

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
PREHRAMBENO-TEHNOLOŠKI FAKULTET OSIJEK

Zdravko Vulin

ODREĐIVANJE BOJE I STABILNOSTI PJENE LAGER PIVA RAČUNALNOM
ANALIZOM SLIKE

DIPLOMSKI RAD

Osijek, svibanj, 2019.

TEMELJNA DOKUMENTACIJSKA KARTICA

DIPLOMSKI RAD

Sveučilište Josipa Jurja Strossmayera u Osijeku
Prehrambeno-tehnološki fakultet Osijek
Zavod za procesno inženjerstvo
Katedra za bioproceno inženjerstvo
Franje Kuhača 20, 31000 Osijek, Hrvatska

Diplomski sveučilišni studij prehrambeno inženjerstvo

Znanstveno područje: Biotehničke znanosti
Znanstveno polje: Prehrambena tehnologija
Nastavni predmet: Biotehnološka proizvodnja hrane
Tema rada je prihvaćena na IX. redovitoj sjednici Fakultetskog vijeća Prehrambeno-tehnološkog fakulteta Osijek u akademskoj godini 2017./2018. održanoj 29. lipnja 2018.
Mentor: doc. dr. sc. *Kristina Mastanjević*
Komentor: izv. prof. dr. sc. *Jasmina Lukinac Čačić*
Pomoć pri izradi: Izv. prof. dr. sc. *Marko Jukić*

Određivanje boje i stabilnosti pjene lager piva računalnom analizom slike

Zdravko Vulin, 396-DI

Sažetak:

Boja piva i stabilnost pjene važni su pokazatelji kvalitete i svježine piva, stoga je njihovo praćenje važno tijekom procesa proizvodnje, transporta i skladištenja. U ovom radu mjerena je boja i stabilnost pjene 12 različitih vrsta piva deklariranih kao crno, tamno, pils i svijetlo lager pivo, računalnom analizom slike. Rezultati boje piva prikazani su kao komponente CIEL*a*b* sustava boja, a stabilnost pjene izražena kao promjena visine stupca pjene tijekom vremena i modelirana primjenom eksponencijalnog modela gubitka pjene. Računalna analiza slike pokazala se kao prikladna, objektivna, ponovljiva, pouzdana i dovoljno osjetljiva metoda za mjerenje boje i stabilnosti pjene različitih vrsta piva. Primijenjeni matematički model pokazao se kao prikladan za predviđanje promjene gubitka pjene različitih vrsta piva svijetlih i tamnih piva. S obzirom na rezultate stabilnosti pjene, u prosjeku tamna piva imala su stabilniju pjenu.

Ključne riječi: pivo, boja, pjena, računalna analiza slike

Rad sadrži: 61 stranica
43 slika
12 tablica
0 priloga
37 literaturne reference

Jezik izvornika: hrvatski

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

- | | |
|--|---------------|
| 1. prof. dr. sc. <i>Vinko Krstanović</i> | predsjednik |
| 2. doc. dr. sc. <i>Kristina Mastanjević</i> | član-mentor |
| 3. izv. prof. dr. sc. <i>Jasmina Lukinac Čačić</i> | član-komentor |
| 4. izv. prof. dr. sc. <i>Marko Jukić</i> | zamjena člana |

Datum obrane: 30. svibnja 2019.

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 Process Engineering
Subdepartment of Bioprocess Engineering
Franje Kuhača 20, HR-31000 Osijek, Croatia

Graduate program Food engineering

Scientific area: Biotechnical sciences

Scientific field: Food technology

Course title: Basics of Bioprocess Engineering

Thesis subject was approved by the Faculty of Food Technology Osijek Council at its session no. IX held on Jun 29, 2018

Supervisor: *Kristina Mastanjević*, PhD, assistant prof.

Co-supervisor *Jasmina Lukinac Čačić*, PhD, associate prof.

Technical assistance: *Marko Jukić*, PhD, associate prof.

Beer colour and foam stability determination using image analysis method

Zdravko Vulin, 396-DI

Summary:

Beer colour and foam stability are important indicators of beer quality and freshness. Their monitoring during the production, transportation and storage processes is very important. In this paper beer colour and foam stability are measured with image analysis method on 12 different types of beers (declared as black, dark, pils and light beer type). The beer colour is presented in CIE L*a*b* colour system. Beer foam stability is expressed as a change of foam height during the time. Beer foam stability is modelled by using an exponential decay model. According to the results, digital image analysis method proved to be a suitable, objective, repeatable, reliable and sufficiently sensitive method for measuring colour and foam stability of different beer types. The applied mathematical model proved to be suitable for predicting changes in foam loss of different types of light and dark beer.

Key words: Beer, Colour, Foam, Digital Image Analysis

Thesis contains: 61 pages
43 figures
12 tables
0 supplements
37 references

Original in: Croatian

Defense committee:

- | | |
|--|---------------|
| 1. <i>Vinko Krstanović</i> , PhD, prof. | chair person |
| 2. <i>Kristina Mastanjević</i> , PhD, assistant prof. | supervisor |
| 3. <i>Jasmina Lukinac Čačić</i> , PhD, associate prof. | Co-supervisor |
| 4. <i>Marko Jukić</i> , PhD, associate prof. | stand-in |

Defense date: May, 30th, 2019

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

1. UVOD	1
2. TEORIJSKI DIO	3
2.1. Percepcija boje	4
2.1.1. Sustavi boja	5
2.1.1.1. RGB sustav boja	5
2.1.1.2. CIExyZ sustav boja	6
2.1.1.3. CIEL*a*b* sustav boja	7
2.1.2. Pretvorba boja iz jednog modela u drugi model boja	8
2.2. Boja piva	10
2.2.1. Tvari u pivu koje apsorbiraju svjetlost	11
2.2.1.1. Melanoidini	11
2.2.1.2. Polifenoli	11
2.2.1.3. Metali u tragovima	12
2.2.1.4. Ostali izvori	12
2.2.2. Mjerenje boje piva	12
2.2.2.1. Komparativna metoda	12
2.2.2.2. Spektrofotometrijska metoda	13
2.2.2.3. CIEL*a*b* metoda	14
Računalna analiza slike	14
2.3. Pjena piva	17
2.3.1. Formiranje pjene piva	17
2.3.1.1. Formiranje veličina mjehurića	18
2.3.1.2. Isušivanje	18
2.3.1.3. Kremastost	19
2.3.1.4. Koalescencija	19
2.3.1.5. Disproporcioniranje	19
2.3.1.6. Dušik ili ugljični dioksid	20
3. EKSPERIMENTALNI DIO	21
3.1. ZADATAK	22
3.2. MATERIJALI I METODE	22
3.2.1. Određivanje boje piva računalnom analizom slike	22
3.2.2. Određivanje stabilnosti pjene piva računalnom analizom slike	25
3.2.3. Modeliranje kinetike stabilnosti pjene piva	27
3.2.4. Statistička obrada rezultata	28
4. REZULTATI I RASPRAVA	29
4.1. Rezultati mjerenja boje različitih uzoraka piva računalnom analizom slike	30
4.2. Rezultati mjerenja stabilnosti pjene različitih uzoraka piva računalnom analizom slike	33
4.3. Rezultati mjerenja stabilnosti vlažnog dijela pjene različitih uzoraka piva računalnom analizom slike	36
4.4. Rezultati mjerenja stabilnosti suhog dijela pjene različitih uzoraka piva računalnom analizom slike	39
4.5. Rezultati mjerenja stabilnosti pjene različitih uzoraka piva	42
4.6. Rezultati mjerenja stabilnosti vlažnog dijela pjene različitih uzoraka piva	45
4.7. Rezultati mjerenja stabilnosti suhog dijela pjene različitih uzoraka piva	47
4.8. Usporedba stabilnosti pjene svijetlog i tamnog piva	50
4.9. Usporedba stabilnosti vlažnog dijela pjene svijetlog i tamnog piva	52
4.10. Usporedba stabilnosti suhog dijela pjene svijetlog i tamnog piva	54
5. ZAKLJUČCI	56
6. LITERATURA	58

Slika 1. Aditivni i suptraktivni sustavi boja [WEB1].....	5
Slika 2. RGB model boja [WEB2, WEB3].....	6
Slika 3. CIExyZ model boja [WEB4]	6
Slika 4. CIE Lab model boja [WEB5, WEB6]]	7
Slika 5. Izgled sučelja programa ImageJ.....	16
Slika 6. Formiranje mjehurića plina u pivu [WEB 7].....	18
Slika 7. Struktura mjehurića plina u pjenu [WEB 8]	18
Slika 8. Kremastost pjene različitih vrsta piva [WEB 9].....	19
Slika 9. Disproporcioniranje mjehurića pjene različitih vrsta piva tijekom vremena	20
Slika 10. Prikaz ravne čaše korištene u analizi piva.....	23
Slika 11. Oprema za slikanje a) digitalni fotoaparata b) Sučelje EOS Utility programa	23
Slika 12. Kalibracijska pločica SpyderCHECKR™	24
Slika 13. Određivanje visine stupca pjene piva računalnom analizom slike.....	25
Slika 14. Dinamika promjene visine stupca pjene piva (stabilnost pjene) mjerena računalnom analizom slike.....	26
Slika 15. Izmjerene vrijednosti svjetline L^* različitih uzoraka piva	30
Slika 16. Izmjerene vrijednosti kromatske komponente zeleno-crvene boje (a^*) različitih uzoraka piva	31
Slika 17. Izmjerene vrijednosti kromatske komponente plavo-žute boje (b^*) različitih uzoraka piva .	32
Slika 18. Izmjerene vrijednosti visine pjene različitih uzoraka piva.....	34
Slika 19. Usporedba vrijednosti konstante brzine gubitka pjene različitih uzoraka piva	34
Slika 20. Usporedba vrijednosti vremena polureakcije gubitka pjene različitih uzoraka piva	35
Slika 21. Izmjerene vrijednosti visine vlažnog dijela pjene različitih uzoraka piva	37
Slika 22. Usporedba vrijednosti konstante brzine gubitka vlažnog dijela pjene različitih uzoraka piva	37
Slika 23. Usporedba vrijednosti vremena polureakcije gubitka vlažnog dijela pjene različitih uzoraka piva	38
Slika 24. Izmjerene vrijednosti visine suhog dijela pjene različitih uzoraka piva.....	40
Slika 25. Usporedba vrijednosti konstante brzine gubitka suhog dijela pjene različitih uzoraka piva .	40
Slika 26. Usporedba vrijednosti vremena polureakcije gubitka suhog dijela pjene različitih uzoraka piva	41
Slika 27. Izmjerene vrijednosti visine pjene različitih uzoraka piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo.....	42
Slika 28. Usporedba vrijednosti konstante brzine gubitka pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo.....	43
Slika 29. Usporedba vrijednosti vremena polureakcije gubitka pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo	43
Slika 30. Izmjerene vrijednosti visine vlažnog dijela pjene različitih uzoraka piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo.....	45
Slika 31. Usporedba vrijednosti konstante brzine gubitka vlažnog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo.....	46
Slika 32. Usporedba vrijednosti vremena polureakcije gubitka vlažnog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo	46
Slika 33. Usporedba vrijednosti visine suhog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo	47

Slika 34. Usporedba vrijednosti konstante brzine gubitka suhog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo.....	48
Slika 35. Usporedba vrijednosti vremena polureakcije gubitka suhog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo	48
Slika 36. Usporedba vrijednosti visine pjene tamnog (T) i svijetlog (S) piva	50
Slika 37. Usporedba vrijednosti konstante brzine gubitka pjene tamnog (T) i svijetlog (S) piva.....	51
Slika 38. Usporedba vrijednosti vremena polureakcije gubitka pjene tamnog (T) i svijetlog (S) piva..	51
Slika 39. Usporedba vrijednosti visine vlažnog dijela pjene tamnog (T) i svijetlog (S) piva.....	52
Slika 40. Usporedba vrijednosti konstante brzine gubitka vlažnog dijela pjene tamnog (T) i svijetlog (S) piva	53
Slika 41. Usporedba vrijednosti vremena polureakcije gubitka vlažnog dijela pjene tamnog (T) i svijetlog (S) piva	53
Slika 42. Usporedba vrijednosti visine suhog dijela pjene tamnog (T) i svijetlog (S) piva	54
Slika 43. Usporedba vrijednosti konstante brzine gubitka suhog dijela pjene tamnog (T) i svijetlog (S) piva	55
Slika 44. Usporedba vrijednosti vremena polureakcije gubitka suhog dijela pjene tamnog (T) i svijetlog (S) piva	55

Popis tablica

Tablica 1. Raspon EBC vrijednosti za različite vrste piva.....	13
Tablica 2. Oznake uzoraka piva	22
Tablica 3. Postavke fotoaparata	24
Tablica 4. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost pjene	33
Tablica 5. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost vlažnog dijela pjene	36
Tablica 6. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost suhog dijela pjene.....	39
Tablica 7. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost pjene	42
Tablica 8. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost vlažnog dijela pjene	45
Tablica 9. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost suhog dijela pjene.....	47
Tablica 10. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost pjene	50
Tablica 11. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost vlažnog dijela pjene	52
Tablica 12. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost suhog dijela pjene.....	54

1. UVOD

Pivo se može opisati kao gazirano piće gorkog okusa i hmeljne arome s malim udjelom alkohola, koje nastaje procesom alkoholnog vrenja ohmeljene sladovine uz pomoć pivskog kvasca. Tipove piva moguće je razlikovati ovisno o vrsti glavnog vrenja, pa tako imamo piva gornjeg vrenja (deklariraju se kao *ale* ili *alt bier*), piva donjeg vrenja (deklariraju se kao *lager*) i samovrenja.

Aroma i okus piva razvijaju se u procesu proizvodnje i kuhanja sladovine te tijekom procesa glavnog i naknadnog vrenja. Nusproizvodi koji nastaju alkoholnim vrenjem (viši alkoholi, diacetil esteri, aldehidi i sumporni spojevi) odgovorni su za kakvoću piva u smislu doprinosa punoće okusa, no ako je njihova koncentracija prevelika tada djeluju negativno na okus, aromu i stabilnost pjene. Oksidacija sastojaka u pivu smatra se glavnim uzrokom nestabilnosti okusa i arome.

Niz čimbenika utječe na boju i stabilnost pjene piva, poput sirovine (tip slada i dodani surogati), procesa proizvodnje (kuhanje, hmeljenje), vrste ambalaže, uvjeta skladištenja i sl.

Boja piva izražava se u EBC¹ jedinicama te prema boji pivo može biti svijetle ili tamne boje. S obzirom na vrijednosti EBC jedinica, pivo se deklarira kao svijetlo pivo (intenzitet boje do 15 EBC jedinica), tamno pivo (intenzitet boje u rasponu 15-40 EBC jedinica), te crno pivo (ukoliko je intenzitet boje >40 EBC jedinica). Upotrebom različitih tipova sladova poput svijetlog, tamnog, karamelnog, ječmenog slada ili pšeničnog slada nastaju i različite vrste piva.

Osjetilom vida primamo više od 90 % informacija iz vanjskog svijeta, stoga se primarna privlačnost/odbojnost prema proizvodu temelji na njegovu vanjskom izgledu (boji, obliku, teksturi te veličini). Iskustveno smo si stvorili slike kako bi hrana trebala izgledati te na taj način donosimo sigurne prosudbe o njenoj kvaliteti.

Točenjem piva u čašu, potrošač će donijeti svoj sud o kvaliteti proizvoda na temelju onoga što on vidi, a to su bistroća, boja i pjena piva. Boja piva i stabilnost pjene važni su pokazatelji kvalitete i svježine piva, stoga je njihovo praćenje važno tijekom procesa proizvodnje, transporta i skladištenja. Cilj ovog rada je praćenje boje i stabilnosti pjene različitih vrsta svijetlog i tamnog piva nedestruktivnom metodom - računalnom analizom slike.

¹ EBC (*European Brewing Convention Unit*) – europska jedinica boje za pivo

2. TEORIJSKI DIO

2.1. Percepcija boje

Osjet boje predstavlja psihofizički doživljaj koji ovisi o izvoru svjetla, psihološkim i fiziološkim uvjetima promatrača i karakteristikama objekata koji se promatra. Često je boja svojstvo prehrambenih proizvoda koje se prvo uočava i direktno pretvara u pozitivan ili negativan predznak ukupne kvalitete proizvoda. Iako nije uvijek nužno povezana s nutritivnom vrijednošću, okusom ili funkcionalnim svojstvima hrane, boja hrane ima znatan utjecaj na vizualni doživljaj hrane i njenu prihvatljivost od strane potrošača.

Ono što ljudi i neke životinje percipiraju kao boju je u biti reflektirana svjetlost s površine nekog objekta, zbog čega je karakteriziranje svjetlosti izuzetno bitno za znanost o bojama i korištenje boje u računalnom vidu (Filko, 2013). 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 Meloni, 1994).

Pod pojmom pojavnost boje podrazumijevamo kako promatrač percipira to jest shvaća neku boju dok pojam specifikacije boje apsolutno određuje neku boju, što ne znači da dobro opisuje boju točno onako kako ju promatrač vidi. Boje se mogu definirati svojim uobičajenim imenima, ali i opisnim literarnim izvedenicama, no to ne govori ništa o njihovim vrijednostima. Stoga postoje tri osnovna atributa koje koristimo kada opisujemo svaku boju:

- ***h***° - **ton boje** ili tonalnost boje (engl. *hue*) označava vrstu boje te se definira kao kromatska kvaliteta boje, odnosno kvaliteta kojom se jedna boja razlikuje od druge. Ton može poprimiti vrijednosti 0° - 360° koji određuju položaj boje na kružnoj paleti boja. Crvena boja se nalazi na 0° (ili 360°), zelena na 120°, a plava na 240°.
- ***S*** - **zasićenost** ili saturacija (engl. *saturation*) je stupanj čistoće boje, koji se određuje udjelom akromatskih boja (crna, siva, bijela) u kromatskim bojama (crvena, narančasta, žuta, zelena). Zasićenost se izražava u postocima i poprima vrijednosti u postocima od 0 % do 100 %. Vrijednost 0 % će dati sivu boju, dok će vrijednost 100% predstavljati čistu boju.

- L^* - **svjetlina** ili luminancija (engl. *lightness*) se izražava u postocima 0% - 100%. Vrijednost 0% će dati crnu, a 100% bijelu boju.


2.1.1. Sustavi boja

Obzirom da su boje opisane s tri obilježja vizualnog osjeta, tonom, zasićenjem i svjetlinom, moguće ih je prikazati u trodimenzionalnom dijagramu. Kažemo da se boja specificira na način da se odrede koordinate u sustavu boja (npr. CIEXYZ, CIEL*a*b*, RGB) kojima je ona prikazana.

Modeli (sustavi) boje su trodimenzionalni prikazi boja uz pomoć kojih je moguće pobliže odrediti i vizualizirati sve vidljive boje i one koje se mogu koristiti u određenom reproduksijskom sustavu. Postoje brojni sustavi boja, a osnovna podjela je na (Slika 1):

- **aditivni** - sustavi boja ovisni o uređaju, kod kojih se boja dobiva zbrajanjem pojedinih komponenti (npr. RGB ili CMY); dodaju svjetlost na tamnu podlogu
- **suptraktivni** – sustavi boja kod kojih se boja dobiva oduzimanjem pojedinih komponenti i oni su neovisni o uređaju (to su CIE prostori boja kao npr. CIEXYZ, CIEL*a*b* ili CIEL*u*v*); pigmentima blokira bijelu svjetlost

Može se reći da je sustav (model) boja način pomoću kojeg se definiraju, stvaraju i vizualiziraju boje (Russ, 2007).



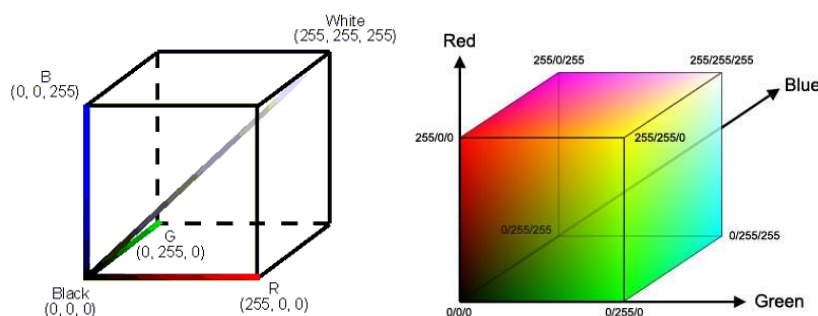
Slika 1. Aditivni i suptraktivni sustavi boja [WEB1]

2.1.1.1. RGB sustav boja

RGB sustav boja se prikazuje u obliku kocke (Slika 2), gdje x-os predstavlja crvenu boju, y-os zelenu, a z-os plavu boju. RGB sustav boja koristi tri primarne boje (crvenu, zelenu i plavu), a

njihovim miješanjem nastaju sekundarne boje. Ovaj sustav boja je aditivni, odnosno boje se dobivaju zbrajanjem komponenti. Ako sve tri komponente iznose 0, dobit ćemo crnu boju, a ukoliko sve tri komponente iznose 255, što je maksimum, tada ćemo dobiti bijelu boju.


Danas je najraširenija upotreba RGB sustava boja koji se temelji na 24 bitnom modelu koji ima raspon od 16,7 milijuna boja. Koriste se za prikaz boja u monitorima, digitalnim i video kamerama, skenerima, televizijskim uređajima. Postoji više RGB sustav boja koji se razlikuju po rasponu boja (gamut), bijeloj točki (izvor svjetla koji koristi prostor boja) te primarnim bojama. Najčešći su sRGB i Adobe RGB sustav boja (Puglia, 2000).



Slika 2. RGB model boja [WEB2, WEB3]

2.1.1.2. CIExyZ sustav boja


Jedan je od prvih matematički dešifriranih sustava boja, a nastao je iz razloga što bolje opisuje sustav boja koje prosječno ljudsko oko može vidjeti, u odnosu na RGB sustav boja, kojemu je svrha opisati boje koje se mogu reproducirati standardnim uređajima ili snimiti kamerom. U CIExyZ sustav boja x se smatra linearnom kombinacijom R , G i B boje, y se smatra svjetlinom, dok Z komponenta odgovara donekle plavoj boji (Slika 3).



Slika 3. CIExyZ model boja [WEB4]

2.1.1.3. CIEL*a*b* sustav boja

CIEL*a*b* sustav boja je trodimenzionalni sustav boja (Slika 4) temeljen na percepciji boje standardnog promatrača. Kratica L*a*b* označava tri komponente ovog sustava kojima je on opisan, a numeričke vrijednosti CIEL*a*b* sustava boja opisuju sve boje koje može razlikovati ljudsko oko.



Slika 4. CIELab model boja [WEB5, WEB6]]

U CIEL*a*b* sustavu boja, boja je opisana pomoću tri osi (dvije kromatske i jednom akromatskom):

- kromatska komponenta boje a^* koja se kreće u rasponu $-128 - +127$, te predstavlja odnos između crvene ($0 - +127$) i zelene ($-127 - 0$) boje;
- kromatska komponenta boje b^* koja se kreće u rasponu $-128 - +127$, te predstavlja odnos između plave ($-128 - 0$) i žute ($0 - +127$) boje;
- akromatska komponenta L^* koja predstavlja svjetlinu uzorka i mjeri po vertikalnoj osi CIEL*a*b* sustava. Svjetlina se kreće u rasponu $0 - 100$, pri čemu vrijednosti 0 predstavlja čistu crnu, a 100 čistu bijelu boju (Yam i Papadakis, 2004).

2.1.2. Pretvorba boja iz jednog modela u drugi model boja

Pretvorba iz RGB u CIE L*a*b*sustav boja u nekoliko koraka (Leon i sur., 2006; Mendoza, 2006; Larrain i sur., 2008).

Normalizacija sRGB vrijednosti pri čemu vrijedi $0 \leq R, G, B \leq 1$

$$R = \frac{sR}{255}, \quad G = \frac{sG}{255}, \quad B = \frac{sB}{255} \quad 2.1$$

$$R' = \left[\frac{R + 0,055}{1,055} \right]^{2/4} \begin{cases} \text{ako je } R > 0,04045 \\ \text{u protivnom } R' = \frac{R}{12,92} \end{cases} \quad 2.2$$

$$G' = \left[\frac{G + 0,055}{1,055} \right]^{2/4} \begin{cases} \text{ako je } G > 0,04045 \\ \text{u protivnom } G' = \frac{G}{12,92} \end{cases} \quad 2.3$$

$$B' = \left[\frac{B + 0,055}{1,055} \right]^{2/4} \begin{cases} \text{ako je } B > 0,04045 \\ \text{u protivnom } B' = \frac{B}{12,92} \end{cases} \quad 2.4$$

$$R_s = R' \cdot 100, \quad G_s = G' \cdot 100, \quad B_s = B' \cdot 100 \quad 2.5$$

Pri standardnim vrijednostima D65 i 10° vrijedi:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,4124 & 0,3576 & 0,1805 \\ 0,2126 & 0,7152 & 0,0722 \\ 0,0193 & 0,1192 & 0,9505 \end{bmatrix} \cdot \begin{bmatrix} R_s \\ G_s \\ B_s \end{bmatrix} \quad 2.6$$

Prema slijedećim formulama moguće je izračunati L^* , a^* i b^* koordinate iz standardnih CIEXYZ vrijednosti:

Tisimulusne vrijednosti bijelog standarda CIE1964., D65, 10°

$$X_{ref} = 95,811, \quad Y_{ref} = 100,00, \quad Z_{ref} = 107,304 \quad 2.7$$

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

$$X_s = 7,787 \cdot X' + \left(\frac{16}{116}\right) \begin{cases} \text{ako je } X' > 0,008856 \\ \text{u protivnom } X_s = (X')^{1/3} \end{cases} \quad 2.8$$

$$Y_s = 7,787 \cdot Y' + \left(\frac{16}{116}\right) \begin{cases} \text{ako je } Y' > 0,008856 \\ \text{u protivnom } Y_s = (Y')^{1/3} \end{cases} \quad 2.8$$

$$Z_s = 7,787 \cdot Z' + \left(\frac{16}{116}\right) \begin{cases} \text{ako je } Z' > 0,008856 \\ \text{u protivnom } Z_s = (Z')^{1/3} \end{cases} \quad 2.10$$

$$L^* = (116 \cdot Y_s) - 16 \quad 2.11$$

$$a^* = 500 \cdot \left[\frac{X}{X_s}\right]^{1/3} - \left(\frac{Y}{Y_s}\right)^{1/3} \quad 2.12$$

$$b^* = 200 \cdot \left[\frac{Y}{Y_s}\right]^{1/3} - \left(\frac{Z}{Z_s}\right)^{1/3} \quad 2.13$$

2.2. Boja piva

Pivo je pjenušavo, osvježavajuće piće koje nastaje tijekom fermentacije pivske hmeljne sladovine uz pomoć pivskog kvasca. Pivo može sadržavati različiti udjel alkohola, imati jače ili slabije karakterističan okus po sladu, gorčinu i specifičnu heljnu aromu te aromu estera. Nakon procesa proizvodnje piva, kao i tijekom procesa skladištenja, nužno je osigurati visoku razinu kvalitete proizvoda. Među bitnim parametrima kvalitete piva ističu se boja piva, gorčina te volumni udjel alkohola. U prehrambenoj industriji, potrošači procjenjuju kvalitetu proizvoda po vanjskom izgledu i boji, kao primarnim pokazateljima kvalitete. Boja i bistroća piva su važni kriteriji kvalitete. Očekuje se da su boja i bistroća konstantni nakon proizvodnje te tokom skladištenja i prodaje, kod vrsta kod kojih se očekuje da su bistre (Evans, 2009). Boja piva prenosi bitnu poruku potrošaču, pa tako tamnija boja piva sugerira jači okus i aromu, veći postotak alkohola i bogatiju punoću piva, dok je kod svjetlijih boja piva upravo obrnuto. Kada snop svjetlost pada na uzorak (npr. tekući medij kao što je pivo), dio svjetlosti se rasprši (zrake svjetlosti koje nakon prolaza kroz uzorak idu u drugom smjeru u odnosu na upadnu svjetlost), dio propusti ili transmitira (one zrake svjetlosti koje nakon prolaza kroz uzorak nastavljaju svoj put pod istim kutom kao i upadna svjetlost), a dio svjetlosti apsorbira uzorak kroz koji svjetlost prolazi. Količinu svjetlosti koju apsorbira uzorak moguće je izmjeriti i pomoću Lambert-Beer-ovim zakonom. Lambert-Beer-ov zakon dan je formulom:

$$A = \alpha \cdot l \cdot c \quad 2.14$$

$$\alpha = \frac{4 \cdot \pi \cdot k}{\lambda} \quad 2.15$$

gdje su:

A – apsorbancija pri određenoj valnoj duljini svjetlosti λ

l – duljina puta svjetlosti kroz uzorak [cm]

c – molarna koncentracija [L^{-1}]

α – molarni apsorpcijski koeficijent [$Lmol^{-1}cm^{-1}$]

k – ekstincija

2.2.1. Tvari u pivu koje apsorbiraju svjetlost

Boja piva nastaje primarno od sirovog materijala koji se koristi pri proizvodnji piva. Koncentracija komponenata koje utječu na boju može se povećati tokom proizvodnje slada, smanjiti tokom fermentacije te na kraju se može prilagoditi krajnjim specifikacijama proizvoda dodavanjem karamele ili obojenog ekstrakta slada. Neki od načina bojenja piva su i karamelizacija te Maillardove reakcije. Karamelizacija se odvija kada su visoke koncentracije šećera te povišena temperatura. Karamelizacija je reakcija raspada molekula šećera pri temperaturama višim od 120°C, također reakcija ovisi o pH i vrsti šećera (Buera i sur., 1987). Piroliza je reakcija koja se odvija kada je temperatura viša od 200°C pri čemu nastaju intenzivni crni pigmenti (Shellhammer, 2008).

2.2.1.1. Melanoidini

Maillardove reakcije, koje se nazivaju još i neenzimsko posmeđivanje, nastaju reakcijom između šećera i određenih aminokiselina ili proteina nizom kompleksnih reakcija pod utjecajem povišene temperature (Hodge, 1953). Dolazi do formiranja obojenih i aromatičnih komponenata. Melanoidini su polimeri i obojeni, te konačan produkt Maillardovih reakcija, koji nastaju procesiranjem hrane, uključujući i pivo. Topivi su u vodi, a na početku nastajanja su obojeni žuto, narančasto i crveno, a daljnjim odvijanjem Maillardovih reakcija postaju smeđi (Nursten, 2005).

2.2.1.2. Polifenoli

Peroksidaze mogu utjecati na fenolne spojeve i stvaranje boje. Količina polifenola koja se može naći u sladu je proporcionalna pH slada i temperaturi. Daljnja ekstrakcija polifenola se može odviti tijekom vrenja slada.

Oksidirani polifenoli su također značajan izvor boje u pivu, imaju crveno-smeđi pigment. Njihovo nastajanje može biti uzrokovano neenzimskim reakcijama ili katalizirano enzimima. Kisik je neophodan. Promjene boje uzrokovane oksidacijom polifenola su najuočljivije kod svijetlih lager piva tijekom skladištenja. U ambalažu se stavljaju adsorbensi polifenola koji sprječavaju tamnjenje smanjivanjem razine polifenolnih prekursora (Shellhammer, 2008).

2.2.1.3. Metali u tragovima

Boja piva može biti uzrokovana prisustvom metala u tragovima kao što su bakar i željezo. Ovi metali mogu stimulirati oksidativne reakcije, kao npr. s polifenolima. Metali se mogu koristiti pri modificiranju boje (npr. kationi aluminija), kao katalizatori karamelizacije, uglavnom se koriste pri prilagodbi boje i okusa, a sada i češće kod tamnih prženih sladova (Boulton i sur., 2001).

2.2.1.4. Ostali izvori

Riboflavin – pri niskim koncentracijama u pivu može značajno doprinijeti boji svijetlih lager piva (Pozdrik i sur., 2006; Briggs i sur., 2004). Pri proizvodnji *ale* i *stout* piva, za bojenje se koristi karamela, koja ima intenzivno crveno-smeđu boju. Korištenjem karamela olakšava proizvođačima održavanje konstantne boje njihovih proizvoda bez mijenjanja okusa.

2.2.2. Mjerenje boje piva

2.2.2.1. Komparativna metoda

Kod ove metode boja piva je jednostavno uspoređena sa setom standardnih boja bez posebnih uređaja. Predložak sa standardiziranim bojama se izrađuje od otopina kalijevog kromata, koje imaju karakterističnu boju koja podsjeća na boju komercijalnih piva (Shellhammer, 2008). Obojene staklene diskove je proizveo Lovibond 1893. Koji su nakon nekoliko modifikacija prihvaćeni 1951. Na Europskoj konvenciji pivara, a jedinice su definirane kao EBC (Hughes i sur., 2001). Problem kod navedene metode mogu biti greške ljudske prirode, jer ljudi očitavaju vrijednosti boje te može doći do različitih rezultata istog uzorka među laboratorijima. Također do greške može doći zbog promjene boje na disku uzrokovane dužim stajanjem, različitim izvorima svjetlosti te razrjeđenjem jako obojenih piva.

2.2.2.2. Spektrofotometrijska metoda

ASBC² je 1950. implementiralo spektrofotometrijsku metodu mjerenja boje piva. Ovom metodom mjeri se apsorbancija (A_{430}) svijetlih piva i slada prema EBC skali. Prema odboru za analize Europske pivarske konvencije boja piva i slada se mjeri pri valnoj duljini od 430 nm (de Lange, 2008). Ovom metodom očitana apsorbancija je množena s faktorom 12,7 za SRM ili 25 za određivanje boje u EBC jedinicama, pri čemu D predstavlja razrjeđenje uzorka:

$$A_{430} \cdot D \cdot 12,7 = \text{SRM} \quad 2.16$$

$$A_{430} \cdot D \cdot 25 = \text{EBC} \quad 2.17$$

Uzorci bi trebali biti čisti bez stranih čestica, kako ne bi došlo do raspršivanja svjetla. Neke pivarske industrije koriste ovu metodu kao konvencionalnu standardnu za određivanje boje piva, jer je brza i jednostavna. Za tamne vrste piva ova metoda nije zadovoljavajuća, jer postoji mogućnost da dva različita uzorka piva s identičnim EBC vrijednostima imaju različitu vrijednost apsorbancije. U Tablici 1 prikazan je raspon EBC vrijednosti za određene vrste piva.

Tablica 1. Raspon EBC vrijednosti za različite vrste piva

Vrsta piva	EBC vrijednosti boje	Opis boje
American/Light Lager	3 – 8	Vrlo svijetla do blijeda
Bavarian Helles	6 – 10	Blijeda do boje slame
American/European Malt Pilsner	6 – 18	Zlatna
English Pale Ale	10 – 28	Boja slame prema bakrenoj
Red Beers	18 – 108	Smeđa/jantarna/crvenkasta
Porter	40 – 60	Tamno smeđa
Irish Stout	> 80	Crna

² ASBC -Američko društvo kemičara pivara (engl. *The American Society of Brewing Chemists*)

2.2.2.3. CIEL*a*b* metoda

U mnogim industrijama se tristimulusno mjerenje koristi za kontrolu kvalitete boje. Ove metode temelje se na mjerenju količine reflektirane svjetlosti vidljivog dijela svjetla s površine analiziranog uzorka. Reflektirana količina svjetlosti mjeri se uređajima kao što su kolorimetar, denziometar, računalna analiza slike, a dobiveni rezultati prikazani su kao vrijednosti boje u CIEL*a*b*, RGB ili nekom drugom prostoru boja.

Računalna analiza slike

Računalna analiza slike (DIA³) predstavlja postupak pronalaženja značajnih informacija iz fotografija tehnikama računalne obrade. DIA ima primjenu u brojnim područjima tehnike i znanosti poput medicine, biologije, astronomije, elektronike, prehrambene tehnologije i dr.

Pomoću DIA-e boja uzoraka određuje beskontaktno, mjerenjem količine reflektirane svjetlosti s površine analiziranog uzorka. Sustav za analizu slike boju registrira pomoću tri senzora boje (R, G i B), a osnovni elementi koji čine sustav za analizu slike su rasvjeta, uređaj za akviziciju fotografija (digitalni fotoaparati, kamera, skener i sl.) te računalna i programska podrška (uključuje računalo te programe za obradu i analizu slike).

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

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

³ DIA – računalna analiza slike (engl. *Digital Image Analysis*)

određuje se i boja tog piksela i ovaj princip nazivamo Bayerovom interpolacijom (Strgar Kurečić, 2015).

Piksel (eng. *Picture Element*) predstavlja najmanji sastavni element digitalne slike. Sadrži brojevu vrijednost, ili više njih, koja je osnovna informacija slike za određenu koordinatu. Dva su faktora koja u kombinaciji određuju kvalitetu slike: veličina senzora i veličina piksela. Da bi se slika zapisala potrebno je odrediti svjetlinu pojedinih elemenata kako bi im se pripisale pripadajuće vrijednosti. U prvom koraku potrebno je pronaći najsvjetliji element kojem se pripisuje vrijednost 256 (najveća vrijednosti) te najtamniji element kojem se pripisuje vrijednosti 0 (najmanja vrijednost). Ostalim elementima pripisuje se vrijednost proporcionalna drugom korijenu svjetline kako bi se veći dio raspona vrijednosti rasporedio na tamne tonove, obzirom da ljudsko oko bolje uočava razlike u tamnim tonovima, u odnosu na svijete tonove.


Koraci u procesu računalne obrade i analize slike

- ✓ PRIHVAT i DIGITALIZACIJA – digitalna slika je proizvedena od jednog ili više senzora. Ovisno o tipu senzora, slikovni podatak je obični 2D prikaz, 3D volumen, ili slijed slika u različitim formatima (JPEG; TIFF...)
- ✓ PRETPROCESIRANJE – podrazumijeva ispravljanje eventualnih grešaka nastalih prilikom snimanja digitalne slike te evaluacija kvalitete slike, pretprocesiranje je priprema za segmentaciju slike.
- ✓ SEGMENTACIJA - pri analizi objekata na slici neophodno je razgraničiti „objekte od interesa“ od ostatka slike. Segmentacija objekata, pojedinačnih površina ili dijelova objekata vrši se klasifikacijom svakog piksela, odnosno računalo provjerava pripada li ili ne pojedini piksel grupi odnosno objektu.
- ✓ POSTPROCESIRANJE - u osnovi vezano je na dvije metode kojima se poboljšavaju rezultati dobiveni segmentacijom. Prva metoda bazirana je na morfološkim operacijama kojima je cilj popraviti rezultat segmentacije, a druga na mjerenju segmentiranih objekata čime se razdvajaju objekti spojeni segmentacijom. Operacije mjerenja dolaze nakon što slika prođe kroz proces pretprocesiranja, segmentacije i postprocesiranja.

- ✓ IZDVAJANJE ZNAČAJKI - značajke slike na različitim razinama složenosti su izlučene iz slikovnih podataka. Tipični primjeri takvih značajki: linije i rubovi, lokalizirane točke kao što su kutovi, mrlje ili točke, složenija obilježja mogu biti povezana s teksturom, oblicima ili pokretima.

Program za obradu i analizu slike *ImageJ*

ImageJ je program otvorenog koda temeljen na Javi koji se primjenjuje za vizualizaciju, obradu, procesiranje i analizu digitalnih slika. *ImageJ* je dizajniran s otvorenom arhitekturom koja omogućuje proširenje putem plugina u Javi i makronaredbi. Izgled sučelja programa prikazan je na Slici 5.



Slika 5. Izgled sučelja programa *ImageJ*

Program može prikazivati, uređivati, analizirati, obrađivati, spremati i ispisivati 8-bitne, 16-bitne 32-bitne slike. *ImageJ* podržava različite formate slikovnog uključujući TIFF, PNG, JPEG, GIFF, DICOM; BMP, PMG i FITS, kao i sirove (*raw*) formate slikovnih zapisa. *ImageJ* podržava nizove slika, seriju slika koje dijele jedan prozor i to tako da se dugotrajne operacije mogu izvoditi paralelno na hardwareu s više procesora. Pomoću *ImageJ*-a moguće je izračunati analiziranu površinu i prikazati statistiku piksela analiziranog područja slike; omogućuje mjerenje kutova i udaljenosti na fotografijama; histograme gustoće. Podržava standardne funkcije obrade slike kao što su logičke i aritmetičke operacije između slika, manipulacija kontrastom, Fourierovu analizu, izoštravanje, izgladivanje, detekciju rubova i filtriranje medijana. Radi geometrijske transformacije kao što su skaliranje, rotacija i okretanje.

2.3. Pjena piva

Prezentacija piva u čaši je bitna osobi koja konzumira pivo, zbog samog izgleda pjene, boje i bistroće piva. Iz tog razloga se kaže da osoba koja pije pivo „pije“ ga očima, jednako koliko i ustima. Pjena je bitna iz razloga što je ona medij u kom su zarobljeni mjehurići plina, koji sadrže aromu piva, te je pjena prvi stupanj procjene kvalitete, okusa i punoće piva.

Danas se većinom pivo konzumira direktno iz boce, iz tog razloga se pridaje dosta značaja pri dizajnu same boce i ambalaže. S obzirom da su te boce najčešće obojene (zeleno, smeđe), potrošač ne vidi samu boju piva, a isto tako ne može vidjeti formiranje pjene koje se odvija unutar boce. U zadnje vrijeme pivo se uspoređuje s vinom, a kako znamo da se vino ne pije iz boce, to se pokušava postići i s pivom, promijeniti kultura načina konzumiranja piva.

Karakteristike pjene dobre kvalitete su kombinacija njezine stabilnosti, količine, vezanja pjene na staklenu površinu, bjeline, kremastosti i snage. Kako je ljepota u oku promatrača, tako i potrošači različitih rasa, spola ili iz različitih regija, ne gledaju isto na pjenu. Jednima će pivo s pjenom biti odlično, dok će drugi smatrati da čaša nije puna, jer sadrži pjenu. Neki potrošači preferiraju malo pjene i „čistu“ čašu nakon ispijanja piva, dok drugi preferiraju tragove pjene na čaši nakon ispijanja, tzv. „lacing pattern“. Muškarci preferiraju uzorak pjene na čaši dok žene ne.

2.3.1. Formiranje pjene piva

Kako bismo bolje razumjeli nastajanje pjene moramo biti upoznati sa fizikom nastanka pjene piva te interakcijama koje nastaju između različitih komponenti. Kompleksne fizikalne reakcije koje se odvijaju prilikom nastanka pjene su pojednostavljene i postavljene u ovih 5 koraka:

- Formiranje mjehurića i veličina,
- Isušivanje (drenaža),
- Kremastost,
- Koalescencija i
- Disproporcioniranje.

2.3.1.1. Formiranje veličina mjehurića


Unatoč prezasićenosti piva ugljikovim dioksidom, mjehurići se neće početi spontano proizvoditi ukoliko nema nukleacije, koja može biti potaknuta sitnim česticama, vlaknima ili ogrebotinama na čaši ili točenjem piva na točioniku ili iz boce. Pri stvaranju mjehurića poželjno je da mjesta nukleacije budu što manja kako bi se stvarali što sitniji mjehurići kako bi pjena bila kvalitetnija i privlačnija (Lubetkin i sur., 1988). Prednost korištenja dušika pred ugljikovim dioksidom, je ta što dolazi do proizvodnje znatno manjih mjehurića (Slika 6).



Slika 6. Formiranje mjehurića plina u pivu [WEB 7]

2.3.1.2. Isušivanje

Pri nastajanju pjena je vlažna, jer se među mjehurićima nalazi suvišak piva, koji se djelovanjem sile teže spušta dolje, što dovodi do nastanka suhe pjene (Hepworth i sur., 2001). Daljnjim isušivanjem pjene dolazi do oslabljivanja membrane mjehurića što dovodi do pucanja. Stoga možemo zaključiti da je viskoznost piva ključan čimbenik u održivosti pjene. Pjena je također stabilnija na nižim temperaturama. Vlažna pjena sadrži pravilne mjehuriće plina, dok se pri sušenju pjene otjecanjem piva formira oblik pčelinjih saća, odnosno šesterokutnika (Slika 7).



Slika 7. Struktura mjehurića plina u pjeni [WEB 8]

2.3.1.3. Kremastost

Kremastost pjene ili „beading“ što bi prevedeno značilo nizanje perli, a u ovome slučaju „nizanje“ mjehurića koji nastaju u pivu i formiraju pjenu. Značajni čimbenici ključni za formiranje kremaste pjene su nastajanje mjehurića, površinska napetost, gustoća piva i količina CO₂ (Evans i sur., 2009). Najznačajniji čimbenik je količina samog plina (Slika 8).




Slika 8. Kremastost pjene različitih vrsta piva [WEB 9]

2.3.1.4. Koalescencija

Koalescencija ili srastanje mjehurića se odvija kada dolazi do pucanja opne mjehurića i stvaranja većeg mjehurića koji je manje stabilan (Bamforth, 2004).

2.3.1.5. Disproporcioniranje

Disproporcioniranje ili spajanje mjehurića nastaje srastanjem dva mjehurića, manjeg i većeg (Slika 9), pri čemu dolazi do nastajanja velikih mjehura koji su nestabilni i manje privlačni (Slika xx). Ovdje možemo vidjeti još jednu prednost u primjeni dušika, jer je dušik manje topiv u vodi od ugljičnog dioksida, i manja je vjerojatnost difuzije plinova u veći mjehurić. Dva bitna čimbenika su primjena pravilne kombinacije plina i debljina filma koji oblaže mjehuriće u pjenu, odnosno brzina isušivanja same pjene stabilan (Bamforth, 1985).



Slika 9. Disproporcioniranje mjehurića pjene različitih vrsta piva tijekom vremena

2.3.1.6. Dušik ili ugljični dioksid

Većina piva su prirodno gazirana ili nekim uobičajenim postupkom, a dodatkom dušika postiže se veća stabilnost pjene. Dušik ima niži parcijalni tlak od ugljičnog dioksida i proizvodi manje mjehuriće koji su stabilniji i iz razloga što je dušik manje topiv u vodi od ugljičnog dioksida. Kombinacija plinova u omjeru 25% dušika i 75% ugljičnog dioksida se koristi u točionicima zbog bolje i stabilnije pjene. Pjena nastala dušikom je kremastija

3. EKSPERIMENTALNI DIO

3.1. ZADATAK

Zadatak ovog diplomskog rada temelji se na određivanju parametara boje i stabilnosti pjene različitih vrsta lager piva nedestruktivnom vizualnom metodom - računalnom analizom slike.

3.2. MATERIJALI I METODE

U diplomskom radu provedeno je mjerenje boje i stabilnosti pjene svijetlog i tamnog piva (ukupno 12 različitih vrsta piva), pakiranih u staklenoj ambalaži volumena 500 ml. S obzirom na deklaraciju, uzorci su razvrstani u četiri potkategorije (C, T, P i S), te su za svaku potkategoriju piva ispitani uzorci po tri najzastupljenija proizvođača dostupnih na lokalnom tržištu. Pregled i oznake uzoraka korištenih za analizu dan je u Tablici 2.

Tablica 2. Oznake uzoraka piva

Vrsta piva	Oznake uzoraka	Deklarirani naziv	
Tamno	C1	Crno lager nefiltrirano	
	C	C2	Crno trosladno
	C3	Crno lager	
	T	T1	Tamno lager
	T2	Tamno	
	T3	Vrhunsko tamno	
Svijetlo	P1	Premium pils	
	P	P2	Pils
	P3	Premium pils	
	S	S1	Premium svijetlo lager
	S2	Svijetlo lager	
	S3	Premium svijetlo lager	

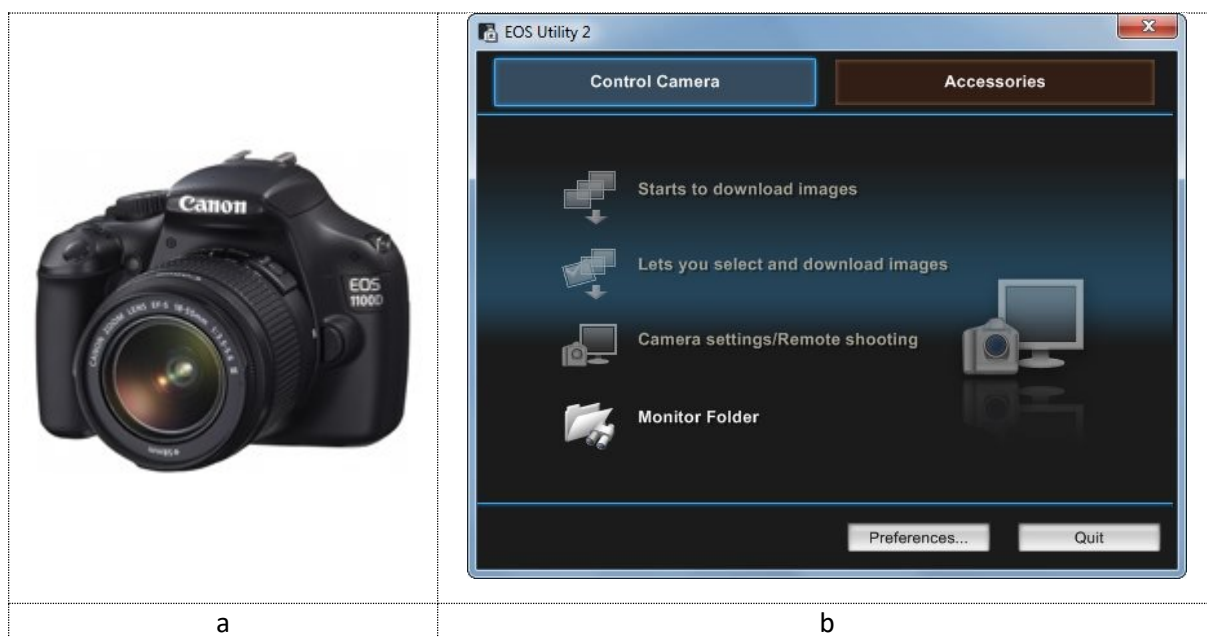
3.2.1. Određivanje boje piva računalnom analizom slike

Mjerenje boje provedeno je primjenom računalne analize slike fotografiranih uzoraka piva. Prije analize uzorci piva ostavljeni su 1h na sobnoj temperaturi, te su neposredno prije fotografiranja degazirani. Temperatura piva tijekom analize iznosila $23 \pm 0,5$ °C.



Slika 10. Prikaz ravne čaše korištene u analizi piva

U ravnu staklenu čašu (njem. *stange*) uliven je volumen piva od 100 ml, čaša je smještena u komoru za slikanje i potom fotografirana pomoću digitalnog fotoaparata (Canon EOS-1100D) u TIFF formatu i sRGB modelu boja. Izgled čaše korištene u analizi prikazana je na Slici 10.



Slika 11. Oprema za slikanje a) digitalni fotoaparata b) Sučelje EOS Utility programa

Komora za slikanje je osvijetljena sa četiri LED lampe sa difuzerom smještene s vanjske strane, a uzorci fotografirani na udaljenosti od 50 cm od objektiva fotoaparata. Prije fotografiranja fotoaparata je kalibriran pomoću Datacolor SpyderCHECKR™ kalibracijske pločice. Radom fotoaparata upravljano je putem EOS Utility programa (Slika 11-12). Detaljne postavke fotoaparata dane su u Tablici 3.



Slika 12. Kalibracijska pločica SpyderCHECKR™

Tablica 3. Postavke fotoaparata

Karakteristika fotoaparata	Vrijednost
Fotoapararat	Canon Power Shot EOS-1100D - digitalni, zrcalno-refleksni AF/AE fotoapararat s ugrađenom bljeskalicom
Senzor slike	CMOS (22,2 x 14,8mm), rezolucija 10,10MP
Objektiv	Canon EF-S18 – 55mm
Način rada	Ručno upravljanje
ISO brzina	ISO-1600
Otvor blende (F-stop)	f/20
Vrijeme ekspozicije	1/40 s
Žarišna duljina	36 mm
Način rada bljeskalice	Bez bljeska
Vodoravna i okomita razlučivost	72 dpi
Dubina boja	24 bit
Model boja	sRGB
Ravnoteža bjeline	<i>Custom white balans</i> – kalibracijska pločica SpydeCHECKR
Format slike	TIFF
Programska podrška	EOS Utility 2.3.0.2. (Canon Inc., USA), remote capture software


Nakon fotografiranja, boja uzoraka određene je računalnom analizom slike. Fotografije su obrađene primjenom računalnog programa *ImageJ* (ver.1.52a, Wayne Rasband, National Institute of Health, Maryland, USA). Dobiveni rezultati mjerenja boje dobiveni nakon analize i obrade slike te izraženi kao vrijednosti crvene (R), zelene (G) i plave (B) boje u RGB sustavu

boja. Dobivene vrijednosti boje pretvorene su iz RGB u CIE L*a*b* model boja, a detaljan opis postupka pretvorbe boje iz jednog u drugi model boja dan je u poglavlju 2.1.2. Mjerenje boje piva je provedeno u četiri ponavljanja, a rezultati izraženi kao srednja vrijednost.

3.2.2. Određivanje stabilnosti pjene piva računalnom analizom slike

Mjerenje stabilnosti pjene različitih uzoraka piva provedeno je primjenom računalne analize slike. Neposredno prije fotografiranja volumen od 100 ml piva uliven je direktno u staklenu čašu s točno definirane visine, promjene visine stupca pjene fotografirane su pomoću digitalnog fotoaparata svakih 5 s tijekom 10 min (600 s). Postavke fotoaparata dane su u **Tablici 3**. Nakon fotografiranja, na svim fotografijama provedena je računalna analiza slike pomoću računalnog programa *ImageJ*.

Nakon provedene računalne analize slike kao rezultat su određeni parametri promjene visine stupca pjene i izraženi kao promjena visine stupca pjene tijekom vremena. Mjerenje je provedeno u četiri ponavljanja, a rezultati izraženi kao srednja vrijednost. Prikaz koraka računalne analize slike i određivanje promjene visine stupca pjene primjenom računalnog programa *ImageJ* prikazan je na **Slici 13-14**.



Slika 13. Određivanje visine stupca pjene piva računalnom analizom slike

Izračunavanje promjene visine stupca pjene tijekom vremena

$$H_t(SDP) = H_t(P) + H_t(T) - H_{max}(T) \quad 3.1$$

$$H_t(VDP) = H_t(P) - H_t(SDP) \quad 3.2$$

gdje su:


$H_t(SDP)$ - visina suhog dijela pjene u trenutku t ,

$H_t(VDP)$ - visina vlažnog dijela pjene u trenutku t ,

$H_t(P)$ - visina pjene u trenutku t ,

$H_t(T)$ - visina tekućine u trenutku t ,

$H_{max}(T)$ - maksimalna visina tekućine, u trenutku $t = 600s$.



Slika 14. Dinamika promjene visine stupca pjene piva (stabilnost pjene) mjerena računalnom analizom slike

3.2.3. Modeliranje kinetike stabilnosti pjene piva

Određivanje vrijednosti parametara **modela eksponencijalnog gubitka pjene** provedena je u svrhu predviđanja stabilnosti pjene različitih vrsta piva.

Model eksponencijalnog gubitka pjene dan je jednadžbom:

$$H_t = H_0 \times e^{-kt} \quad 3.3$$

$$t_{1/2} = \frac{\ln(2)}{k} \quad 3.4$$

gdje su:

H_0 - početna vrijednost visine pjene,

H_t – visina pjene u trenutku t ,

k - konstanta brzine (s^{-1}),

t - vrijeme (s),

$t_{1/2}$ - vrijeme polureakcije.

Za obradu eksperimentalnih podataka korišten je dodatak XLSTAT u MS Excel programu, te su parametri modela izračunati regresijskom analizom. Uspješnost aproksimacije eksperimentalni podataka promjene boje matematičkim modelima procijenjena je na osnovi više statističkih kriterija:

- koeficijenta determinacije, R^2

- srednje kvadratnog odstupanje, $RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (H_{t_{pre,i}} - H_{t_{eks,i}})^2}$

Aproksimacija eksperimentalnih podataka modelom je bolja što su vrijednosti srednjeg kvadratnog odstupanja niže ($RMSE \rightarrow 0$), a koeficijenta determinacije više ($R^2 \rightarrow 1$).

3.2.4. Statistička obrada rezultata


Rezultati mjerenja boje prikazani su kao komponente L^* , a^* i b^* CIEL*a*b* prostora boja, dok su parametri stabilnosti pjene prikazani kao promjena visine pjene (suhog dijela pjene i vlažnog dijela pjene) tijekom vremena.

Dobiveni rezultati su prikazani kao srednja vrijednost \pm standardna devijacija. Analiza varijance (ANOVA) i Fisher-ov LSD test najmanje značajne razlike (engl. *Least significant difference*) provedeni su pomoću računalnog programa Statistica 12 (Stat Soft Inc. Tulsa, SAD) te dodatka XLSTAT unutar MS Excel programa (Addinsoft, NewYork, SAD).

4. REZULTATI I RASPRAVA

4.1. Rezultati mjerenja boje različitih uzoraka piva računalnom analizom slike

Slikama 15-17 prikazani su rezultati mjerenja boje 12 različitih uzoraka piva deklariranih kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo. Boja uzoraka prikazana je komponentama CIEL*a*b* prostora boja, kao L^* vrijednosti, a^* vrijednosti i b^* vrijednosti. Vrijednosti akromatske komponente CIEL*a*b* sustava L^* označava svjetlinu uzoraka te vrijednosti svjetline bliže 0 označavaju tamniju boju, dok vrijednosti svjetline bliže 100 ukazuju na svjetliju boju uzorka. Kromatska komponenta CIEL*a*b* sustava a^* označava prisutnost zeleno-crvene boje. Uzorak se nalazi u domeni zelene boje, ako su izmjerene vrijednosti komponente a^* negativne, odnosno crvene boje ako su vrijednosti komponente a^* pozitivne. Kromatska komponenta b^* ukazuje na prisutnost plavo-žute boje. Uzorak se nalazi u domeni plave boje, ako su izmjerene vrijednosti komponente b^* negativne, odnosno žute boje ako su vrijednosti komponente b^* pozitivne. Tijekom proizvodnje piva, u fazi ukomljavanja i kuhanja sladovine s hmeljom, nastaju obojeni karamelni spojevi, koji utječu na intenzitet boje. Promjene boje piva tijekom skladištenja uglavnom su posljedica enzimskih i ne enzimskih oksidacija polifenola i/ili nastajanja melanoidinskih spojeva (Šavel, 2010).




Slika 15. Izmjerene vrijednosti svjetline L^* različitih uzoraka piva

S obzirom na rezultate svjetline (L^*) analiziranih uzoraka piva (Slika 15) postoji statistički značajna razlika među uzorcima tamnog (deklariranih kao crno pivo C, odnosno tamno pivo T)

i svijetlog piva (deklariranih kao pils P, odnosno svijetlo lager S pivo). Vrijednosti svjetline uzoraka tamnog piva (deklariranih kao crno C i tamno T) bile su manje ($L^* = 25,5 - 31,1$) u odnosu na uzorke svijetlog piva ($L^* = 60,1 - 69,9$ deklariranih kao pils P i svijetlo lager S). Manje vrijednosti svjetline (bliže 0) ukazuju na tamniju boju uzoraka, dok veće vrijednosti (bliže 100) ukazuju na svjetliju boju uzoraka.


Na slikama 15-17 prikazane su izmjerene vrijednosti kromatskih komponenti CIEL*a*b* sustava boja, a^* i b^* . Vrijednosti komponente a^* za sve analizirane uzorke piva bile su pozitivne te su kod uzoraka piva deklariranih kao crno pivo C1-C3 bile u rasponu 7,5-10,0, a kod uzoraka piva deklariranih kao tamno pivo T1- T3 u rasponu 7,4 - 16,1. Za uzorke svijetlog piva vrijednosti komponente a^* kretale su se u rasponu 3,1 - 6,6 za uzorke piva deklariranih kao pils P1-P3; odnosno 4,2 - 15,5 za uzorke piva deklarirane kao svijetlo lager S1-S3. Vrijednosti komponente b^* bile su pozitivne za sve analizirane uzorke piva, te su veće vrijednosti izmjerene kod uzoraka svijetlog piva (52,2 - 59,1) deklariranih kao pils i svijetlo lager, u odnosu na uzorke piva deklarirane kao crno i tamno pivo (2,3 - 8,7).



Slika 16. Izmjerene vrijednosti kromatske komponente zeleno-crvne boje (a^*) različitih uzoraka piva

Boja nastaje kao rezultat kemijskih reakcija poput Maillardovih reakcija, karamelizacije te pirolize. Maillardove reakcije su reakcije između reducirajućih šećera (uglavnom maltoze) te slobodnih aminokisline ili amino skupina aminokiselina koje sadrže protein. Reakcijom karamelizacije razvijaju se kemijski produkti, uglavnom crvene i/ili smeđe boje, dok

Maillardovim reakcijama nastaju nusprodukti (melanoidini, furani, furanozini, piroli, pirazini), koji pivu daju tamniju boju. Na početku Maillardovih reakcija melanoidini imaju žutu, narančastu ili crvenu boju, koje postepeno prelaze u smeđu kako reakcije napreduju (Nursten, 2005). Pri temperaturama iznad 200 °C odvijaju se reakcije pirolize kojima dolazi do izgaranja šećera te nastanka pigmenata intenzivno crne boje. Može se zaključiti da će povećana koncentracija ovih spojeva u pivu doprinostiti tamnijoj boji piva (manje vrijednosti svjetline, veće vrijednosti kromatske komponente a^* i manje vrijednosti kromatske komponente b^*), dok će u slučaju manje količine ovih spojeva boja piva biti svjetlija (veće vrijednosti svjetline i kromatske komponente b^* te manje vrijednosti kromatske komponente a^*) (Spearot, 2016).



Slika 17. Izmjerene vrijednosti kromatske komponente plavo-žute boje (b^*) različitih uzoraka piva

Sekundarni put nastajanja boje piva je procesom oksidacije polifenola koja se događa tijekom procesa skladištenja i/ili starenja piva, te je vrlo uočljiva kod svijetlih piva. Kod tamnijih piva tamnjenje uslijed oksidacije polifenola je maskirano bojama obojenog i prženog slada. Polifenoli, tj. polifenolne komponente u pivo se oslobađaju iz ječma prilikom procesa kuhanja slada. Nadalje, oksidacijom polifenola može doći do pojačane interakcije protein-polifenol i stvaranja zamućenja (*haze*) ne-biološkog podrijetla. Promjena boje piva uslijed oksidacije polifenola najuočljivija je u svijetlim pivima tijekom skladištenja i /ili starenja piva (Shellhammer, 2008).

4.2. Rezultati mjerenja stabilnosti pjene različitih uzoraka piva računalnom analizom slike

Stabilnost pjene različitih vrsta piva analizirana je računalnom analizom slike te izražena kao promjena visine stupca pjene H_0 tijekom vremena t . Rezultati mjerenja stabilnosti pjene prikazani su tablično (**Tablica 4**) i grafički (**Slika 18-20**).


Nakon provedenog matematičkog modeliranja stabilnosti pjene piva dobiveni su parametri modela eksponencijalnog gubitka pjene: konstanta brzine reakcije k i vrijeme polureakcije $t_{1/2}$. Ukoliko su vrijednosti konstante brzine k manje, te vrijeme polureakcije $t_{1/2}$ veće, tada je pjena analiziranih uzoraka stabilnija. Uspješnost aproksimacije eksperimentalnih podataka odabranim matematičkim modelom, analizirana je na osnovi više statističkih kriterija. U ovom radu prikazani su koeficijent determinacije (R^2), koji bi idealnom slučaju imao vrijednost 1, te srednje kvadratno odstupanje ($RMSE$) kod kojeg manje vrijednosti označavaju uspješniju aproksimaciju podataka primijenjenim modelom.

Tablica 4. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost pjene


Oznaka uzorka	H_0 (mm)	k (s^{-1})	$t_{1/2}$ (s)	R^2	$RMSE$
C1	77,6±7,1 ^a	0,0076±0,0002 ^g	90,9±1,9 ^a	0,9973	1,0183
C2	71,3±6,3 ^{ab}	0,0087±0,0000 ^{efg}	80,1±0,2 ^{bc}	0,9965	1,0715
C3	58,8±1,5 ^{cd}	0,0158±0,0006 ^b	43,9±1,8 ^f	0,9952	1,1454
T1	66,1±2,0 ^{bc}	0,0091±0,0004 ^{ef}	76,1±3,4 ^c	0,9893	1,7242
T2	69,7±0,8 ^{ab}	0,0091±0,0004 ^{ef}	76,2±3,6 ^c	0,9941	1,2767
T3	50,2±5,1 ^{de}	0,0095±0,0006 ^{de}	73,1±5,0 ^{cd}	0,9825	2,3693
P1	51,9±0,7 ^{de}	0,0111±0,0005 ^c	62,8±2,8 ^e	0,9871	1,5474
P2	52,3±3,6 ^{de}	0,0116±0,0002 ^c	59,7±1,1 ^e	0,9892	1,4894
P3	48,7±1,4 ^{def}	0,0110±0,0000 ^{cd}	63,2±0,1 ^{de}	0,9695	2,2525
S1	38,8±2,4 ^f	0,0122±0,0005 ^c	56,8±2,3 ^e	0,9957	0,5769
S2	43,3±1,5 ^{ef}	0,0177±0,0007 ^a	39,2±1,5 ^f	0,9953	0,6978
S3	55,0±0,0 ^d	0,0077±0,0006 ^{fg}	90,2±7,4 ^{ab}	0,9894	1,2872
LSD	10,8	0,0014	10,1		

Iz dobivenih rezultata (**Slika 18**) vidljivo je da su uzorci C1-C3 te T1-T2 i S3 imali statistički značajno veće vrijednosti visine pjene, u odnosu na uzorke P1-P3 i S1-S2 i T3. Veće vrijednosti

visine pjene ukazuju na veću početnu visinu pjene analiziranih uzoraka nakon točenja piva u čašu pri jednakim eksperimentalnim uvjetima (**Tablica 4**).




Slika 18. Izmjerene vrijednosti visine pjene različitih uzoraka piva



Slika 19. Usporedba vrijednosti konstante brzine gubitka pjene različitih uzoraka piva

S obzirom na vrijednosti konstante brzine (**Slika 19**) vidljivo je da su vrijednosti najmanje (gubitak pjene najsporiji) kod uzoraka T1-T3, C1-C2 te S3. Manju stabilnost pjene pokazali su uzorci P1-P3, S1-S2 te C3. Nadalje, prema vrijednostima konstante brzine k među uzorcima T1 i T2, P1, P2 i S1 nema statistički značajne razlike.



Slika 20. Usporedba vrijednosti vremena polureakcije gubitka pjene različitih uzoraka piva

Vrijednosti polureakcije $t_{1/2}$ prikazane su na **Slici 20** iz koje je vidljivo da su najveću stabilnost pjene imali uzorci C1, S3, C2, T1-T3. Veće vrijednosti polureakcije ukazuju na to da je potrebno duže vremena da se visina pjene analiziranih uzoraka smanji za pola, odnosno pjena tih uzoraka se duže zadržavala na površini piva. Statistički najkraće vrijeme polureakcije gubitka pjene (najmanju stabilnost pjene) imali su uzorci C3 i S2 te se može zaključiti da su ovi uzorci imali najlošiji omjer tvari koje pozitivno i negativno utječu na stabilnost pjene. Smatra se da stabilnost pjene piva najviše ovisi upravo o tome da li će u njemu prevladati tvari koje imaju pozitivan ili tvari koje imaju negativan utjecaj na stvaranje i stabilnost pjene. Pozitivan utjecaj na stabilnost pjene imaju hidrofobni površinsko-aktivni proteini, naročito protein Z i lipid transfer protein LTP1, zatim izo- α -kisleline iz hmelja, dekstrini, metalni kationi, polipeptidni derivati hordeina, polifenoli, melanoidini i neškrobni polisaharidi (β -glukan i arabinoksilan). Tvari koje destabiliziraju pjenu su lipidi, neke aminokisleline i povećan udio etanola. Iako je u tamnim pivima sadržaj proteina koji pozitivno utječu na stabilnost pjene smanjen, ova piva uglavnom imaju vrlo stabilnu pjenu, a to se može pripisati produktima Maillardovih reakcija, melanoidinima nastalih pri proizvodnji specijalnih tamnih sladova. Melanoidini značajno pojačavaju hidrofobnost prisutnih proteina što uzrokuje da se mjehurići pjene jače privlače i bolje drže na okupu što u konačnici daje stabilniju pjenu (Lukinac i sur., 2019.).


4.3. Rezultati mjerenja stabilnosti vlažnog dijela pjene različitih uzoraka piva računalom analizom slike

Stabilnost **vlažnog dijela** pjene različitih vrsta piva analizirana je računalom analizom slike te izražena kao promjena visine stupca pjene H_0 tijekom vremena t . Rezultati mjerenja stabilnosti **vlažnog dijela** pjene prikazani su tablično (**Tablica 5**) i grafički (**Slika 21-23**). Vlažni dio pjene predstavlja onaj dio pjene koji se prvi gubi, i to u procesu isušivanja ili cijedenja pjene.

Tablica 5. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost vlažnog dijela pjene


Oznaka uzorka	H_0 (mm)	k (s ⁻¹)	$t_{1/2}$ (s)	R^2	RMSE
C1	23,0±2,5 ^{ab}	0,0237±0,0004 ^{cde}	29,3±0,5 ^{cd}	0,9695	0,7602
C2	21,7±1,6 ^{abc}	0,0235±0,0014 ^{cde}	29,6±1,8 ^{cd}	0,9630	0,7701
C3	15,0±0,9 ^e	0,0308±0,0004 ^{ab}	22,5±0,3 ^{ef}	0,9598	0,4517
T1	24,6±0,7 ^a	0,0342±0,0012 ^a	20,3±0,7 ^f	0,9595	0,7659
T2	22,7±2,1 ^{ab}	0,0272±0,0006 ^{bcd}	25,5±0,5 ^{def}	0,9657	0,6933
T3	16,6±2,9 ^{de}	0,0220±0,0012 ^e	31,7±1,7 ^c	0,9408	0,7422
P1	18,0±0,2 ^{cde}	0,0334±0,0014 ^a	20,8±0,9 ^f	0,9255	0,7866
P2	14,2±0,5 ^e	0,0237±0,0020 ^{cde}	29,5±2,4 ^{cd}	0,9228	0,7077
P3	19,7±1,2 ^{bcd}	0,0279±0,0029 ^{bc}	25,1±2,6 ^{def}	0,9201	0,9383
S1	7,0±0,7 ^f	0,0167±0,0014 ^f	41,9±3,6 ^b	0,9361	0,3535
S2	9,6±0,1 ^f	0,0253±0,0012 ^{cde}	27,4±1,3 ^{cde}	0,9291	0,4286
S3	8,5±0,8 ^f	0,0127±0,0006 ^f	54,7±2,7 ^a	0,9766	0,2802
LSD	4,5	0,0043	5,8		

Prema rezultatima prikazanim u **Tablici 5** vidljivo je da su vrijednosti H_0 vlažnog dijela pjene kod uzoraka C1-C3 u rasponu 15,0-23,0; kod uzoraka T1-T3 su u rasponu 16,6-24,6, kod uzoraka P1-P3 su u rasponu 14,2-19,7 te među njima postoji statistički značajna razlika. Vrijednosti H_0 vlažnog dijela pjene kod uzoraka S1-S3 su u rasponu 7,0-9,6 te među njima postoji statistički značajna razlika.




Slika 21. Izmjerene vrijednosti visine vlažnog dijela pjene različitih uzoraka piva

Iz dobivenih rezultata (**Slika 21**) vidljivo je da su se vrijednosti visine vlažnog dijela pjene kretale u rasponu 7,0-23,0 mm. Najveće vrijednosti visine vlažnog dijela pjene izmjerene su kod uzoraka C1-C2 te T1-T2, dok su najmanje vrijednosti izmjerene kod uzoraka S1-S3. S obzirom na vrijednosti visine vlažnog dijela pjene postoji statistički značajna razlika među većinom analiziranih uzoraka, iznimka su uzorci S1-S3 koji se nisu statistički značajno razlikovali.



Slika 22. Usporedba vrijednosti konstante brzine gubitka vlažnog dijela pjene različitih uzoraka piva

Najmanje vrijednosti konstante brzine k stabilnosti vlažnog dijela pjene imali su uzorci S3 ($0,0127 \text{ s}^{-1}$) i S1 ($0,0167 \text{ s}^{-1}$), dok su najveće vrijednosti imali uzorci T1 ($0,0342 \text{ s}^{-1}$) i P1 ($0,0334 \text{ s}^{-1}$). Veće vrijednosti ukazuju na manju stabilnost vlažnog dijela pjene analiziranih uzoraka piva, odnosno brzina gubitka pjene je veća. Analogno tomu, najduže vrijeme polureakcije gubitka vlažnog dijela pjene imali su uzorci S1 (41,9 s) i S3 (54,7 s) (**Slike 22 i 23**).




Slika 23. Usporedba vrijednosti vremena polureakcije gubitka vlažnog dijela pjene različitih uzoraka piva

4.4. Rezultati mjerenja stabilnosti suhog dijela pjene različitih uzoraka piva računalom analizom slike

Tablica 6. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost suhog dijela pjene


Oznaka uzorka	H_0 (mm)	k (s ⁻¹)	$t_{1/2}$ (s)	R^2	RMSE
C1	62,6±5,4 ^a	0,0068±0,0002 ^g	101,9±2,7 ^a	0,9912	1,5592
C2	56,1±4,7 ^{ab}	0,0077±0,0000 ^{fg}	90,1±0,2 ^b	0,9964	0,8554
C3	46,5±2,1 ^{cd}	0,0144±0,0009 ^b	48,3±3,0 ^{fg}	0,9940	0,9545
T1	51,5±2,6 ^{bc}	0,0078±0,0005 ^{fg}	88,1±5,6 ^b	0,9972	0,6800
T2	54,6±0,0 ^{abc}	0,0080±0,0005 ^{fg}	87,2±5,1 ^{bc}	0,9957	0,8856
T3	37,3±2,1 ^{ef}	0,0083±0,0005 ^{fg}	83,9±4,7 ^{bc}	0,9881	1,0515
P1	40,3±0,5 ^{def}	0,0098±0,0004 ^{de}	70,6±3,0 ^d	0,9943	0,8986
P2	41,0±3,6 ^{de}	0,0106±0,0001 ^{cd}	65,3±0,6 ^{de}	0,9920	1,0987
P3	34,1±1,5 ^{ef}	0,0091±0,0001 ^{ef}	76,2±0,9 ^{cd}	0,9765	1,4704
S1	32,2±1,7 ^f	0,0118±0,0005 ^c	58,9±2,3 ^{ef}	0,9986	0,2852
S2	34,6±1,4 ^{ef}	0,0169±0,0008 ^a	41,1±2,0 ^g	0,9983	0,4436
S3	47,4±0,2 ^{cd}	0,0074±0,0005 ^g	94,8±6,4 ^{ab}	0,9878	1,2635
LSD	8,3	0,0015	11,2		

Tablično i grafički (**Tablica 6 i Slike 24-26**) prikazani su rezultati stabilnosti suhog dijela pjene piva koja su deklarirana kao crno, tamno, pils i svijetlo lager. Stabilnost suhog dijela pjene određena je procesima koalescencije i disproporcijacije pri čemu se međusobno spajaju mjehurići pjene stvarajući veće mjehuriće što uzrokuje postupno smanjenje stabilnosti pjene. Prema vrijednostima statističkih kriterija uspješnosti aproksimacije eksperimentalnih podataka matematičkim modelom, vidljivo je da model dobro opisuje eksperimentalne podatke te može poslužiti za predviđanje stabilnosti suhog dijela pjene analizirani uzoraka piva (C, T, P i S). Najbolje slaganje eksperimentalnih i modelom predviđenih rezultata pokazali su uzorci piva deklarirane kao svijetlo lager (S1 i S2) te crno (C2).




Slika 24. Izmjerene vrijednosti visine suhog dijela pjene različitih uzoraka piva

S obzirom na dobivene rezultate visine suhog dijela pjene vidljivo je da uzorci deklarirani kao crno i tamno pivo imaju veće početne vrijednosti visine suhog dijela pjene, pri čemu najveće vrijednosti imaju uzorci deklarirani kao crno (C1, C2) te tamno (T1 i T2) pivo. Dok najmanje vrijednosti visine suhog dijela pjene imaju uzorci deklarirani kao svijetlo lager (S1 i S2) te pils (P3) pivo (**Slika 24**).



Slika 25. Usporedba vrijednosti konstante brzine gubitka suhog dijela pjene različitih uzoraka piva

S obzirom na vrijednosti konstante brzine gubitka suhog dijela pjene (**Slika 26**) manje vrijednosti konstante brzine gubitka pjene pokazali uzorci tamnog piva, deklarirani kao crna (C1, C2) i tamna piva (T1-T3), uz iznimku jednog uzorka svijetlog piva deklariranog kao svijetlo lager (S3).



Slika 26. Usporedba vrijednosti vremena polureakcije gubitka suhog dijela pjene različitih uzoraka piva

Nadalje, prema rezultatima vremena polureakcije gubitka suhog dijela pjene najveće vrijednosti pokazali uzorci tamnog piva, deklarirani kao crno (C1 i C3), tamno (T1-T3) uz iznimku jednog uzorka i svijetlog piva deklariranog kao svijetlo lager (S3) pivo (**Slika 26**).


Obzirom na veće vrijednosti visine, manje vrijednosti konstante brzine te veće vrijednosti vremena polureakcije može se reći da uzorci deklarirani kao crna i tamna piva imaju sporiji gubitak suhog dijela pjene te imaju stabilniju pjenu u odnosu na pils i svijetla lager piva.

4.5. Rezultati mjerenja stabilnosti pjene različitih uzoraka piva

Tablica 7. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost pjene


Oznaka uzorka	H_0 (mm)	k (s ⁻¹)	$t_{1/2}$ (s)	R^2	RMSE
C	69,2±9,6 ^a	0,0107±0,0037 ^a	71,7±20,2 ^a	0,9963	1,0784
T	62,0±9,0 ^a	0,0093±0,0005 ^a	75,1±4,3 ^a	0,9886	1,7901
P	50,9±2,8 ^b	0,0112±0,0004 ^a	61,9±2,3 ^a	0,9820	1,7631
S	45,7±7,0 ^b	0,0126±0,0041 ^a	62,0±21,7 ^a	0,9935	0,8540
LSD	10,0	0,0037	19,8		

Tablično i grafički (**Tablica 7** i **Slike 27-29**) prikazani su rezultati stabilnosti ukupne pjene piva koja su deklarirana kao crno, tamno, pils i svijetlo lager. Prema vrijednostima statističkih kriterija uspješnosti aproksimacije eksperimentalnih podataka matematičkim modelom, vidljivo je da model dobro opisuje eksperimentalne podatke te može poslužiti za predviđanje stabilnosti pjene analizirani uzoraka piva (C, T, P i S). Najbolje slaganje eksperimentalnih i modelom predviđenih rezultata pokazali su uzorci piva deklarirane kao crno (C), kod kojih je R^2 bio najveći ($R^2=0,9963$).




Slika 27. Izmjerene vrijednosti visine pjene različitih uzoraka piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo

S obzirom na dobivene rezultate visine ukupne pjene (**Slika 27**) vidljivo je da postoji statistički značajna razlika između svijetlog (uzorci deklarirani kao pils i svijetlo lager) te tamnog piva (uzorci deklarirani kao crno i tamno) pri čemu su uzorci tamnog piva pokazali veću početnu visinu (najveća visina pjene kod uzoraka deklariranih kao crno pivo).



Slika 28. Usporedba vrijednosti konstante brzine gubitka pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo

S obzirom na vrijednosti konstante brzine gubitka pjene nema statistički značajne razlike između analiziranih uzoraka piva, pri čemu su manje vrijednosti konstante brzine gubitka pjene pokazali uzorci deklarirani kao crna i tamna piva (**Slika 28**).



Slika 29. Usporedba vrijednosti vremena polureakcije gubitka pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo

Nadalje, prema rezultatima vremena polureakcije gubitka pjene nema statistički značajne razlike između analiziranih uzoraka piva, pri čemu su veće vrijednosti pokazali uzorci deklarirani kao crno i tamno pivo (**Slika 29**).


Obzirom na veće vrijednosti visine, manje vrijednosti konstante brzine te veće vrijednosti vremena polureakcije može se reći da uzorci deklarirani kao crna i tamna piva imaju manji gubitak pjene te imaju stabilniju pjenu u odnosu na pils i svijetla lager piva.

4.6. Rezultati mjerenja stabilnosti vlažnog dijela pjene različitih uzoraka piva

Tablica 8. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost vlažnog dijela pjene


Oznaka uzorka	H_0 (mm)	k (s ⁻¹)	$t_{1/2}$ (s)	R^2	RMSE
C	19,9±3,9 ^a	0,0260±0,0035 ^a	27,1±3,5 ^b	0,9641	0,6607
T	21,3±4,0 ^a	0,0278±0,0051 ^a	25,8±4,8 ^b	0,9553	0,7338
P	17,3±2,4 ^a	0,0283±0,0045 ^a	25,1±4,1 ^b	0,9228	0,8109
S	8,4±1,2 ^b	0,0182±0,0054 ^b	41,3±11,4 ^a	0,9473	0,3541
LSD	4,1	0,0062	8,9		

Tablično i grafički (**Tablica 8 i Slike 30-32**) prikazani su rezultati stabilnosti vlažnog dijela pjene piva koja su deklarirana kao crno, tamno, pils i svijetlo lager. Prema vrijednostima statističkih kriterija uspješnosti aproksimacije eksperimentalnih podataka matematičkim modelom, vidljivo je da model dobro opisuje eksperimentalne podatke te može poslužiti za predviđanje stabilnosti pjene analizirani uzoraka piva (C, T, P i S). Najbolje slaganje eksperimentalnih i modelom predviđenih rezultata pokazali su uzorci piva deklarirane kao crno (C), kod kojih je R^2 bio najveći ($R^2=0,9641$).




Slika 30. Izmjerene vrijednosti visine vlažnog dijela pjene različitih uzoraka piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo

S obzirom na dobivene rezultate visine vlažnog dijela pjene vidljivo da uzorci piva deklarirani kao svijetlo lager pivo imaju najmanje početne vrijednosti visine vlažnog dijela pjene (**Slika 30**).



Slika 31. Usporedba vrijednosti konstante brzine gubitka vlažnog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo

Prema rezultatima konstante brzine gubitka vlažnog dijela pjene te vremena polureakcije gubitka vlažnog dijela pjene nema statistički značajne razlike između uzoraka deklariranih kao crno, tamno i pils pivo (**Slika 31-32**).



Slika 32. Usporedba vrijednosti vremena polureakcije gubitka vlažnog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo


Najveće vrijednosti visine vlažnog dijela pjene zabilježene su kod uzoraka deklariranih kao tamno pivo. Nadalje najveće vrijednosti vremena polureakcije i najmanje vrijednosti konstante brzine gubitka vlažnog dijela pjene zabilježene su kod uzoraka deklariranih kao svijetlo lager pivo.

4.7. Rezultati mjerenja stabilnosti suhog dijela pjene različitih uzoraka piva

Tablica 9. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost suhog dijela pjene


Oznaka uzorka	H_0 (mm)	k (s ⁻¹)	$t_{1/2}$ (s)	R^2	RMSE
C	55,1±7,9 ^a	0,0096±0,0034 ^{ab}	80,1±23,1 ^{ab}	0,9939	1,1230
T	47,8±7,8 ^a	0,0080±0,0005 ^b	86,6±5,6 ^a	0,9937	0,8724
P	38,4±3,8 ^b	0,0098±0,0007 ^{ab}	70,7±4,8 ^{ab}	0,9876	1,1559
S	38,1±6,8 ^b	0,0120±0,0039 ^a	64,8±22,5 ^b	0,9949	0,6641
LSD	9,0	0,0035	21,8		

Tablično i grafički (**Tablica 9** i **Slike 33-35**) prikazani su rezultati stabilnosti suhog dijela pjene piva koja su deklarirana kao crno, tamno, pils i svijetlo lager. Prema vrijednostima statističkih kriterija uspješnosti aproksimacije eksperimentalnih podataka matematičkim modelom, vidljivo je da model dobro opisuje eksperimentalne podatke te može poslužiti za predviđanje stabilnosti pjene analizirani uzoraka piva (C, T, P i S). Najbolje slaganje eksperimentalnih i modelom predviđenih rezultata pokazali su uzorci piva deklarirane kao pils (P), kod kojih je R^2 bio najveći ($R^2=0,9976$).




Slika 33. Usporedba vrijednosti visine suhog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo

S obzirom na dobivene rezultate visine suhog dijela pjene vidljivo je da postoji statistički značajna razlika između svijetlog (uzorci deklarirani kao pils i svijetlo lager) te tamnog piva (uzorci deklarirani kao crno i tamno) pri čemu su uzorci tamnog piva imali veću početnu visinu (Slika 33).



Slika 34. Usporedba vrijednosti konstante brzine gubitka suhog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo



Slika 35. Usporedba vrijednosti vremena polureakcije gubitka suhog dijela pjene piva koja su deklarirana kao crno (C), tamno (T), pils (P) i svijetlo lager (S) pivo

Vrijednosti konstante brzine gubitka suhog dijela pjene bile su najmanje kod uzoraka deklariranih kao tamna piva (**Slika 34**).

Uspoređujući rezultate vremena polureakcije gubitka suhog dijela pjene svih promatranih uzoraka vidljivo je da su vrijednosti $t_{1/2}$ najmanje kod uzoraka deklariranih kao svijetla lager piva (**Slika 35**).


Obzirom na veće vrijednosti visine, manje vrijednosti konstante brzine te veće vrijednosti vremena polureakcije može se reći da uzorci deklarirani kao crna i tamna piva imaju manji gubitak suhog dijela pjene te imaju stabilniju pjenu u odnosu na pils i svijetla lager piva.

4.8. Usporedba stabilnosti pjene svijetlog i tamnog piva

Tablično i grafički (**Tablica 10 i Slike 36-38**) prikazani su rezultati stabilnosti pjene svijetlog i tamnog piva. Prema vrijednostima statističkih kriterija uspješnosti aproksimacije eksperimentalnih podataka matematičkim modelom, vidljivo je da model dobro opisuje eksperimentalne podatke te može poslužiti za predviđanje stabilnosti pjene kako svijetlih tako i tamnih vrsta piva. Obzirom na veće vrijednosti R^2 za uzorke svijetlog piva, model bolje predviđa stabilnost ukupne pjene kod uzoraka svijetlog piva.


Tablica 10. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost pjene

Oznaka uzorka	H_0 (mm)	k (s^{-1})	$t_{1/2}$ (s)	R^2	RMSE
T	65,6±10,0 ^a	0,0100±0,0027 ^a	73,4±14,7 ^a	0,9925	1,4342
S	48,3±5,9 ^b	0,0119±0,0030 ^a	62,0±15,4 ^a	0,9877	1,3085
LSD	10,0	0,0037	19,8		




Slika 36. Usporedba vrijednosti visine pjene tamnog (T) i svijetlog (S) piva

S obzirom na dobivene rezultate visine pjene vidljivo je da postoji statistički značajna razlika između svijetlog i tamnog piva, pri čemu su uzorci tamnog piva pokazali veću početnu visinu pjene (**Slika 36**).



Slika 37. Usporedba vrijednosti konstante brzine gubitka pjene tamnog (T) i svijetlog (S) piva



Slika 38. Usporedba vrijednosti vremena polureakcije gubitka pjene tamnog (T) i svijetlog (S) piva

Vrijednosti konstante brzine gubitka pjene te vremena polureakcije nisu se statistički značajno razlikovale kod promatranih uzoraka, pri čemu su uzorci tamnog piva pokazali manje vrijednosti konstante brzine ($0,0100 s^{-1}$) i veće vrijednosti vremena polureakcije (73,4 s) gubitka pjene (**Slika 37-38**).


4.9. Usporedba stabilnosti vlažnog dijela pjene svijetlog i tamnog piva

Tablično i grafički (**Tablica 11** i **Slike 39-41**) prikazani su rezultati stabilnosti vlažnog dijela pjene svijetlog i tamnog piva. Prema vrijednostima statističkih kriterija uspješnosti aproksimacije eksperimentalnih podataka matematičkim modelom, vidljivo je da model dobro opisuje eksperimentalne podatke te može poslužiti za predviđanje stabilnosti pjene kako svijetlih tako i tamnih vrsta piva. Obzirom na veće vrijednosti R^2 za uzorke tamnog piva, model bolje predviđa stabilnost vlažnog dijela pjene kod uzoraka tamnog piva.


Tablica 11. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost vlažnog dijela pjene

Oznaka uzorka	H_0 (mm)	k (s ⁻¹)	$t_{1/2}$ (s)	R^2	RMSE
T	20,6±4,0 ^a	0,0269±0,0045 ^a	26,5±4,2 ^a	0,9597	0,6972
S	12,8±4,8 ^b	0,0233±0,0071 ^a	33,2±11,8 ^a	0,9350	0,5825
LSD	3,9	0,0052	7,8		


S obzirom na dobivene rezultate visine vlažnog dijela pjene vidljivo je da postoji statistički značajna razlika između svijetlog i tamnog piva, pri čemu su uzorci tamnog piva pokazali veću početnu visinu vlažnog dijela pjene (**Slika 39**).



Slika 39. Usporedba vrijednosti visine vlažnog dijela pjene tamnog (T) i svijetlog (S) piva



Slika 40. Usporedba vrijednosti konstante brzine gubitka vlažnog dijela pjene tamnog (T) i svijetlog (S) piva



Slika 41. Usporedba vrijednosti vremena polureakcije gubitka vlažnog dijela pjene tamnog (T) i svijetlog (S) piva


Vrijednosti konstante brzine gubitka vlažnog dijela pjene te vremena polureakcije nisu se statistički značajno razlikovale kod promatranih uzoraka (**Slika 40-41**). Pri čemu su uzorci tamnog piva pokazali veće vrijednosti konstante brzine ($0,00269 s^{-1}$) i manje vrijednosti vremena polureakcije (26,5 s) gubitka vlažnog dijela pjene.

4.10. Usporedba stabilnosti suhog dijela pjene svijetlog i tamnog piva

Tablično i grafički (**Tablica 12** i **Slike 42-44**) prikazani su rezultati stabilnosti suhog dijela pjene svijetlog i tamnog piva. Vrijednosti konstante brzine gubitka suhog dijela pjene te vremena polureakcije ukazuju na veću stabilnost suhog dijela pjene kod uzoraka tamnog piva. Odnosno uzorci tamnog piva imali su manje vrijednosti konstante brzine ($0,0088 \text{ s}^{-1}$) i veće vrijednosti vremena polureakcije (83,4 s) gubitka suhog dijela pjene piva.

Tablica 12. Parametri eksponencijalnog matematičkog modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka za stabilnost suhog dijela pjene


Oznaka uzorka	H_0 (mm)	k (s^{-1})	$t_{1/2}$ (s)	R^2	RMSE
T	$51,4 \pm 8,7^a$	$0,0088 \pm 0,0026^a$	$83,4 \pm 17,1^a$	0,9938	0,9977
S	$38,3 \pm 5,5^b$	$0,0109 \pm 0,0030^a$	$67,8 \pm 16,5^b$	0,9913	0,9100
LSD	6,4	0,0025	14,9		




Slika 42. Usporedba vrijednosti visine suhog dijela pjene tamnog (T) i svijetlog (S) piva

S obzirom na dobivene rezultate vidljivo je da postoji statistički značajna razlika u stabilnosti suhog dijela pjene između svijetlog i tamnog piva, pri čemu su uzorci tamnog piva pokazali veću visina te duže vrijeme polureakcije gubitka suhog dijela pjene (**Slika 43-44**). Prema vrijednostima statističkih kriterija uspješnosti aproksimacije eksperimentalnih podataka matematičkim modelom, vidljivo je da model dobro opisuje eksperimentalne podatke

(vrijednosti R^2 visoke) te može poslužiti za predviđanje stabilnosti pjene kako svijetlih tako i tamnih vrsta piva.



Slika 43. Usporedba vrijednosti konstante brzine gubitka suhog dijela pjene tamnog (T) i svijetlog (S) piva



Slika 44. Usporedba vrijednosti vremena polureakcije gubitka suhog dijela pjene tamnog (T) i svijetlog (S) piva

5. ZAKLJUČCI

Iz provedenog istraživanja moguće je izvesti sljedeće zaključke:

- Računalna analiza slike pokazala se kao prikladna, objektivna, ponovljiva i pouzdana metoda za mjerenje boje i stabilnosti pjene piva (i to ukupne pjene, vlažnog te suhog dijela pjene). Nadalje, metoda je dovoljno osjetljiva da se može primijeniti za određivanje boje i stabilnosti pjene različitih vrsta piva.
- Rezultati boje piva prikazani su kao komponente CIEL*a*b* sustava boja, te su tamnija piva imala manje vrijednosti parametra svjetline (L^*), veće vrijednosti kromatske komponente a^* i manje vrijednosti kromatske komponente b^* . Nasuprot tome, uzorci svijetlog piva pokazali su veće vrijednosti svjetline (L^*), manje vrijednosti kromatske komponente a^* i veće vrijednosti kromatske komponente b^* .
- Primijenjeni matematički model (eksponencijalni model gubitka pjene) pokazao se kao prikladan za predviđanje promjene gubitka pjene različitih vrsta piva svijetlih i tamnih piva
- S obzirom na rezultate stabilnosti pjene, u prosjeku tamna piva imaju stabilniju pjenu.

6. LITERATURA

- Bamforth, CW: The foaming properties of beer. *Journal of Institute of Brewing*. 91:370-383, 1985.
- Bamforth, CW: The relative significance of physics and chemistry for beer foam excellence: theory and practice. *Journal of Institute of Brewing*. 110: 259-266, 2004.
- Boulton C, Quain D: *Brewing Yeast and Fermentation*, Blackwell Science Ltd Oxford, 2001.
- Briggs DE, Boulton CA, Brookes PA, Stevens R: *Brewing Science and Practice*, Woodhead Publishing Limited, Cambridge, UK, 2004.
- Buera MPJ: Chirife J, Resnik SL, Wetzler G: Nonezymatic browning in liquid model systems of high water activity: Kinetic of color changes due to Maillards reaction between different single sugar and glycine and comparison with caramelization browning. *Journal of Food Science*. 52(4):1063-1064, 1987.
- Cao L: Novel methods for the determination of colour and translucency in selected alcoholic beverages. *Doktorska disertacija*. International Centre for Brewing and Distilling, School of Life Sciences Heriot-Watt University, 2013.
- deLange AJ: The standard reference method of beer color specification as the basis for a new method of beer color reporting. *Journal of American Society of Brewing and Chemistry*. 66:143-150, 2008.
- Evans DE, Bamforth CW: *Beer foam: achieving a suitable head* U Beer: A Quality Perspective, 1st ed., Bamforth, C.W., Ed., Academic Press, New York, 2009.
- Filko D: Robusna lokalizacija mobilnog robota zasnovana na vizualnim obilježjima ravninskih segmenata. *Doktorska disertacija*. Elektrotehnički fakultet, Osijek, 2013.
- Hepworth NJ, Varley J, Hind A: Characterizing Gas Bubble Dispersions in Beer. *Food Bioprod. Process*. 79:13-20, 2001.
- Hodge JE: Chemistry of Browning Reactions in Model Systems. *Agricultural and Food Chemistry*, 1(15): 928-943, 1953.
- Hsien-Che L: *Introduction to Color Imaging Science*. Cambridge University Press, New York, 2005.
- Huges PS, Baxter ED: *Beer: Quality, Safety and Nutritional Aspects*. Royal Society of Chemistry, Cambridge, 2001.
- Larrain RE., Schafer DM, Reed JD: Use of digital images to estimate CIE color coordinates of beef. *Food Research International*. 41:380-385, 2008.
- Leon K, Mery D, Pedreschi D, Leon D. Color measurement in L*a*b* units from RGB digital images. *Food Research International*, 39: 1084-1091, 2006.
- Lubetkin S, Blackwell B: The nucleation of bubbles in supersaturated solutions. *Journal of Colloid Interf. Science*. 26:610-615, 1988.
- Lukinac J, Mastanjević K, Mastanjević K, Nakov G, Jukić M: Computer Vision Method in Beer Quality Evaluation—A Review. *Beverages*. 5(2): 1-21, 2019.

- Mendoza F, Dejmek P, Aguilera JM: Calibrated color measurements of agricultural foods using image analysis. *Postharvest Biology and Technology*, 41(3): 285-295, 2006.
- Nursten H: *The Maillard Reaction. Chemistry, Biochemistry and Implications*. The Royal Society of Chemistry, Cambridge, UK, 2005.
- Pomeranz Y, Meloan CE: *Measurement of color*. U *Food Analysis: Theory and Practice*. Y.M.C.E. Pomeranz. (ur.), New York, 1994.
- Pozdrik R, Roddick FA, Rogers PJ, Nguyen T: Spectrophotometric method for exploring 3-methyl-2-butene-1-thiol (MBT) formation in lager. *Journal of Agricultural and Food Chemistry*. 54(17):6123-9, 2006.
- Puglia S: Technocal Primer U *Handbook for Digital Projects: A Management Tool for Preservation and Access* Maxine K. Sitts. (ur.) Northeast Document Conservation Center, 2000.
- Russ JC, Neal FB: *The image Processing Handbook, 7th edition*. Taylor & Francis Group, New York, 2007.
- Šavel J, Košin P, Brož A: Anaerobic and Aerobic Beer Aging. *Czech Journal of Food Science* 28:18-26, 2010.
- Shellhammer TH: Beer color U *Beer: A Quality Perspective*, 1st ed., Bamforth, C.W., Ed., Academic Press, New York, 2009.
- Spearot JW: Influence of Beer Color on Perception of Bitterness. Master rad, Drexel University, Philadelphia, 2016.
- Strgar Kurečić M: *Primjena digitalne fotografije u reprodukcijским medijima*. Grafički fakultet, 2015.
- WEB (1) URL: https://www.google.com/search?q=aditivni+modeli&client=firefox-b-d&source=lnms&tbm=isch&sa=X&ved=0ahUKEWjyh9LCjLXiAhVw-ioKHWm9CUQQ_AUIDigB&biw=1920&bih=983#imgrc=Xynr_v2KQqwK8M (datum pristupa 20.2.2019.)
- WEB (2) URL: https://www.google.com/search?client=firefox-b-d&biw=1920&bih=983&tbm=isch&sa=1&ei=aF_oXP-dHo77kwX3x46wDA&q=rgb+space&oq=rgb+space&gs_l=img.3..0i19j0i7i30i19l4j0i7i5i30i19l3j0i30i19j0i8i30i19.149111.149111..149445...0.0.0.171.171.0j1.....0....1..gws-wiz-img.xXlfq1DHMTs#imgrc=48JIGUKYZH-MPM: (datum pristupa 20.2.2019.)
- WEB (3) URL: https://www.google.com/search?client=firefox-b-d&biw=1920&bih=983&tbm=isch&sa=1&ei=tV7oXIShC5GTkwWcwlyoDw&q=rgb+color+space&oq=rgb+color+space&gs_l=img.3..0i19l3j0i5i30i19l2j0i8i30i19l2.170284.171561..171812...0.0.0.151.847.0j6.....0....1..gws-wiz-img.....0i7i30j0i7i5i30j0i8i7i30j0i7i30i19j0i7i5i30i19j0i8i7i30i19.L2s_d-QdIX0#imgrc=Bflz7Cw_8mTpRM: (datum pristupa 20.2.2019.)
- WEB (4) URL: https://www.google.com/search?client=firefox-b-d&biw=1920&bih=983&tbm=isch&sa=1&ei=f1zoXPP0IcGSsAft7pNA&q=cie+xyz+space&oq=cie+xyz+space&gs_l=img.3..0i8i30l2.101671.103741..104197...0.0.0.153.821.0j6.

.....0....1..gws-wiz-
img.....0i19j0i30i19j0i8i30i19.UC0TMHDRVok#imgdii=Xm8XLbeN7KETbM:&imgrc=kj
m_bGKqKY9lOM: (datum pristupa 20.2.2019.)

WEB (5) URL: <https://www.pinterest.com/pin/416864509250812954/> (datum pristupa 20.2.2019.)

WEB (6) URL:
https://developer.apple.com/library/archive/documentation/GraphicsImaging/Conceptual/csintro/csintro_colorspace/csintro_colorspace.html (datum pristupa 20.2.2019.)

WEB (7) URL: <https://designontopic.files.wordpress.com/2014/02/beerfoam.jpg> (datum pristupa 18.12.2018.)

WEB (8) URL: <https://www.slideshare.net/akarim717/foam-24926136> (datum pristupa 18.12.2018.)

WEB (9) URL: <http://frankenmuthbrewery.com/12-fun-facts-beer-foam/> (datum pristupa 18.12.2018.)

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