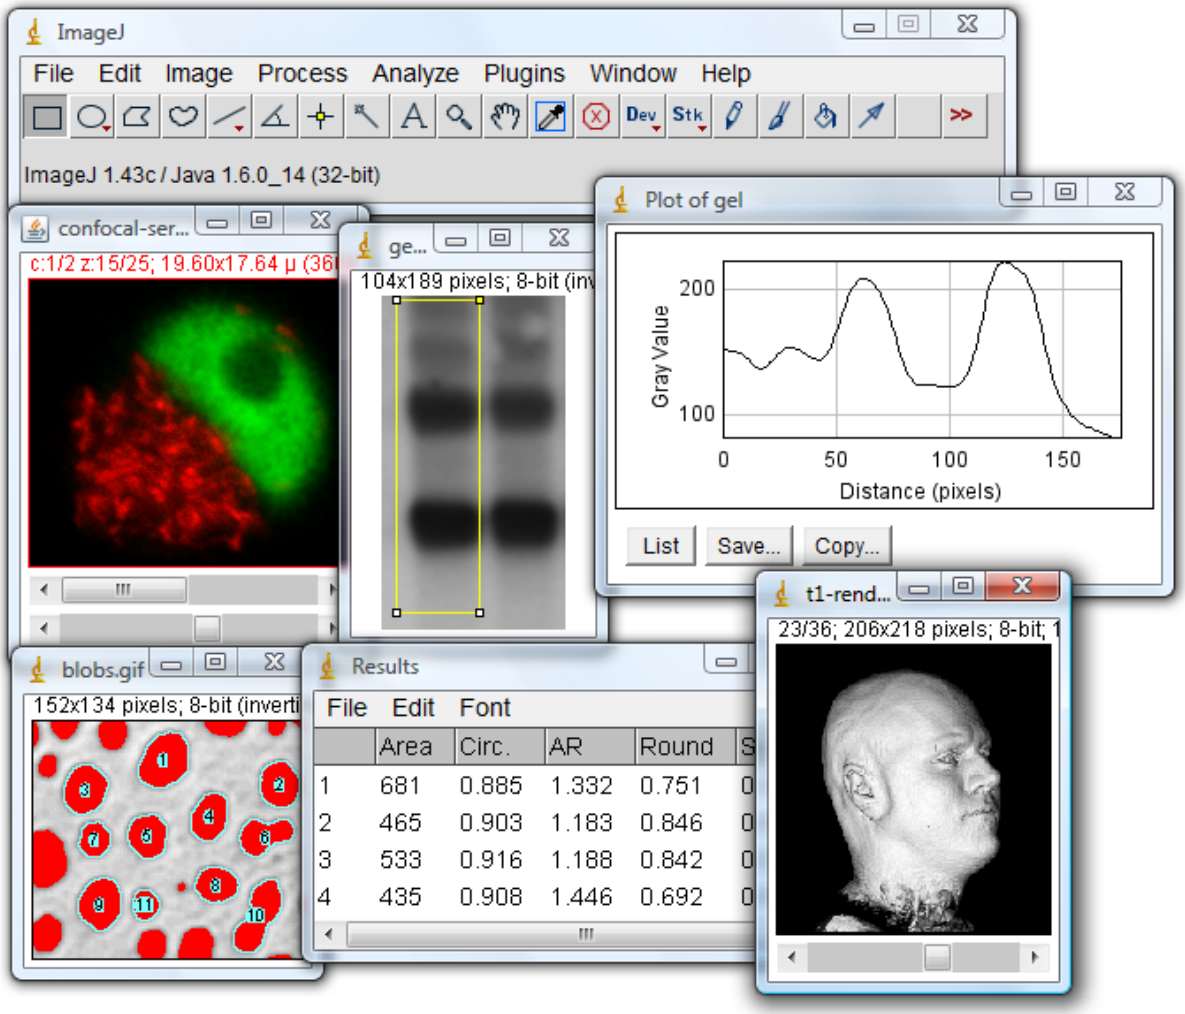

Slika 12 Izgled sučelja programa *ImageJ*

3.2.5.3 Određivanje faktora posmeđivanja

Faktor posmeđivanja (engl. *browning factor,* BF) se definira kao omjer vrijednosti sivog tona prije i nakon pečenja. Vrijednost sive boje se može opisati kao razina sivoće ili svjetline (Wang i Sun, 2013). U ovom istraživanju je faktor posmeđivanja izračunat u odnosu na parametar svjetline:

$$BF = \frac{L^*(0)}{L^*(\mathrm{t})} \cdot 100\ (\%) \tag{3.11}$$

gdje su:

$L^*(0)$ – parametar svjetline prije pečenja,

$L^*(\mathrm{t})$ – parametar svjetline poslije pečenja.

3.2.6. Senzorska analiza

3.2.6.1 Metoda bodovanja

Senzorska analiza je znanstvena disciplina koja tumači reakcije za one značajke hrane koje opažaju osjetila vida, mirisa, okusa i sluha (Mandić i Perl, 2006).

Za definiranje senzorskih svojstava parametri koji se najčešće koriste su:

- mirisna svojstva,
- svojstvo okusa,
- svojstvo konzistencije (tekućine) i teksture (krutine i polukrutine),
- zvuk,
- izgled – optička svojstva.

Svi testovi se mogu podijeliti na dva osnovna tipa:

- analitičke testove (diskriminativni, deskriptivni i bodovanje),
- testiranje potrošača (određuju preferenciju te koliko se proizvod sviđa potrošaču).

Za senzorsku analizu uzoraka Mozzarella sira korišten je analitički test – metoda bodovanja (**Slika 13**), koja je najčešće korištena senzorska metoda za testiranje namirnica. Različite zemlje koriste metode bodovanja s različitom svrhom i raznim strukturama bodova pa tako razlikujemo sustave s 5, 10, 18, 20, 30, 50, 100 i 200 bodova među kojima se najčešće primjenjuju oni s 5 i 20 bodova, a preporuča se jednoobrazna skala s 5 bodova (Filajdić i sur., 1988). Zahtjevi su prikazani u **Tablici 4**.

Tablica 4 Zahtjevi za bodovanje (Filajdić i sur., 1988)

Bodovi (ocjene)	*Opis zahtjeva*
5	U odnosu na zahtjeve senzorske kakvoće istraživani parametar proizvoda ima izrazito pozitivna svojstva. Opći utisak je potpuni sklad. Nikakvi nedostaci se ne mogu uočiti.
4	Određeno svojstvo grupe (parametar senzorske kakvoće) pokazuje jedva zamjetljive nedostatke. Proizvod je gotovo punovrijedan u istraživanom svojstvu.
3	Istraživani parametar kakvoće pokazuje da je intenzitet neoštećen. Proizvod ima uočljive manje nedostatke, ali njegova upotrebna vrijednost još sadrži prihvatljivu razinu.
2	U odnosu nasvojstvo grupe (parametar senzorske kakvoće) proizvod ima nedostatke. Zbog toga ima smanjenu upotrebnu vrijednost, ali se ipak može staviti u promet pod određenim uvjetima (npr. s proporcionalno nižom cijenom).
1	U odnosu na svojstvo grupe proizvod ima znatne nedostatke. Zbog toga je nepodesan za namjensku upotrebu. Proizvod nije pokvaren, ali ga prije upotrebe treba doraditi (preraditi).
0	U odnosu na svojstvo grupe proizvod sadrži nedostatke koji bezuvjetno ukazuju na njegova oštećena svojstva. Prema tome, proizvod je u svakom slučaju nepodesan za ljudsku ishranu, te ga se ne smije stavljati u promet.

Kod izbora parametara senzorske kakvoće za određeni tip proizvoda treba uzimati u obzir sljedeće osnovne grupe:

- izgled,
- tekstura,
- miris,
- okus.

Listić za senzorsko ocjenjivanje uzoraka Mozzarelle od parametara kakvoće sadržavao je: izgled, boju, strukturu, presjek, miris i okus kao što je prikazano u **Tablici 5**.

Vrijednost čimbenika značajnosti parametra kakvoće raste proporcionalno sa važnošću parametra u odnosu na ukupno senzorsko vrjednovanje testiranog proizvoda (Filajdić i sur., 1988).

Tablica 5 Listić za senzorsko ocjenjivanje Mozzarelle

Parametar kakvoće	Najviši broj bodova	Ocjena	Čimbenik značajnosti	1	2	3	4	5	6
IZGLED	2	1-5	0,4						
BOJA	1	1-5	0,2						
STRUKTURA	2	1-5	0,4						
PRESJEK	3	1-5	0,6						
MIRIS	2	1-5	0,4						
OKUS	10	1-5	2,0						
ukupno	20								

Ponderirani bodovi, računaju se kao zbroj umožaka ocjene i čimbenika značajnosti za svako svojstvo, a **Tablica 6** prikazuje kategorije kakvoće sira s obzirom na ponderirane bodove.

Tablica 6 Kategorija kakvoće sira

kategorija kakvoće	ponderirani bodovi
izvrsna	17,6-20,0
dobra	15,2-17,5
osrednja	13,2-15,1
prihvatljiva	11,2-13,1
neprihvatljiva	<11,2

Slika 13 Senzorska analiza uzoraka Mozzarelle uz pomoć metode bodovanja

3.2.6.2 Deskriptivna senzorska analiza

Deskriptivne metode nastoje identificirati i kvantificirati senzorske karakteristike. Uključuju razlikovanje i opis kvantitativnih i kvalitativnih senzorskih aspekata proizvoda pomoću grupe od 5-100 članova (Primorac, 2006).

Senzorski profil predstavlja metodu senzorske analize kojom se senzorska svojstva neke namirnice raščlanjuju na niz pojedinačnih svojstava koji se u namirnici mogu pojaviti, pa se zbog toga za svaku namirnicu upotrebljava specifičan i detaljno razrađen rječnik.

Najčešće korištena metoda senzorskog profila je kvantitativna deskriptivna analiza (QDA, eng. *Quantitative descriptive analysis*). Kod ove metode u pravilu se koristi kontinuiranim ili linijskim ljestvicama. Zadatak analitičara je da intenzitet označi okomitom crticom na linijskoj ljestvici. Brojčana vrijednost intenziteta određuje se mjerenjem dužine od početka ljestvice do okomite crtice (Koprivnjak, 2014).

U ovom istraživanju korišten je obrazac s definiranim svojstvima vanjskog izgleda, mirisa, okusa te teksturalnim svojstvima tijekom žvakanja, kako prikazuje **Tablica 7**.

Tablica 7 Obrazac za senzorski profil Mozzarelle (Pagliarini, 1997)

Pred Vama se nalaze uzorci Mozzarelle označeni brojevima 1-6. Kušajte ih redom i označite intenzitet pojedinog svojstva znakom (×) na kontinuiranoj skali, s tim da početak skale označava najslabiji intenzitet, a kraj skale - najjači intenzitet ispitivanog svojstva.

SVOJSTVO	OPIS	uzorak br.
vanjski izgled		
1. bjelina	potpuno bijela boja	|_____|
2. prozračnost	prozračnost tijesta (ovisi o količini vlage na površini)	|_____|
3. vlaknastost	tipična vlaknasta tekstura kazeina nakon rastezanja u vrućoj vodi	|_____|
4. glatkoća	površina proizvoda bez rupica i granula	|_____|
miris		
5. po mlijeku	karakterističan miris pasteriziranog punomasnog mlijeka	|_____|
6. po maslacu	karakterističan miris maslaca	|_____|
7. po jogurtu	karakterističan miris punomasnog čvrstog jogurta	|_____|
okus tijekom žvakanja		
8. kiselost	jedan od četiri osnovna okusa (sredina jezika)	|_____|
9. gorčina	jedan od četiri osnovna okusa (stražnji dio jezika)	|_____|
10. slatkoća	jedan od četiri osnovna okusa (vrh jezika)	|_____|
11. slanost	jedan od četiri osnovna okusa (vrh i bočni dio jezika)	|_____|
12. okus mlijeka	karakterističan okus pasteriziranog punomasnog mlijeka	|_____|
13. okus vrhnja	karakterističan okus svježeg vrhnja	|_____|
tekstura tijekom žvakanja		
14. čvrstoća	snaga potrebna za kompresiju između kutnjaka	|_____|
15. elastičnost	stupanj uspostavljanja originalnog oblika nakon kompresije među zubima	|_____|
16. kohezivnost	stupanj kompresije nastao među zubima prije slamanja	|_____|
17. gumenost	gustoća tijekom žvakanja potrebna za razaranje hrane kako bi postala pogodna za gutanje	|_____|
18. sočnost	osjećaj vlažnosti u ustima nastao nakon kompresije među zubima	|_____|
19. klizavost	stupanj uljnosti koji se osjeća na usnama i u ustima	|_____|
20. pahuljastost	osjećaj u ustima koji se opisuje kao tipična vlaknasta tekstura kazeina nakon rastezanja u vrućoj vodi	|_____|
datum:	ocjenjivač:	

3.2.7. Statistička obrada rezultata

Rezultati su prikazani kao srednja vrijednost ponavljanja $\pm$ standardna devijacija. Svi rezultati su odbrađeni u programima Excel 2013 (Microsoft) i XLStat (Addinsoft). Provedene su analiza varijance (one-way ANOVA) i potom Fischerov LSD test najmanje značajne razlike engl. *Least significant difference*) dobivenih rezultata te multivarijantna analiza (Pearsonova korelacijska matrica s nivoima značajnosti od 5%) podataka dobivenih ispitivanjem kemijskih i senzorskih svojstava.

4. REZULTATI I RASPRAVA

4.1. FIZIKALNO-KEMIJSKA SVOJSTVA SIRA

Tablica 8 Fizikalno-kemijska svojstva uzoraka Mozzarelle

	maseni udjeli [%]												
UZORAK	MAST	VODA	PROTEINI	NaCl	s.t.	mm/s.t.	BMT	voda/BMT	mast + voda	NaCl/voda	omjer P:M	aw	pH
1	23,42±0,04^{a}	59,92±0,09^{d}	14,27±0,04^{f}	0,26±0,02^{d}	40,08±0,09^{b}	58,43±0,03^{a}	76,58±0,04^{f}	78,24±0,08^{b}	83,34±0,05^{a}	0,43±0,03^{d}	0,61±0,00^{a}	0,959±0,00^{a}	5,34±0,01^{e}
2	14,56±0,01^{e}	67,16±0,01^{b}	14,66±0,00^{e}	047±0,03^{ab}	32,84±0,01^{d}	44,32±0,02^{d}	85,40±0,01^{b}	78,60±0,00^{a}	81,72±0,00^{b}	0,69±0,04^{b}	1,01±0,00^{b}	0,962±0,00^{a}	6,07±0,01^{a}
3	8,40±0,04^{f}	69,40±0,14^{a}	17,97±0,04^{a}	0,44±0,01^{b}	30,60±0,14^{e}	27,43±0,24^{e}	91,61±0,04^{a}	75,76±0,18^{d}	77,80±0,18^{b}	0,63±0,01^{bc}	2,14±0,01^{e}	0,964±0,00^{a}	6,03±0,00^{b}
4	20,09±0,00^{d}	60,11±0,09^{d}	17,19±0,04^{b}	0,36±0,02^{c}	39,90±0,09^{b}	50,34±0,12^{c}	79,92±0,00^{c}	75,21±0,11^{e}	80,19±0,09^{c}	0,60±0,04^{c}	0,86±0,00^{c}	0,964±0,00^{a}	5,44±0,01^{d}
5	20,33±0,00^{c}	59,48±0,09^{e}	16,75±0,00^{c}	0,51±0,04^{a}	40,53±0,09^{a}	50,15±0,09^{c}	79,68±0,00^{d}	74,65±0,10^{f}	79,80±0,08^{d}	0,86±0,07^{a}	082±0,00^{d}	0,965±0,00^{a}	5,93±0,00^{c}
6	21,13±0,02^{b}	60,5±0,11^{c}	15,75±0,07^{d}	0,38±0,02^{c}	39,45±0,11^{c}	53,55±0,20^{b}	78,88±0,02^{e}	76,10±0,16^{e}	81,68±0,13^{b}	0,63±0,04^{bc}	0,75±0,00^{b}	0,963±0,00^{a}	6,03±0,13^{b}

Podaci prikazuju srednje vrijednosti (±SD) tri ponavljanja. ^{abc}Vrijednosti označene istim slovima nisu statistički značajno različite ($p<0,05$) prema Fisherovom LSD testu najmanje značajne razlike. *Legenda*: **s.t.** – suha tvar, **BMT** – bezmasna tvar, **omjer P:M** – omjer proteina i masti

Dobiveni rezultati ispitivanja kemijskog sastava prikupljenih uzoraka Mozzarella sira nalaze se u **Tablici 8**. Iz rezultata je vidljivo da se uzorci ispitivanih sireva međusobno statistički razlikuju prema udjelu osnovnih sastojaka (masti, vode, proteina i NaCl), kao i prema pH vrijednosti, dok između uzoraka nema značajnije razlike u odnosu na aktivitet vode. Budući da se radi o tržišnim uzorcima različitih proizvođača, proizvedenih od različitih sirovina i s različito deklariranim minimalnim udjelima masti, proteina, ugljikohidrata, ovakvi rezultati su bili i očekivani. Međutim, sve dobivene vrijednosti kreću se u okviru standardnih raspona za sir ovoga tipa. Postoji statistički značajna pozitivna korelacija između masenog udjela masti i ukupne suhe tvari sira (0,953) te udjela proteina u siru i aktiviteta vode (0,866; **Tablica 9**).

Udio vode u bezmasnoj suhoj tvari sira u uzorcima kreće se od 74,65% do 78,80%, pa se prema Pravilniku (MPRRR, 2013) svi uzorci mogu svrstati u meke sireve. U većini sireva udio mliječne masti u suhoj tvari se kreće u rasponu vrijednosti 44,32-58,43% pa prema tome sirevi spadaju u punomasne sireve osim uzorka 3 koji ima najmanju vrijednost mliječne masti u suhoj tvari sira (27,43%) te prema tome spada u masne sireve. Budući da je uzorak 3 deklariran kao „light“ proizvod, odnosno proizvod sa sniženim udjelom masti, ovakav rezultat je bio očekivan. Raspon udjela proteina kreće se od 14,27-17,97%, udio soli je u rasponu od 0,26-0,51%, a kiselost sireva (pH) je u rasponu vrijednosti 5,34-6,07%. Statistički se značajno ističe uzorak 1 (proizveden od bivoljeg mlijeka) po najvišem udjelu mliječne masti, ali i najmanjem udjelu soli i najvišoj kiselosti.

Tablica 9 Pearsonova korelacijska matrica podataka dobivenih ispitivanjem osnovnog kemijskog sastava uzoraka Mozzarella sira

varijable	mast	voda	proteini	NaCl	s.t	mm/s.t	BMT	voda/BMT	aw	pH	punilo(M+V)	NaCl/voda	omjer P:M
mast	1	**-0,953**	-0,500	-0,513	**0,953**	**0,983**	**-1,000**	0,071	-0,384	-0,593	0,727	-0,234	**-0,944**
voda			0,220	0,383	**-1,000**	**-0,886**	**0,953**	0,235	0,117	0,571	-0,484	0,073	**0,843**
proteini			1	0,426	-0,220	-0,636	0,500	**-0,871**	**0,866**	0,203	**-0,942**	0,399	0,650
NaCl				1	-0,383	-0,519	0,513	-0,414	0,730	0,793	-0,612	**0,949**	0,371
s.t					1	**0,886**	**-0,953**	-0,235	-0,117	-0,571	0,484	-0,073	**-0,843**
mm/s.t						1	**-0,983**	0,232	-0,491	-0,553	**0,829**	-0,265	**-0,978**
BMT							1	-0,071	0,384	0,593	-0,727	0,234	**0,944**
voda/BMT								1	**-0,860**	-0,042	0,736	-0,540	-0,237
aw									1	0,506	**-0,842**	0,757	0,427
pH										1	-0,417	0,661	0,450
punilo(M+V)											1	-0,508	**-0,812**
NaCl/voda												1	0,123
omjer P:M													1

Podebljane vrijednosti su statistički značajne na nivou značajnosti p<0,05

4.2. BOJA UZORAKA

4.2.1. Rezultati dobiveni kolorimetrom

Na **Slici 14** prikazane su promjene vrijednosti *L**, *a** i *b** parametara prije i poslije pečenja uzoraka, s tim da je poslije pečenja mjerena boja i gornje i donje površine uzoraka.

Prije pečenja ne postoje statistički značajne razlike *L** vrijednosti između uzoraka, a vrijednosti su vrlo visoke (veće od 94,14) što znači da su svi uzorci svijetli (*L**=100 znači potpuno bijelo). Nakon pečenja je došlo do promjene boje (tamnjenja) i smanjenja *L** vrijednosti. Ova metoda pokazuje da je do veće promjene boje došlo s donje strane uzoraka čije vrijednosti se kreću u rasponu 45,4-52,13, te je ta strana tamnija, što je u suprotnosti s očekivanjima.

Parametar *a** odgovara rasponu boja zelena (-*a**) ili crvena (+*a**). Prije pečenja svi uzorci su imali pozitivnu *a** vrijednost, a kreću se u rasponu od 0,03-0,30, što znači da se nalaze u domeni crvene boje. Nakon pečenja uzorci 1, 3 i 5 i s gornje i s donje strane su poprimili negativnu vrijednost (domena zelene boje). Uzorak 4 jedini je zadržao pozitivnu *a** vrijednost te je i nakon pečenja boja ostala u domeni crvene. Vrijednosti nakon pečenja se kreću u rasponu od -1,98 do 1,55 s vrlo velikim standardnim odstupanjima (0,35-3,72).

Između *b** vrijednosti boje uzoraka prije pečenja ne postoje statistički značajnije razlike, te se one kreću u rasponu od 10,9-12,6. Nakon pečenja došlo je do povećanja *b** vrijednosti uzoraka 1, 2, 4 i 5, dok se kod uzoraka 3 i 6 vrijednost neznatno, ali opet neočekivano, smanjila. S donje strane je došlo do smanjenja vrijednosti većine uzoraka u odnosu na početnu, osim uzoraka 3 i 6. Budući da parametar *b** odgovara rasponu boja žuto (+*b**) ili plavo (-*b**), možemo zaključiti da u svim uzorcima prevladavaju žuti tonovi (*b** vrijednosti su pozitivne).

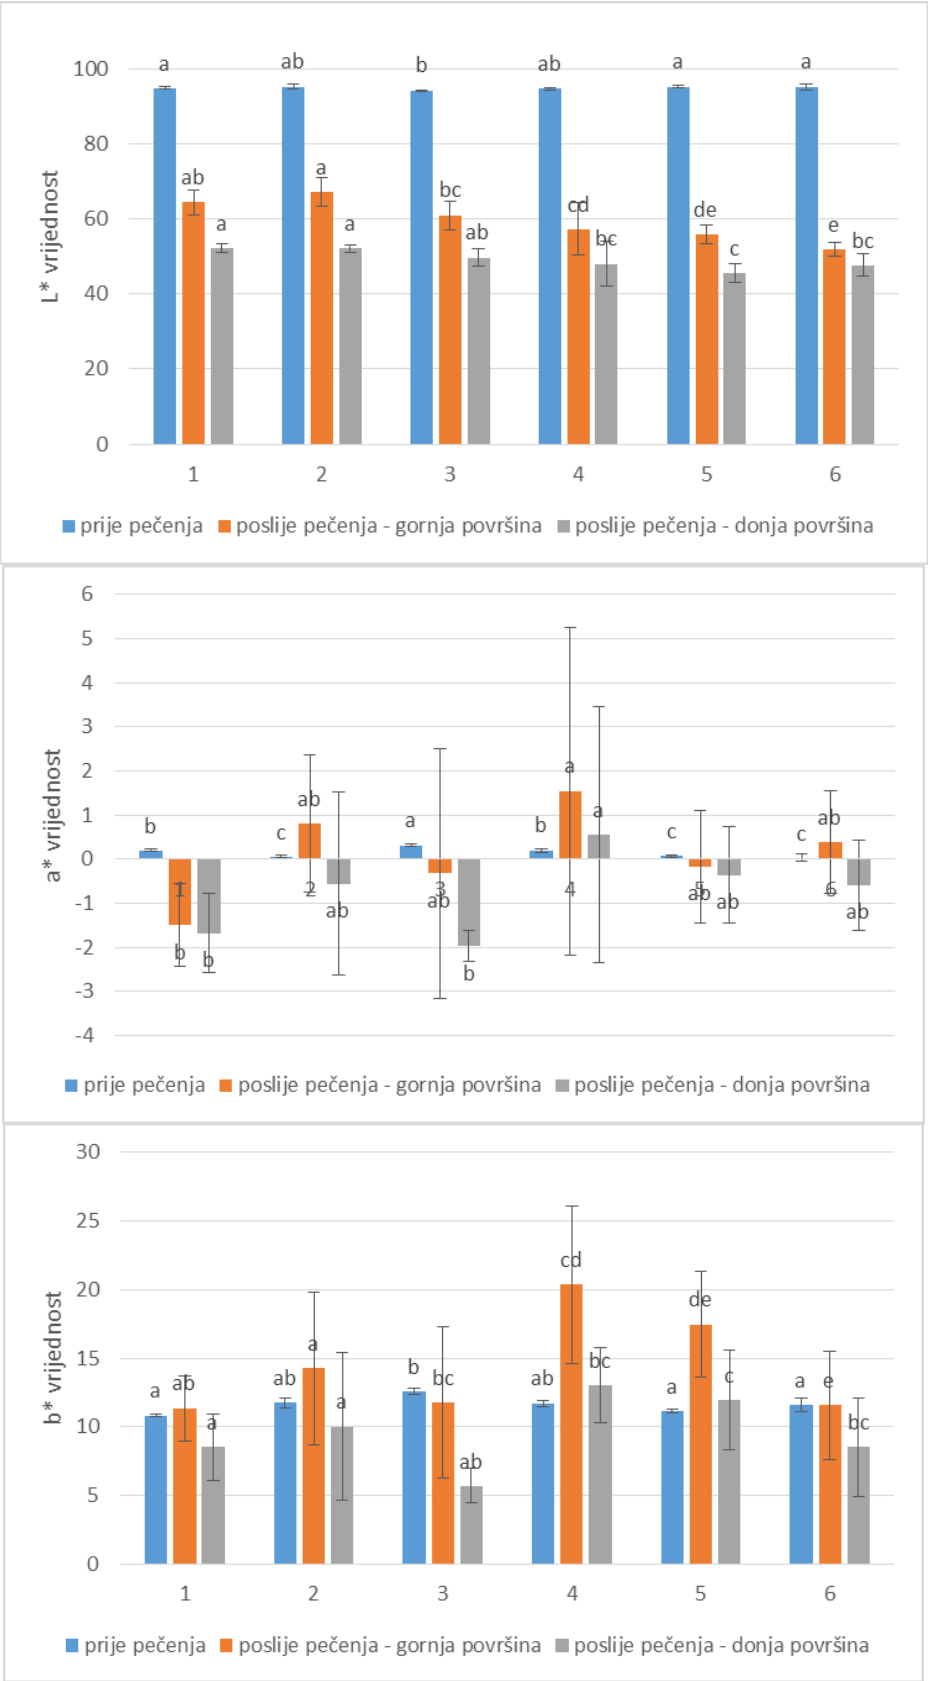

Slika 14 Rezultati promjene boje dobivene kolorimetrom

4.2.2. Rezultati dobiveni računalnom analizom slike

Slika 15 prikazuje rezultate *L**, *a** i *b** vrijednosti uzoraka određene uz pomoć računalne analize slike.

Prije pečenja *L** vrijednosti svih uzoraka su bile visoke (iznad 90,26), a samim tim i boja uzoraka je bila svijetla. Nakon pečenja došlo je do smanjenja vrijednosti, što znači da je boja uzoraka postala tamnija. Za razliku od rezultata dobivenih kolorimetrijski, ovdje su, očekivano, niže *L** vrijednosti nakon pečenja zabilježene na gornjoj površini uzoraka (34,98-42,08), što ukazuje da je i boja tu bila tamnija.

Za razliku od rezultata *a** vrijednosti određenih kolorimetrom, kod računalne analize slike svi uzorci imaju negativnu vrijednost, što znači da se nalaze u domeni zelene boje.

Kao i kod određivanja boje kolorimetrom, i ovdje su kod svih uzoraka očitane pozitivne *b** vrijednost što znači da prevladava žuta boja. Najviše vrijednosti su nakon pečenja s donje površine uzoraka, te se kreću u rasponu 14-20,9, osim uzorka 3 koji ima vrijednost 7,3.

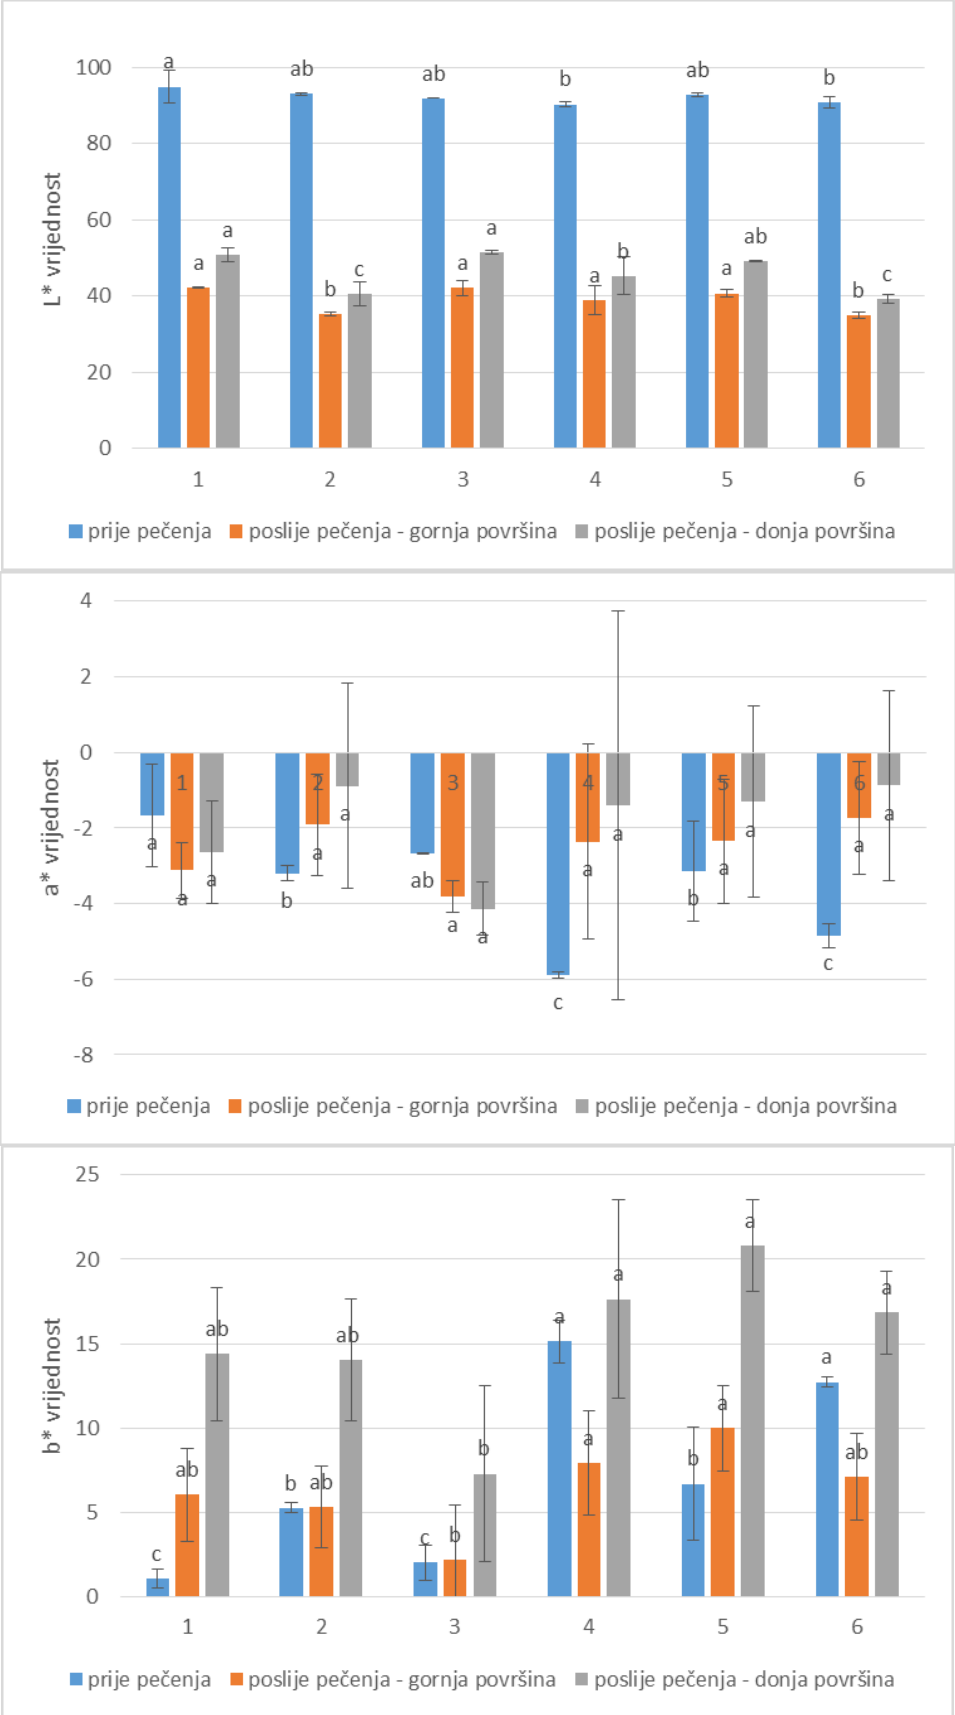

Slika 15 Rezultati promjene boje dobivene računalnom analizom slike

4.2.3. Ukupna promjena boje i posmeđivanje uzoraka tijekom pečenja

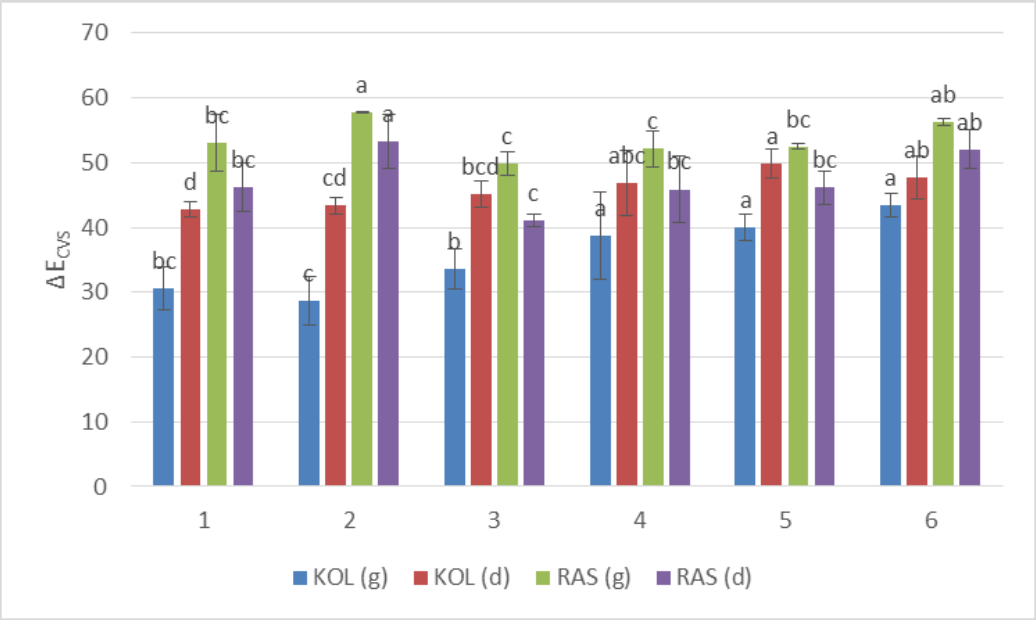

Legenda: KOL – kolorimetar, RAS – računalna analiza slike, (g) – gornja površina, (d) – donja površina

Slika 16 Ukupna promjena boje površine Mozzarella sira tijekom pečenja

Slika 16 prikazuje rezultate ukupne promjene boje Mozzarelle određene kolorimetrom i računalnom analizom slike donje i gornje površine uzoraka. Kao što je uočeno i kod *L** parametra boje, rezultati dobiveni pomoću kolorimetra pokazuju da je do veće promjene boje došlo s donje strane uzoraka, za razliku od računalne analize slike, čiji rezultati pokazuju suprotno. Budući da je za očekivati da će do veće promjene boje (odnosno jačeg tamnjenja) doći na površini uzorka, dolazi do neslaganja s podacima dobivenim kolorimetrom. Ovo bi se moglo protumačiti samim principom analize boje uzoraka. Naime, određivanje boje kolorimetrom se zasniva na analizi površine uzorka od svega nekoliko centimetara (Lukinac-Čačić, 2012), a budući da posmeđivanje površine sira nije jednolično (**Prilog 2-7**), ovom metodom je zapravo teško dobiti reprezentativne podatke za cijelu površinu.

Za razliku od određivanja boje kolorimetrom, računalna analiza slike može obuhvatiti cjelokupnu površinu, što ju čini objektivnijom i preciznijom metodom. Rezultati određivanja ukupne promjene boje računalnom analizom slike pokazuju da je do najveće promjene boje došlo na gornjoj površini uzorka 2, a najmanje na donjoj površini uzorka 3. Nije pronađena statistički značajna korelacija između vrijednosti dobivenih određivanjem pomoću kolorimetra i računala (**Tablica 10**).

Slika 17 predstavlja grafički prikaz rezultata određivanja faktora posmeđivanja pomoću dvije metode (kolorimetar i računalna analiza slike) gornje i donje površine ispitivanog sira. Faktor posmeđivanja (BF) ukazuje na to koliko je tamniji uzorak nakon pečenja u usporedbi s onim prije. Očekuje se da parametar svjetline sira nakon pečenja bude niži od onoga prije zbog nastanka tamnije boje uslijed posmeđivanja. Stoga bi sirevi nakon pečenja trebali imati vrijednost BF iznad 100%. Veća vrijednost BF odgovara tamnijoj boji sira nakon pečenja. Vrijednosti faktora posmeđivanja određenog kolorimetrom kretale su se u rasponu 142,24-183,74 za gornju površinu sira, i 181,86-209,81 za donju površinu sira. Faktor posmeđivanja određen računalnom analizom slike imao je više vrijednosti: za gornju površinu kretao se u rasponu 218,59-263,54, odnosno 178,82-231,94 za donju.

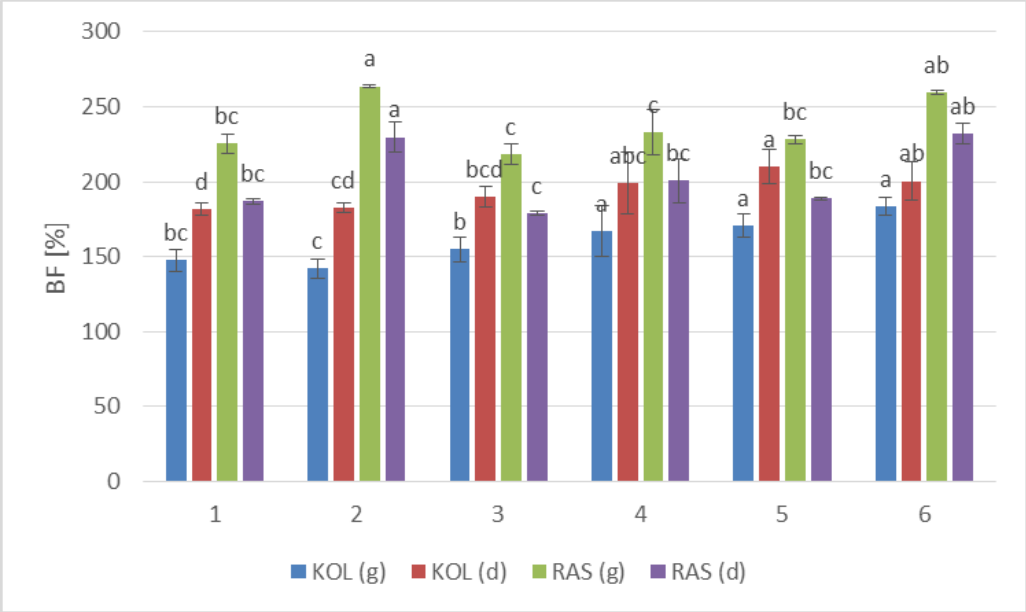

Legenda: KOL – kolorimetar, RAS – računalna analiza slike, (g) – gornja površina, (d) – donja površina

Slika 17 Faktor posmeđivanja uzoraka Mozzarella sira

Postoji statistički značajna pozitivna korelacija između faktora posmeđivanja i ukupne promjene boje (**Tablica 10**), jer zapravo najveći doprinos ukupnoj promjeni boje daje promjena *L** vrijednosti.

Uočeno je da se kod kolorimetra jače posmeđivanje (kao i ukupna promjena boje) dogodilo na donjoj strani. Vidljivo je da ova metoda nije primjerena za praćenje u realnim uvjetima jer se zapravo najveće promjene boje i najveće posmeđivanje odvijaju na površini sira. Stoga je prikladnija za analizu i pokazuje stvarne promjene, metoda računalne analize slike.

Tablica 10 Pearsonova korelacijska matrica podataka dobivenih ispitivanjem boje uzoraka Mozzarella sira

varijable	L^*_{KOL}	$L^*_{KOL}(g)$	$L^*_{KOL}(d)$	$\Delta E_{KOL}(g)$	$\Delta E_{KOL}(d)$	$BF_{KOL}(g)$	$BF_{KOL}(d)$	L^*_{RAS}	$L^*_{RAS}(g)$	$L^*_{RAS}(d)$	$\Delta E_{RAS}(g)$	$\Delta E_{RAS}(d)$	$BF_{RAS}(g)$	$BF_{RAS}(d)$
L^*_{KOL}	**1**	-0,179	-0,208	0,236	0,308	0,261	0,290	0,107	-0,659	-0,644	0,797	**0,843**	0,715	0,684
$L^*_{KOL}(g)$		**1**	**0,872**	**-0,996**	**-0,864**	**-0,995**	**-0,861**	0,665	0,182	0,221	0,129	0,015	-0,030	-0,119
$L^*_{KOL}(d)$			**1**	**-0,891**	**-0,994**	**-0,851**	**-0,995**	0,560	-0,004	0,009	0,281	0,166	0,150	0,099
$\Delta E_{KOL}(g)$				**1**	**0,887**	**0,995**	**0,887**	-0,678	-0,219	-0,259	-0,091	0,029	0,065	0,153
$\Delta E_{KOL}(d)$					**1**	**0,852**	**0,996**	-0,538	-0,079	-0,087	-0,181	-0,066	-0,056	-0,013
$BF_{KOL}(g)$						**1**	**0,848**	-0,661	-0,267	-0,307	-0,031	0,083	0,122	0,210
$BF_{KOL}(d)$							**1**	-0,539	-0,046	-0,059	-0,212	-0,094	-0,094	-0,045
L^*_{RAS}								**1**	0,406	0,438	0,076	-0,007	-0,202	-0,295
$L^*_{RAS}(g)$									**1**	**0,996**	**-0,878**	**-0,903**	**-0,977**	**-0,989**
$L^*_{RAS}(d)$										**1**	**-0,862**	**-0,894**	**-0,964**	**-0,987**
$\Delta E_{RAS}(g)$											**1**	**0,991**	**0,956**	**0,927**
$\Delta E_{RAS}(d)$												**1**	**0,961**	**0,943**
$BF_{RAS}(g)$													**1**	**0,992**
$BF_{RAS}(d)$														**1**

Podebljane vrijednosti su statistički značajne na nivou značajnosti $p<0,05$

4.3. SENZORSKA SVOJSTVA

Jedan od najvažnijih faktora koji određuje kvalitetu gotovog proizvoda je i nivo senzorske poželjnosti. **Slike 18-23** prikazuju da u vrijednostima senzorskih ocjena poslije pečenja nema većih statističkih razlika između uzoraka, osim kod ocjene za okus, dok su prije pečenja rezultati senzorske ocjene značajno različiti. Uzorci 1, 2 i 4 su nakon pečenja najbolje ocjenjeni, s izvrsnim ocjenama za sva senzorska svojstva, dok se uzorak 5 pokazao kao lošiji proizvod što je posljedica niže ocjene za okus zbog previsokog sadržaja soli (**Tablica 8**).

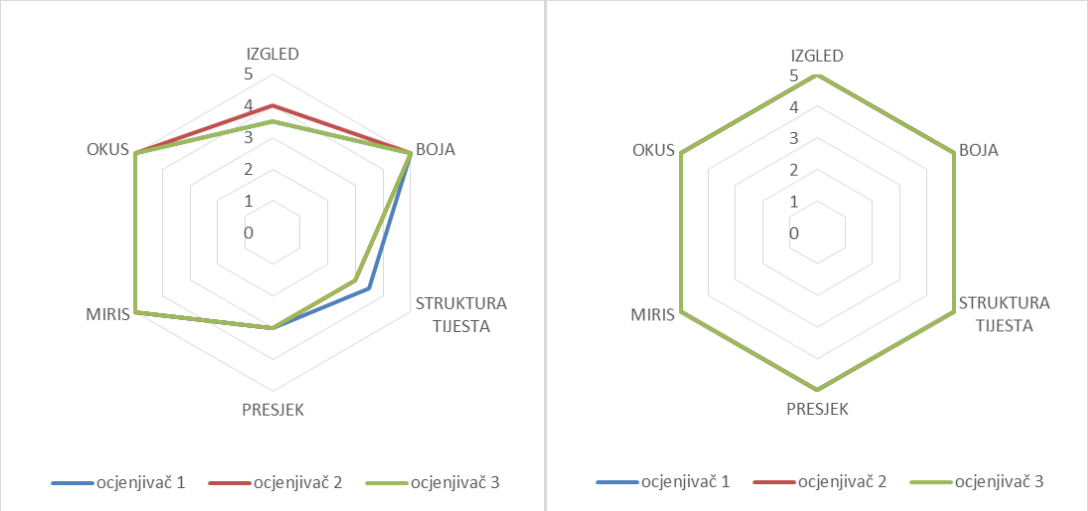

Slika 18 Senzorska ocjena uzorka 1 prije (lijevo) i poslije (desno) pečenja

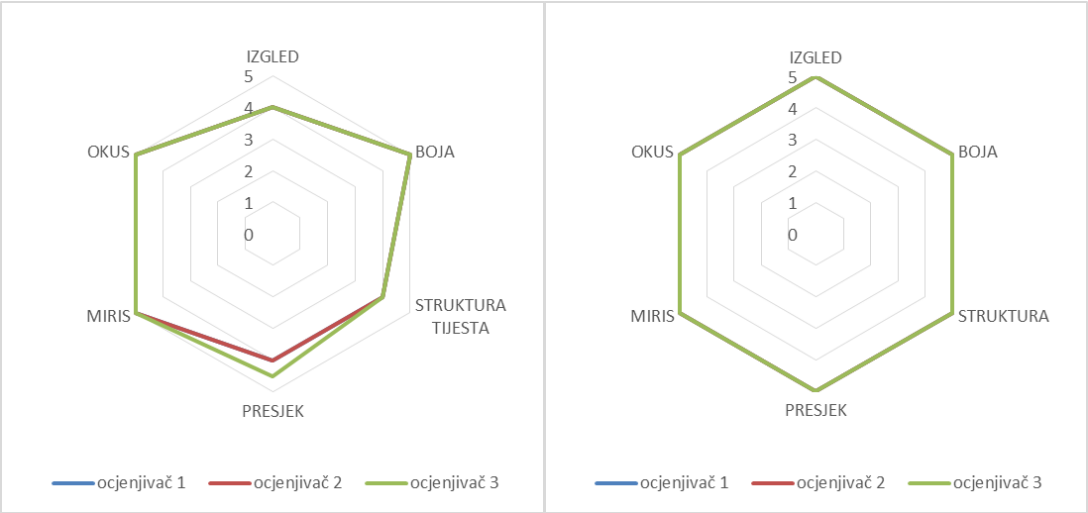

Slika 19 Senzorska ocjena uzorka 2 prije (lijevo) i poslije (desno) pečenja

Slika 20 Senzorska ocjena uzorka 3 prije (lijevo) i poslije (desno) pečenja

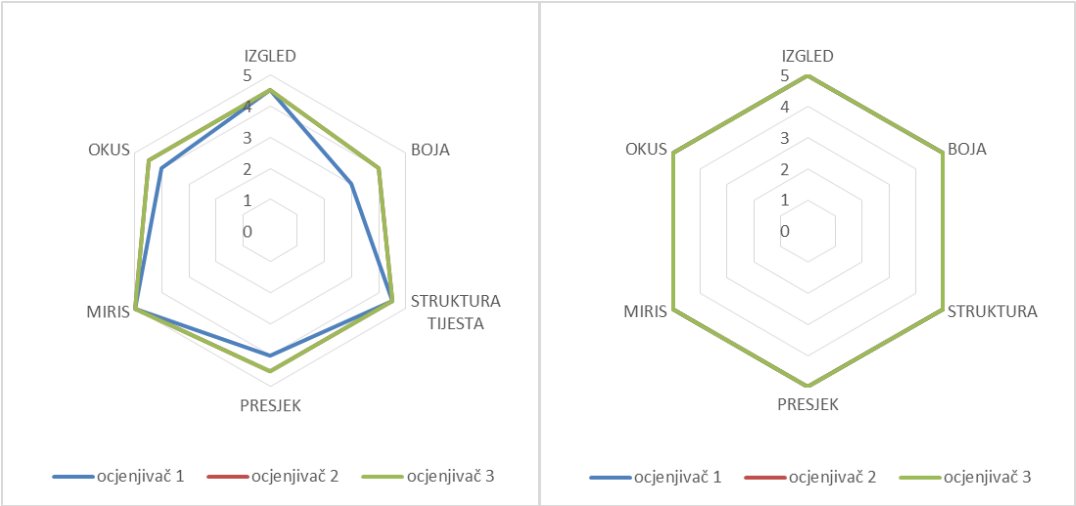

Slika 21 Senzorska ocjena uzorka 4 prije (lijevo) i poslije (desno) pečenja

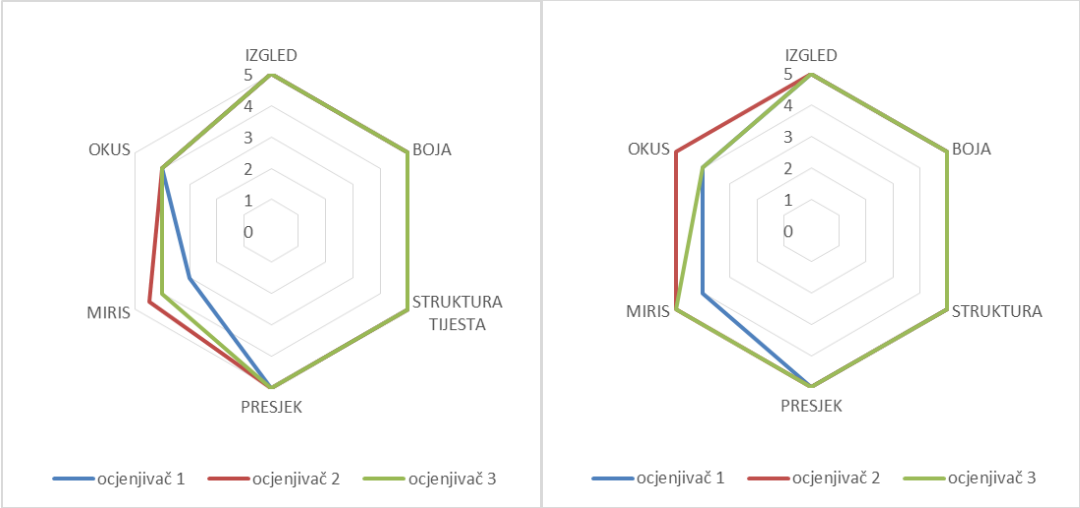

Slika 22 Senzorska ocjena uzorka 5 prije (lijevo) i poslije (desno) pečenja

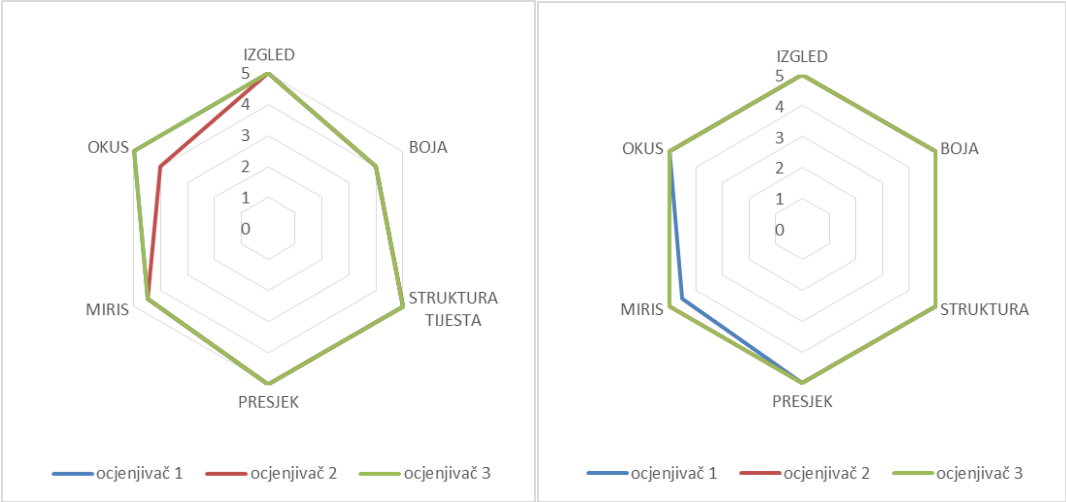

Slika 23 Senzorska ocjena uzorka 6 prije (lijevo) i poslije (desno) pečenja

Ponderirane bodove, koji se računaju kao zbroj umožaka ocjene i čimbenika značajnosti za svako svojstvo, prikazuju **Slika 24** i **Slika 25**. Iz prikazane raspodjele bodova vidljivo je da najveći utjecaj na ukupnu senzorsku ocjenu imaju okus i miris. Na **Slici 24** prikazane su vrijednosti ponderiranih bodova za uzorke prije pečenja i iz njih je vidljivo da nema značajnijih razlika između uzoraka 1, 4 i 5, te između 2 i 3 dok je uzorak 6 označen s najboljom ukupnom ocjenom. **Slika 25** prikazuje vrijednosti ponderiranih bodova nakon pečenja, te je vidljivo da su s maksimalnim brojem bodova ocijenjeni uzorci 1, 2, 4 i 6, a najlošije je ocijenjen uzorak 5. Prema ukupno dobivenim ponderiranim bodovima nakon pečenja svi uzorci se mogu svrstati u kategoriju izvrsne kakvoće proizvoda prema **Tablici 6**. Može se zaključiti da je razina kakvoće istraživanih uzoraka vrlo visoka, prema procjeni senzorskih analitičara.

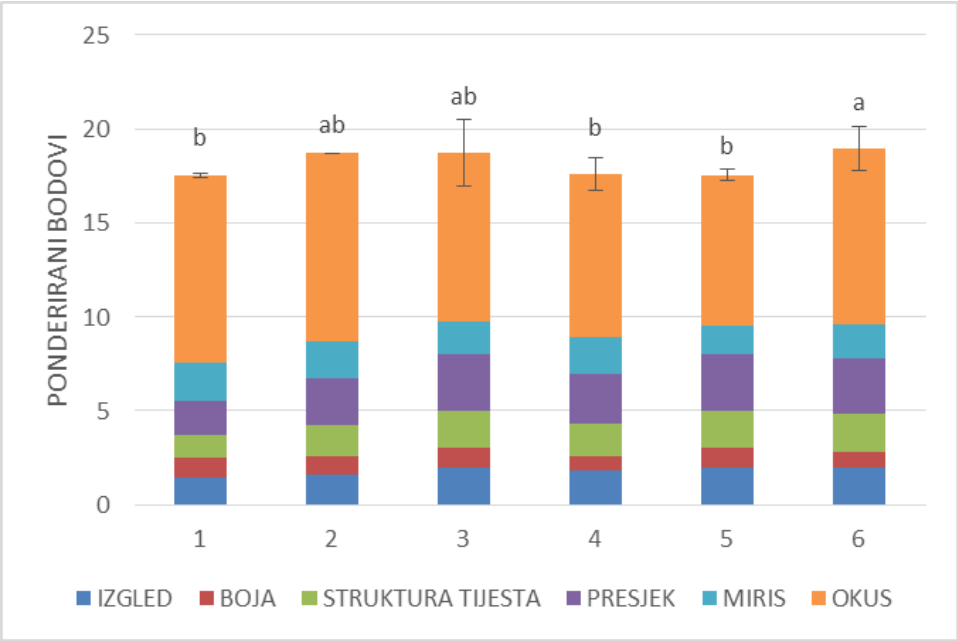

Slika 24 Vrijednost ponderiranih bodova uzoraka prije pečenja

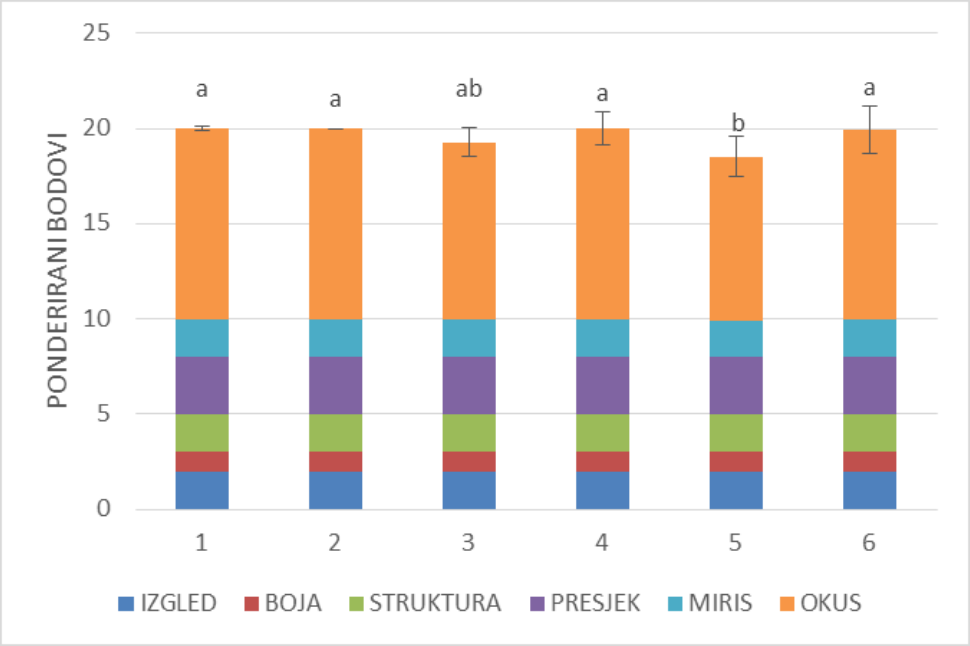

Slika 25 Vrijednost ponderiranih bodova uzoraka poslije pečenja

4.4. REZULTATI DESKRIPTIVNE ANALIZE

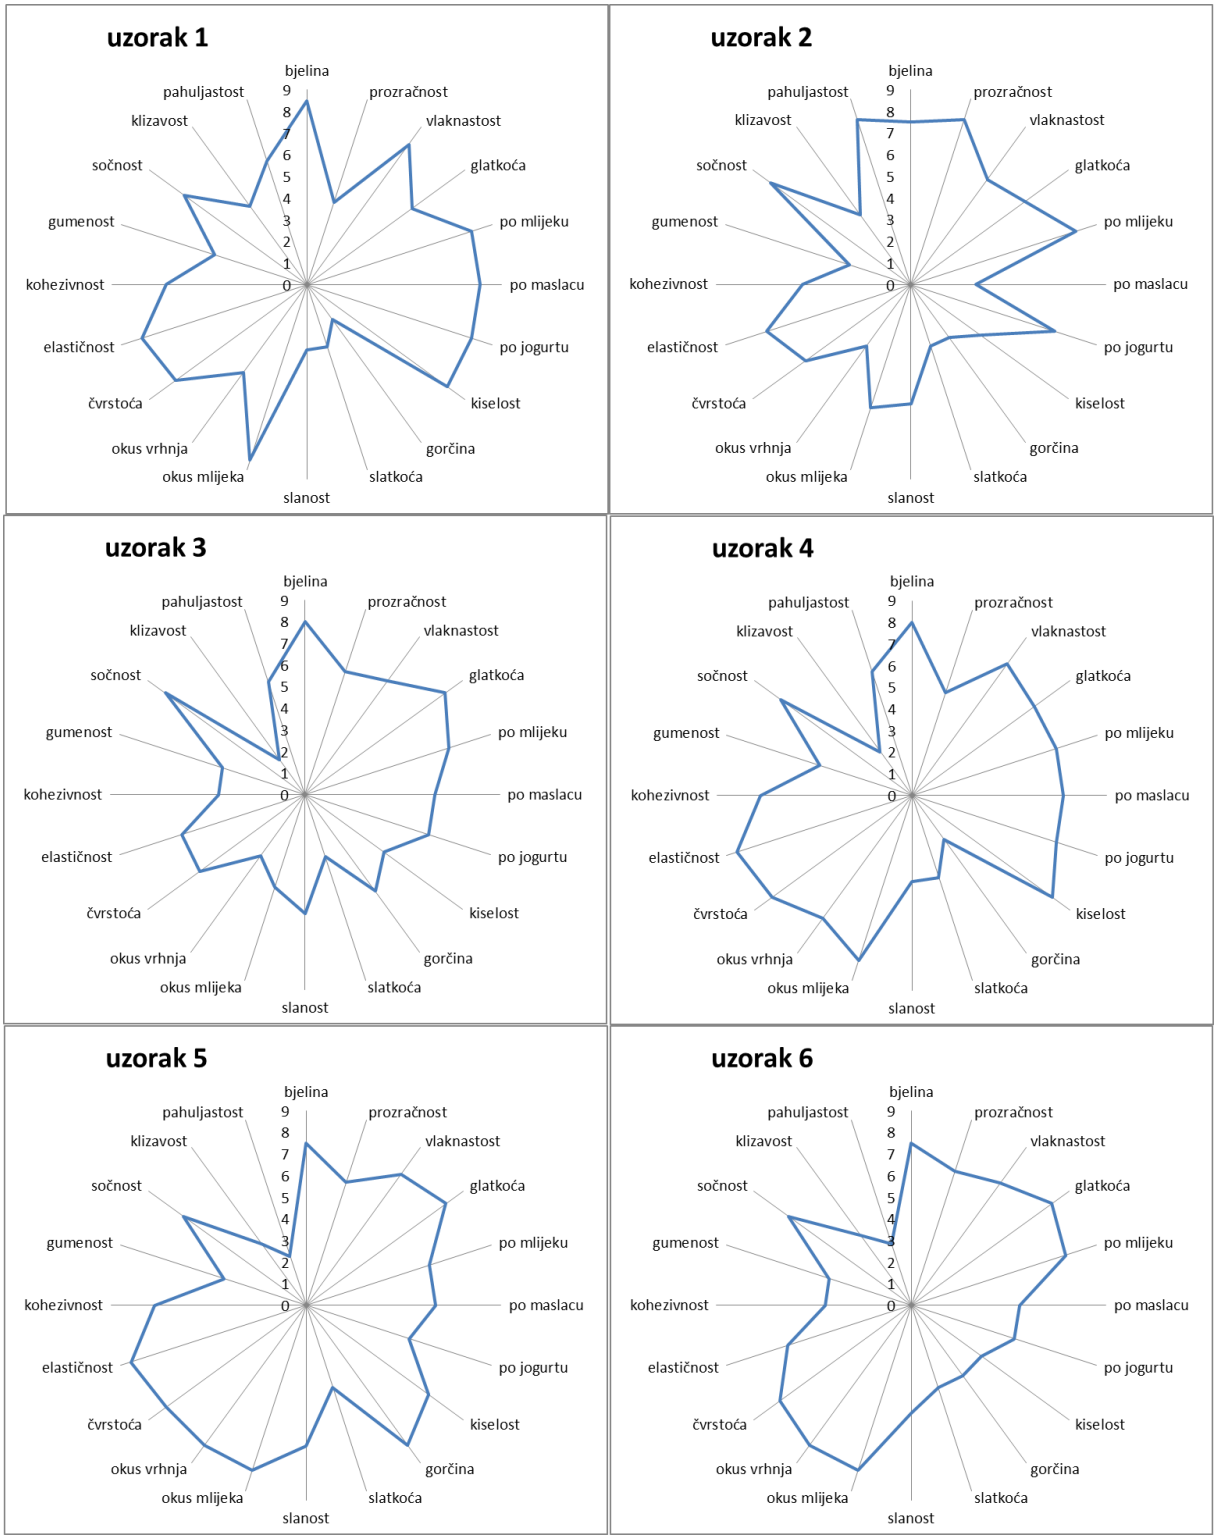

Slika 26 Rezultati deskriptivne analize za senzorska svojstva

Na **Slici 26** prikazane su ocjene deskriptivne analize za vanjski izgled, miris, okus tijekom žvakanja i teksturu tijekom žvakanja.

Parametri koji određuju vanjski izgled su bjelina, prozračnost, vlaknatost i glatkoća. Najveću vlaknatost pokazao je uzorak 1, koji je imao i vrlo visoku vrijednost suhe tvari (40,08%), te je uočena statistički značjna pozitivna korelacija između vlaknatosti i suhe tvari sira (0,847; **Tablica 11**). Vrijednosti za glatkoću su vrlo visoke za sve uzorke. Postoji statistički značajna pozitivna korelacija s ocjenama za izgled, strukturu i presjek sira.

Jedan od najizraženijih okusa tijekom žvakanja je slanost. Deskriptivnom analizom najveću ocjenu za slanost je dobio uzorak 5, što je bilo i očekivano, budući da je utvrđeno ispitivanjem fizikalno-kemijskih svojstava da ima najveći udio soli, te postoji statistički značajna korelacija između ovih vrijednosti (0,976; **Tablica 11**). Sljedeći važan okus je kiselost. Ispitivanjem pH vrijednosti uzoraka utvrđeno je da najniži pH, odnosno najveću kiselost, ima uzorak 1. Uočena je i statistički značajna negativna korelacija između izmjerene pH vrijednosti sira i ocjene za kiselost uzorka (-0889; **Tablica 11**).

Sočnost je parametar koji dobijemo određivanjem teksture tijekom žvakanja. Najveće vrijednosti za sočnost imaju uzorci 2 i 3, koje su i uzorci s najvišim udjelom vode. Također, ti uzorci imaju i najniže vrijednosti za čvrstoću.

Rezultati deskriptivne analize pokazuju vrlo dobro s rezultatima ispitivanja osnovnog kemijskog sastava sira.

Tablica 11 Pearsonova korelacijska matrica podataka dobivenih ispitivanjem fizikalno-kemijskih i senzorskih svojstava Mozzarella sir

Variables	vlaknastost	glatkoća	po mlijeku	po jogurtu	kiselost	gorčina	slanost	okus mlijeka	okus vrhnja	čvrstoća	elastičnost	kohezivnost	gumenost	sočnost	klizavost
mast	0,780	-0,322	0,059	0,121	0,597	-0,251	-0,465	**0,993**	0,687	**0,845**	0,574	0,594	0,475	**-0,880**	0,655
voda	**-0,847**	0,093	0,226	0,059	-0,672	0,042	0,331	**-0,980**	**-0,837**	**-0,966**	-0,638	-0,664	-0,601	**0,908**	-0,429
proteini	-0,083	0,736	-0,740	-0,488	-0,003	0,541	0,415	-0,399	0,160	0,034	-0,086	-0,074	0,268	0,271	**-0,934**
NaCl	-0,588	0,603	-0,590	-0,654	-0,461	0,769	**0,976**	-0,470	0,025	-0,283	-0,120	-0,160	-0,636	0,363	-0,323
s.t	**0,847**	-0,093	-0,226	-0,059	0,672	-0,042	-0,331	**0,980**	**0,837**	**0,966**	0,638	0,664	0,601	**-0,908**	0,429
aw	-0,239	**0,879**	**-0,826**	-0,784	-0,211	0,728	0,735	-0,287	0,387	0,097	-0,098	-0,106	-0,045	0,158	-0,705
pH	-0,802	0,623	-0,169	-0,694	**-0,889**	0,552	**0,849**	-0,601	-0,126	-0,562	-0,667	-0,698	-0,762	0,380	-0,119
izgled	-0,162	**0,993**	-0,737	**-0,915**	-0,334	0,747	0,673	-0,225	0,466	0,113	-0,335	-0,324	0,052	-0,049	-0,556
struktura	-0,295	**0,968**	-0,710	**-0,902**	-0,404	0,714	0,735	-0,290	0,418	0,040	-0,339	-0,340	-0,082	0,076	-0,586
presjek	-0,417	**0,950**	-0,656	**-0,909**	-0,513	0,724	0,810	-0,364	0,341	-0,068	-0,399	-0,408	-0,232	0,151	-0,535
miris	-0,032	**-0,830**	**0,826**	**0,842**	0,136	**-0,979**	-0,766	0,103	-0,406	-0,162	0,069	0,057	0,000	0,259	0,239
okus	-0,261	-0,702	**0,984**	0,634	-0,294	-0,758	-0,532	-0,109	-0,605	-0,504	-0,365	-0,373	-0,311	0,217	0,549
bodovi	-0,793	0,386	0,330	-0,375	**-0,963**	0,001	0,333	-0,616	-0,309	-0,684	**-0,962**	**-0,976**	-0,566	0,455	-0,100
miris	-0,055	**-0,835**	0,808	**0,876**	0,146	**-0,961**	-0,756	0,026	-0,483	-0,219	0,070	0,057	0,000	0,332	0,168
okus	-0,081	-0,611	**0,867**	0,592	-0,091	**-0,956**	-0,722	0,152	-0,226	-0,128	-0,204	-0,209	0,000	0,122	0,308
bodovi	-0,080	-0,637	**0,870**	0,624	-0,071	**-0,966**	-0,732	0,142	-0,252	-0,138	-0,182	-0,187	0,000	0,142	0,298
prozračnost	**-0,893**	0,272	0,073	-0,406	**-0,830**	0,235	0,707	-0,508	-0,215	-0,580	-0,483	-0,537	**-0,942**	0,512	0,032
vlaknastost	**1**	-0,193	-0,224	0,187	**0,872**	-0,070	-0,538	0,807	0,557	**0,851**	0,659	0,705	**0,868**	-0,806	0,222
glatkoća		**1**	-0,712	**-0,938**	-0,391	0,782	0,709	-0,253	0,430	0,061	-0,389	-0,378	0,000	-0,058	-0,497
po mlijeku			**1**	0,653	-0,252	**-0,850**	-0,611	-0,042	-0,530	-0,425	-0,338	-0,346	-0,241	0,201	0,510
po maslacu				0,320	**0,824**	-0,120	-0,616	0,456	0,238	0,582	0,480	0,535	**0,954**	-0,492	-0,130
kiselost					**1**	-0,144	-0,517	0,639	0,322	0,722	**0,887**	**0,913**	0,745	-0,476	0,022
gorčina						**1**	**0,847**	-0,193	0,312	0,080	-0,006	-0,005	-0,122	-0,120	-0,290
slatkoća							0,221	0,581	**0,950**	0,784	0,312	0,319	0,333	-0,557	-0,094
čvrstoća										**1**	0,674	0,702	0,686	**-0,838**	0,184
elastičnost											**1**	**0,998**	0,390	-0,377	0,118

Podebljane vrijednosti su statistički značajne na nivou značajnosti $p<0,05$

5. ZAKLJUČCI

Na osnovi rezultata istraživanja provedenih u ovom radu, mogu se izvesti sljedeći zaključci:

1. Svi prikupljeni uzorci Mozzarella sira udovoljavaju zahtjevima Pravilnika (MPRRR, 2013) o udjelu vode u bezmasnoj suhoj tvari sira za meke sireve. Također, prema udjelu mliječne masti u suhoj tvari svi proizvodi spadaju u skupinu punomasnih sireva, osim „light“ proizvoda koji spada u masne sireve.

2. Prema ukupno dobivenim ponderiranim bodovima nakon pečenja svi uzorci se mogu svrstati u kategoriju izvrsne kakvoće proizvoda, te se može zaključiti da je razina kakvoće istraživanih uzoraka vrlo visoka prema procjeni senzorskih analitičara.

3. Pečenjem sira Mozzarelle došlo je do posmeđivanja i nastanka mjehurića na površini sira. Posmeđivanje slabijeg intenziteta je poželjna karakteristika za sireve koji služe kao topinzi na pizzama i drugim jelima, dok je jače posmeđivanje nepoželjno.

4. Tijekom pečenja uzoraka sira Mozzarella je došlo do smanjenja parametra svjetline sira (*L**) uslijed tamnjenja uzorka: *L** vrijednosti prije pečenja su se kretale u rasponu 89,28-99,17, a nakon pečenja 34,13-71,08; ovisno o upotrijebljenoj metodi (kolorimetar, računalna analiza slike), te da li se radilo o gornjoj odnosno donjoj površini uzorka.

5. Izračunata vrijednost faktora posmeđivanja je kod svih uzoraka iznosila iznad 100%, što ukazuje na to da su svi uzorci bili tamnije boje nakon pečenja u usporedbi s onim prije.

6. Vrijednosti faktora posmeđivanja određenog kolorimetrom kretale su se u rasponu 142,24-183,74 za gornju površinu sira, i 181,86-209,81 za donju površinu sira. Faktor posmeđivanja određen računalnom analizom slike imao je više vrijednosti: za gornju površinu kretao se u rasponu 218,59-263,54, odnosno 178,82-231,94 za donju.

7. Postoji statistički značajna pozitivna korelacija između faktora posmeđivanja i ukupne promjene boje.

8. Rezultati dobiveni pomoću kolorimetra pokazuju da je do veće ukupne promjene boje došlo, neočekivano, s donje strane uzoraka, što ovu metodu čini neadekvatnom za ispitivanja nejednoličnih promjena boje na cijeloj površini uzorka.

9. Kod rezultata određenih računalnom analizom slike, suprotno rezultatima dobivenim kolorimetrom, vrijednosti ukupne promjene boje gornje površine uzoraka bile su veće u odnosu na donju površinu uzoraka.

10. Za razliku od određivanja boje kolorimetrom, računalna analiza slike može obuhvatiti cjelokupnu površinu uzoraka, što ju čini objektivnijom i preciznijom metodom.

6. LITERATURA

Dimitrov E, Mladenov M: Complex Assessment of Diary Products using Color Images and Spectral Analyses. *Information, Communication and Control Systems and Technologies*, University of Ruse, 2012.

Filajdić M, Ritz M, Vojnović V: Senzorska analiza mliječnih proizvoda. *Mljekarstvo* 38:295-301, Prehrambeno-biotehnološki fakultet, Zagreb, 1988.

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

Koprivnjak O: *Kvaliteta, sigurnost i konzerviranje hrane* (Uvod u prehrambene tehnologije). Sveučilište u Rijeci, Rijeka, 2014.

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

Mandić M, Perl A: *Osnove senzorske procjene hrane*. Prehrambeno-tehnološki fakultet, Osijek, 2006.

Matijević B, Kalit S, Perko B, Božanić R: *Sirarstvo u teoriji i praksi*. Veleučilište u Karlovcu, Karlovac, 2015.

MPRR, Ministarstvo poljoprivrede, ribarstva i ruralnog razvoja: Pravilnik o sirevima i proizvodima od sira. Narodne novine 20/13, 2013.

Pagliarini E: *Sensory profile description of Mozzarella Cheese and its relationship with consumer preference.* Universita degli Studi di Milano, Milano, 1997.

Pranjić K: *Optimiranje procesa prženja tijesta različitih oblika primjenom računalne analize slike*. Prehrambeno-tehnološki fakultet, Osijek, 2005.

Primorac Lj: *Metode senzorske ocjene hrane*. Prehrambeno-tehnološki fakultet, Osijek, 2006.

Puglia S: *Handbook for Digital Projects: A Management Tool for Preservation and Access*. Northeast Conservation Center, Massachusetts, 2000.

Slačanac V: *Tehnologija mlijeka i mliječnih proizvoda*. Prehrambeno-tehnološki fakultet, Osijek, 2016.

Tratnik Lj: *Mlijeko – Tehnologija, biokemija i mikrobiologija*. Hrvatska mljekarska udruga, Zagreb, 1998.

Tuntragul S: *Factors affecting on streatchability and meltability of imitation Mozzarella cheese*. Kasetsart University, 2010.

Wang H, Sun D: Assessment of cheese browning affected by baking conditions using computer vision. *Journal of Food Engineering* 56:339-345, 2002.

Xixiu Ma: *Evaluation of Functional Properties and Microstructure of Mozzarella Cheese, and their Correlation*. The University of Auckland, 2013.

7. PRILOZI

Prilog 1 Fotografije uzoraka Mozzarelle prije pečenja

uzorak 1

uzorak 2

uzorak 3

uzorak 4

uzorak 5

uzorak 6

Prilog 2 Fotografije gornje (gore) i donje (dolje) površine uzorka 1 sira Mozzarelle nakon pečenja

Prilog 3 Fotografije gornje (gore) i donje (dolje) površine uzorka 2 sira Mozzarelle nakon pečenja

Prilog 4 Fotografije gornje (gore) i donje (dolje) površine uzorka 3 sira Mozzarelle nakon pečenja

Prilog 5 Fotografije gornje (gore) i donje (dolje) površine uzorka 4 sira Mozzarelle nakon pečenja

Prilog 6 Fotografije gornje (gore) i donje (dolje) površine uzorka 5 sira Mozzarelle nakon pečenja

Prilog 7 Fotografije gornje (gore) i donje (dolje) površine uzorka 6 sira Mozzarelle nakon pečenja