

Analiza varijabli koje utječu na mikrobiološku kvalitetu u proizvodnji svježeg sira

Brankica Sobota Šalamon^{1*}, Rajka Božanić², Jasminka Dobša³

¹NaturaLab d.o.o. Ispitni laboratorij za kontrolu kakvoće, Kolodvorska 21 B, Đurđevac, Hrvatska

²Prehrambeno biotehnološki fakultet Sveučilišta u Zagrebu, Pierottijeva 6, Zagreb, Hrvatska

³Fakultet organizacije i informatike Sveučilišta u Zagrebu, Pavlinska 2, Varaždin, Hrvatska

Prispjelo - Received: 17.10.2010.

Prihvaćeno - Accepted: 22.11.2010.

Sažetak

U radu su ispitivane varijable koje utječu na mikrobiološku kvalitetu u proizvodnji svježeg sira s obzirom na kvasce i plijesni. Kvasci i plijesni ne preživljavaju pasterizaciju, a izolirani iz gotovog proizvoda posljedica su naknadne kontaminacije tijekom fermentacije mlijeka i izdvajanja sirutke. Stoga su u ovom radu mjerene sljedeće varijable: ukupni broj aerobnih mezofilnih bakterija u ispirnoj vodi, ukupni broj kvasaca i plijesni u ispirnoj vodi, ukupni broj aerobnih mezofilnih bakterija u pasteuriziranom mlijeku za sirenje, ukupni broj aerobnih mezofilnih bakterija u zraku i ukupni broj kvasaca i plijesni u zraku. Navedene varijable analizirane su pomoću statističkih metoda deskriptivne statistike i metode glavnih komponenta (PCA), te metode umjetne inteligencije, stabla odlučivanja. Rezultati metode glavnih komponenta, s obzirom na broj kvasaca i plijesni u gramu svježeg sira, pokazali su da najveći utjecaj na kvalitetu sira ima mikrobiološka čistoća zraka. Pomoću metode stabla odlučivanja dobiveni su interni standardi za ukupan broj aerobnih mezofilnih bakterija te kvasaca i plijesni u zraku koji utječu na mikrobiološku kvalitetu svježeg sira.

Ključne riječi: mikrobiološka kvaliteta, metoda glavnih komponenta, stablo odlučivanja, svježi sir, proizvodnja

Uvod

U sustavu samokontrole procesa proizvodnje hrane nameće se pitanje kako se može unaprijediti postojeći sustav kontrole. Želi se postići odvijanje procesa proizvodnje sa što manje rizika, te konačan proizvod ujednačene kvalitete i neškodljiv za zdravlje. S obzirom da se pojedini parametri u procesu proizvodnje prate i evidentiraju odvojeno ili u paru, postavlja se pitanje kako mnogobrojne postupke, odnosno različite parametre u jednom procesu, integrirati u jednu cjelinu i tako ostvariti potpuniji sustav kontrole. Najveći problem svake proizvodnje su potencijalne varijacije u pojedinim koracima procesa. Matematičko modeliranje utjecaja različitih parameta-

tara u proizvodnji svježeg sira na mikrobiološku kvalitetu gotovog proizvoda može pomoći u sagledavanju tijekom proizvodnje. Kako bi se utvrdio optimalan pokazatelj mikrobiološke kvalitete sira važni su sljedeći principi: mikrobiološka kontrola patogena i njihovih toksina, edukacija djelatnika koji sudjeluju u pripremi hrane, distribuciji, skladištenju, prodaji i konzumaciji proizvoda te primjena HACCP-a (Forsythe, 1988.; El-Hofi i sur., 2010.). Najčešći uzroci trovanja hranom su uslijed nedovoljnog hlađenja (44 %), neadekvatne sirovine i loše toplinske obrade (32 %) kao i zbog nedovoljne higijene u proizvodnim procesima (18 %) te je stoga potrebno postaviti kontrolne i kritične točke i redovito ih pratiti (Jay, 2000.).

*Dopisni autor/Corresponding author/: E-mail: brankica.salamon@e-mail.t-com.hr

Potrošači zahtijevaju nove proizvode na tržištu koji su minimalno toplinski obrađeni, senzorski privlačni i zdravstveno neškodljivi. Sve to zahtijeva detaljno poznavanje tehnoloških procesa proizvodnje hrane i znanja iz različitih područja poput tehnologije, statistike i matematike (Raspor, 2006.).

U posljednjih 30 godina počinje intenzivan razvoj i primjena statističkih metoda, koje mogu obrađivati veliku količinu podataka, klasificirati ih te omogućiti donošenje određenih zaključaka iz mase informacija (Mahesh i Mather, 2003.).

Analiza glavnih komponenata klasična je metoda kojom se pokušava reducirati dimenzionalnost podataka, tako da se konstruiraju latentne varijable koje su međusobno nezavisne (nisu međusobno u korelaciji), a onda se zadrže samo one koje su "dovoljno informativne". Razvio ju je Hotelling 1933. godine. Da bi se reducirao broj varijabli, odnosno dimenzija prostora, potrebno je pronaći kriterij za odbacivanje "malo informativnih" varijabli, odnosno za zadržavanje onih varijabli koje nose najveći dio informacija sadržanih u polaznom sustavu varijabli. Metoda glavnih komponenata se najviše koristi kod obrade modela s više parametara. Svrha ove metode je analiza korelacija unutar jednog skupa parametara i posljedične redukcije dimenzionalnosti prostora, kako bi se što veći broj parametara objasnio sa što manje parametara. Metoda glavnih komponenata se ne koristi ako parametri nisu u korelaciji (Manly, 1986.; Matijević i Blažić, 2008.). Metoda glavnih komponenata primijenjena je za otkrivanje i izdvajanje pogrešaka na duplikatorima za fermentaciju. Korišteni su podaci iz laboratorijskih i industrijskih uvjeta proizvodnje (Klančar i Škrjanc, 2002.). Ovom metodom može se ispitivati rok trajanja pasteriziranog i steriliziranog mlijeka na temelju senzorskih parametara mjerenih elektronskim senzorom za komponente kvarenja (diacetil fosfat, oleinska kiselina...) (Yap Mee Sim i sur., 2003.).

Stablo odlučivanja vrlo je uspješna i popularna tehnika modeliranja za klasifikacijske probleme. Prihvatljivost stabla odlučivanja leži u činjenici da nudi model podataka u razumljivom obliku - u obliku pravila. Ta pravila se lako mogu direktno interpretirati običnim jezikom. Metoda stabla odlučivanja je prikladnija za obradu podataka sa šumom (*engl.* noisy data) u odnosu na klasične statističke metode. Kod modeliranja stablom odlučivanja ne postavljaju se nikakve statističke pretpostavke, pa je takav algoritam

pogodan za učenje kada statističke pretpostavke za podatke (kao što je normalna raspodjela podataka) nisu ispunjene. Stablo odlučivanja je klasifikacijski algoritam u obliku stablaste strukture, u kojoj se razlikuju dva tipa čvorova povezanih granama:

- krajnji čvor kojim završava određena grana stabla. Krajnji čvorovi definiraju klasu kojoj pripadaju primjeri koji zadovoljavaju uvjete na toj grani stabla;
- čvor odluke koji definira određeni uvjet u obliku vrijednosti određene varijable, iz koje izlaze grane koje zadovoljavaju određene vrijednosti ciljnih varijabli (Stabla odlučivanja, 2008.).

U ovom je radu korišten algoritam QUEST (Quick, Unbiased, Efficient Statistical Trees) kojim je implementirano stablo odlučivanja. Ovaj algoritam već je korišten za istraživanja u proizvodnji hrane (Bertelli i sur., 2007.) za problem klasifikacije meda iz različitih cvjetnih izvora. U tom se radu pored stabla odlučivanja također koristi i metoda glavnih komponenata za izbor varijabli, tako da se za istraživanje koriste samo one varijable čiji su koeficijenti u glavnim komponentama veliki. U ovom se istraživanju ne koristi metoda glavnih komponenata za izbor varijabli, već samo za identifikaciju glavnih komponenata oko kojih se grupiraju promatrane varijable. Pored primjene u industriji hrane, QUEST algoritam je korišten i u području medicine (Hoque i sur., 2006.), društvenih znanosti (Stahl, 2005.; Kennebley i sur, 2005.), meteorologije (Carter i Elsner, 1997.; Elsner i sur., 1999.) i slično.

Cilj ovog istraživanja je razviti primjenu matematičkih modela kao novih alata za bolje razumijevanje prehrambeno tehnoloških procesa u svrhu prevencije potencijalne mikrobiološke opasnosti i smanjenja rizika za zdravlje potrošača.

Materijal

Kao sirovina za proizvodnju svježeg sira korišteno je sirovo mlijeko s područja 30 km oko mljekare koje je termički obrađeno u postupku proizvodnje svježeg sira.

Od hranjivih podloga korištene su sljedeće podloge: Tryptic glucose yeast agar, Sabraud dextrose agar i Maximum recovery diluent.

Metode rada

Proizvodnja svježeg sira

Sirovo mlijeko cisternama je dopremljeno u mljekaru, rashlađeno preko hladnjaka i primljeno u tankove. Iz tankova je transportirano putem cjevovoda na standardizaciju masti, te na pasterizaciju pri 83 °C/15 sekundi. Mlijeko je ohlađeno na 30 °C i transportirano do Schulenbergove kade u kojoj se vrši fermentacija mlijeka. Ispirna voda uzorkovana je iz cjevovoda neposredno prije napuštanja mlijeka u kadu i ispitivana na broj aerobnih mezofilnih bakterija (AMB) te kvasaca i plijesni (KP). Iz istog cjevovoda uzorkovan je uzorak pasteriziranog mlijeka i ispitivan na broj AMB. Na početku fermentacije ispitivan je broj AMB te KP i u zraku. Ispitivanje je provedeno uvijek na istom mjestu u proizvodnom dijelu pogona. Za određivanje AMB u zraku, zrak je uzorkovan na Tryptic glucose yeast agar pločama (Ø90 mm) otvorenim 30 minuta u neposrednoj blizini kade za fermentaciju svježeg sira, a ploče su inkubirane pri 30 °C/2-3 dana. Za određivanje KP u zraku, zrak je uzorkovan na Sabraud dextrose agar pločama (Ø90 mm) otvorenim 30 minuta u neposrednoj blizini kade za fermentaciju svježeg sira te su ploče inkubirane pri 25 °C/3-5 dana. U pasterizirano mlijeko dodana je mezofilna kultura, kalcijev

klorid i tekuće sirilo. Fermentacija mlijeka trajala je prosječno 18 h. Kada je postignut pH 4,50 prekidala se fermentacija i vršilo rezanje grušā, ocjeđivanje sira i odvajanje sirutke. Ocijeđeni svježi sir se pakirao i spremao u hladnjaču.

Statističke metode

Navedene varijable iz procesa proizvodnje svježeg sira su obrađivane pomoću statističkih metoda deskriptivne statistike i metode glavnih komponenta te metode umjetne inteligencije stabla odlučivanja u programu Statistika 7.1 (Stat Soft Inc., 2008.). Metoda glavnih komponenta daje uvid u najvažnije faktore ili glavne komponente oko kojih su grupirane varijable promatrane u istraživanju. Prva je glavna komponenta linearna kombinacija originalnih varijabli u smjeru maksimalne varijacije podataka. Druga glavna komponenta je linearna kombinacija originalnih varijabli u smjeru ortogonalnom na prvu komponentu, itd. (Manly, 1986.; Rencher, 2002.).

Uzorci sira klasificirani su u dvije klase: u prvoj klasi su mikrobiološki dobri proizvodi, a u drugoj mikrobiološki loši proizvodi. Glavne komponente formirane su temeljem uzoraka iz klase mikrobiološki dobrih proizvoda. Prema broju KP u svježem siru mikrobiološki dobri proizvodi imaju <100 cfu

Tablica 1. Standardna devijacija (st.dev.), aritmetička sredina (\bar{x}) te minimalne (min) i maksimalne (max) vrijednosti varijabli (n=150)

Table 1. Standard deviation (st.dev.), mean (\bar{x}), minimal (min) and maximal (max) values of variables (n=150)

Varijable Variables	St. dev.	\bar{x}	Min.	Max.
Ukupni broj AMB. u ispirnoj vodi/mL Viable count of AMB in rinsing water/mL	18,86	27,19	0,00	82,00
Ukupni broj KP u ispirnoj vodi/mL Viable count of KP in rinsing water/mL	0,67	0,54	0,00	2,00
Ukupni broj AMB u pasteriziranom mlijeku/mL Viable count of AMB in pasteurized milk/mL	73,59	63,33	10,00	400,00
Ukupni broj AMB u zraku Viable count of AMB in air	18,66	43,17	12,00	96,00
Ukupni broj KP u zraku Viable count of KP in air	11,91	23,09	2,00	55,00
Ukupni broj KP/g svježeg sira Viable count of KP/g fresh cheese	35,58	34,07	0,00	100,00

AMB - aerobne mezofilne bakterije/aerobic mesophilic bacteria

KP - kvasci i plijesni/yeasts and moulds

(KP) u gramu svježeg sira, a mikrobiološki loši proizvodi imaju ≥ 100 cfu KP u gramu svježeg sira (Pravilnik o mikrobiološkim standardima za namirnice, NN 46/94). Metodom stabla odlučivanja predviđa se klasa uzoraka na temelju vrijednosti promatranih varijabli. U ovom slučaju to su klase dobri i loši proizvodi. Uzorak se klasificira prolaskom kroz stablo odlučivanja od korijena do najnižih čvorova koji se nazivaju listovima. Svaki čvor predstavlja test za neku od promatranih varijabli, a svaka grana koja izlazi iz čvora predstavlja uvjet na danu varijablu. Ispitivanje je ponovljeno 150 puta, a rezultati su dani kao aritmetička sredina.

Rezultati i rasprava

Tablica 1 daje uvid u standardnu devijaciju, aritmetičku sredinu te minimalne i maksimalne vrijednosti mjenjenih varijabli i gotovog proizvoda. Standardna devijacija predstavlja mjeru raspršenosti u skupu podataka. Najviša je raspršenost podataka kod ukupnog broja AMB u pasteriziranom mlijeku za sirenje, a najniža kod ukupnog broja KP u ispirnoj vodi iz cjevovoda. Usporedo s tim podacima dobiva se uvid u najviše minimalne i maksimalne vrijednosti

kod ukupnog broja AMB u pasteriziranom mlijeku za sirenje, a najniže kod ukupnog broja KP u ispirnoj vodi iz cjevovoda.

U tablici 2 prikazana je deskriptivna statistika ispitivanih varijabli. Aritmetička sredina daje uvid u srednju vrijednost, a koeficijent varijacije u raspršenost numeričkih vrijednosti varijabli. Koeficijent varijacije je omjer standardne devijacije i aritmetičke sredine numeričkih vrijednosti promatrane varijable. Veliki koeficijent varijacije (iznad 50 %) upućuje na veliku raspršenost podataka što povlači malu reprezentativnost aritmetičke sredine. Pored ovih mjera deskriptivne statistike ispitana je i normalnost razdiobe za korištene varijable te je utvrđeno da varijable ne podliježu zakonitostima normalne razdiobe. Nepostojanje normalnosti razdiobe i velika raspršenost podataka zahtijeva robusnije metode analize podataka, pa je to bio indikator za primjenu.

U tablici 3 prikazane su varijable koje su obrađene metodom glavnih komponenata u ovisnosti o broju kvasaca i plijesni u svježem siru. Prvi faktor nosi 29,13 % ukupne varijacije podataka. Pretpostavka je da varijabla pripada faktoru ako je koeficijent uz varijablu u tom faktoru po apsolutnoj vrijednosti veći od 0,6.

Tablica 2. Deskriptivna statistika promatranih varijabli
Table 2. Descriptive statistics of monitored variables

Varijable Variables	Aritmetička sredina Aritmetic mean	Koeficijent varijacije Coefficient of variation %	Aritmetička sredina Aritmetic mean	Koeficijent varijacije Coefficient of variation %
	Dobri proizvodi Products of desired quality		Loši proizvodi Products of undesirable quality	
Ukupni broj AMB u ispirnoj vodi/mL Viable count of AMB in rinsing water/mL	26,89	70,65	29,53	61,18
Ukupni broj KP u ispirnoj vodi/mL Viable count of KP in rinsing water/mL	0,57	118,55	0,29	199,88
Ukupni broj AMB u pasteriziranom mlijeku/mL Viable count of AMB in pasteurized milk/mL	64,80	117,57	51,88	94,41
Ukupni broj AMB u zraku Viable count of AMB in air	38,74	37,11	77,76	13,06
Ukupni broj KP u zraku Viable count of KP in air	20,14	43,70	46,24	13,73

AMB - aerobne mezofilne bakterije/aerobic mesophilic bacteria

KP - kvasci i plijesni/yeasts and moulds


Tablica 3. Korelacije faktora i varijabli za prva tri faktora

Table 3. Factor-variable correlations that can be explained by the first 3PCs

Varijable	Faktor 1	Faktor 2	Faktor 3
Variables	Factor 1	Factor 2	Factor 3
Ukupni broj A.M.B. u ispirnoj vodi/mL			
Total number of aerobic mesophilic bacteria AMB in rinsing water/mL	-0,32	-0,76	0,12
Ukupni broj KP u ispirnoj vodi/mL			
Total number KP in rinsing water/mL	-0,14	-0,14	-0,97
Ukupni broj AMB u pasteuriziranom mlijeku/mL			
Total number of aerobic mesophilic bacteria AMB in pasteurized milk/mL	-0,50	-0,66	0,14
Ukupni broj AMB u zraku			
Total number AMB in air	0,66	-0,52	-0,16
Ukupni broj KP u zraku			
Total number KP in air	0,80	-0,32	0,10
Ukupni broj KP/g svježeg sira			
Total number KP/g fresh cheese	0,16	-0,12	0,04


AMB - aerobne mezofilne bakterije/aerobic mesophilic bacteria

KP - kvasci i plijesni/yeasts and moulds



Slika 1. Grafički prikaz podataka u prostoru razapetom faktorima 1 i 2 za mikrobiološki dobre i loše proizvode s obzirom na broj kvasaca i plijesni u svježem siru

Figure 1. Graphical representation of data in the space spread by the first and the second factor for products of microbiological desired and undesired quality with respect to number of yeasts and moulds in fresh cheese



Slika 2. Grafički prikaz podataka u prostoru razapetom faktorima 1 i 3 za mikrobiološki (DP) i (LP) s obzirom na broj kvasaca i plijesni u svježem siru

Figure 2. Graphical representation of data in the space spread by the first and the third factor for products of microbiological desired and undesired quality with respect to number of yeasts and moulds in fresh cheese

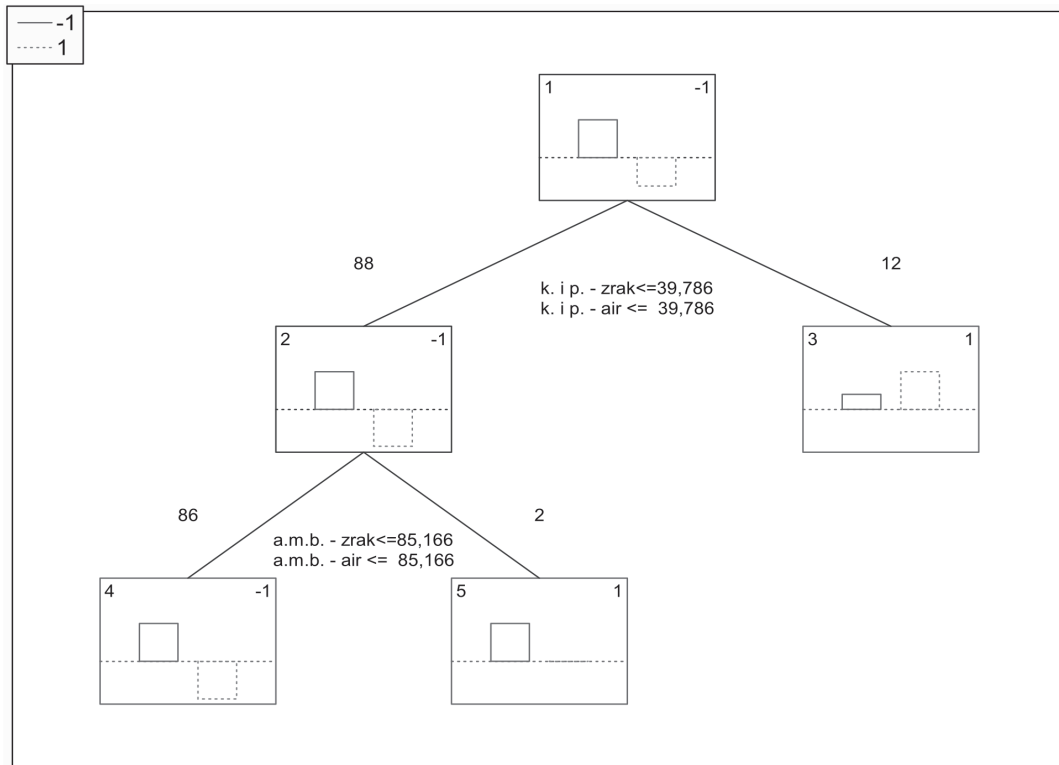
Prema tom kriteriju, prvom faktoru pripadaju varijable ukupnog broja AMB u zraku i ukupnog broja KP u zraku. Dakle, prvi faktor odnosi se na mikrobiološku čistoću zraka. Drugi faktor nosi 28,09 % ukupne varijacije podataka i odnosi se na ukupni broj AMB u ispirnoj vodi i pasteriziranom mlijeku. Treći faktor nosi 20,17 % ukupne varijacije podataka i odnosi se na ukupni broj KP u ispirnoj vodi. Prva tri faktora objašnjavaju 77,39 % varijacija mjerenih podataka. U zadnjem retku tablice dana je korelacija faktora s ciljnom varijablom ukupnog broja kvasca i plijesni u gramu svježeg sira. Vidi se da je prvi faktor u najjačoj korelaciji s ciljnom varijablom, zatim drugi i treći. Prema tome, najveći utjecaj na kvalitetu sira ima mikrobiološka čistoća zraka.

Slika 1 daje grafički prikaz podataka za dobre i loše proizvode s obzirom na broj kvasaca i pljesni u svježem siru u prostoru PC1 i PC2. Iz slike je vidljivo da su loši proizvodi nastali u uvjetima loše mikrobiološke čistoće zraka (faktor 1) i kod veće prisutnosti AMB u ispirnoj vodi i pasteriziranom mlijeku (faktor 2). U uvjetima loše mikrobiološke čistoće zraka ima i dobrih proizvoda, ali kod nižih vrijednosti AMB u is-

pirnoj vodi i pasteriziranom mlijeku. Dobri proizvodi se grupiraju u uvjetima dobre mikrobiološke čistoće zraka i kod nižih vrijednosti AMB u ispirnoj vodi i pasteriziranom mlijeku.

Slika 2 prikazuje podatke za dobre i loše proizvode u prostoru PC1 i PC3. Iz slike se može vidjeti da i treći faktor, koji se odnosi samo na varijablu KP u ispirnoj vodi, ima bitan utjecaj na kvalitetu proizvoda. Naime, mikrobiološki loši proizvodi dobiveni su kod većeg broja KP u ispirnoj vodi.

Slika 3 prikazuje stablo odlučivanja koje je generirano temeljem 100 primjera za formiranje modela koji su odabrani sistematskim izborom (svaki treći primjer je izuzet i korišten kao primjer za testiranje). Stablo je generirano algoritmom QUEST (Loh i Shih, 1997.) u programu Statistica 7.1. U gornjem lijevom kutu svakog čvora je njegov broj. U desnom gornjem kutu je klasa na koju se odnosi čvor (1=loši proizvodi, -1=dobri proizvodi). Važnije varijable su pri vrhu stabla. U ovom slučaju najvažnija varijabla kod određivanja KP u siru je KP u zraku. Granična vrijednost koja dijeli dobre od loših proizvoda



AMB- aerobne mezofilne bakterije, KP-kvasci, plijesni,

AMB – aerobic mesophilic bacteria, KP- yeasts and moulds,

Slika 3. Stablo odlučivanja generirano temeljem 100 primjera za učenje
Figure 3. Decision tree generated by 100 learning examples

ja 39,786 cfu KP u zraku. Vrijednost od 40 cfu KP u zraku izabrana je za interni standard temeljem ovog istraživanja. Od 100 uzoraka koji su korišteni za formiranje modela čak 86 dobrih proizvoda ima vrijednost broja KP u zraku nižu od te vrijednosti, a 12 loših proizvoda ima broj KP u zraku iznad te vrijednosti. Druga po važnosti je varijabla broj AMB u zraku koja od proizvoda nastalih u uvjetima gdje je broj KP u zraku manji od 39,786 izdvaja loše proizvode ako su nastali u uvjetima broj AMB u zraku veće od 85,166. Temeljem graničnih vrijednosti na granama čvorova prikazane na slici 3 određeni su interni standardi za varijable mikrobiološke kvalitete zraka u proizvodnom dijelu pogona.

Dobiveno stablo odlučivanja uspješno je klasificiralo 96 od 100 primjera za formiranje modela, a ista je preciznost klasifikacije postignuta i na primjerima za testiranje gdje je uspješno klasificirano 48 od 50 primjera. Podjednaka preciznost klasifikacije na primjerima za učenje i za testiranje svjedoči o dobroj kvaliteti dobivenog stabla odlučivanja. Dobiveno stablo je jednostavno i lako interpretabilno.

Zaključci

Metodom glavnih komponenta, s obzirom na broj kvasaca i plijesni u gramu sira, izdvojena su tri faktora koji predstavljaju oko 78 % ukupne varijacije podataka. To su: mikrobiološka kvaliteta zraka, broj aerobnih mezofilnih bakterija u ispirnoj vodi i pasteuriziranom mlijeku te ukupan broj kvasaca i plijesni u ispirnoj vodi.

Metodom stabla odlučivanja, kao najvažnija varijabla s obzirom na broj kvasaca i plijesni, u konačnom proizvodu izdvojen je broj kvasaca i plijesni u zraku, a kao druga po važnosti varijabla broj aerobnih mezofilnih bakterija u zraku. To su varijable koje čine prvi faktor dobiven metodom glavnih komponenta. Stablom odlučivanja dobivene su granične vrijednosti za te varijable koje dijele dobre od loših proizvoda. Granične vrijednosti izabrane za interne standarde u proizvodnji mikrobiološki ispravnih proizvoda su: broj kvasaca i plijesni u zraku manji od 40 i broj aerobnih mezofilnih bakterija u zraku manji od 85.

Analysis of variables that influence microbiological quality in fresh cheese production

Summary

In this research variables which influence microbiological quality in fresh cheese production with respect to yeasts and moulds were analyzed. Since yeasts and moulds do not survive the process of pasteurization their isolation in the final product is a result of their supplemental contamination during fermentation and whey drainage. Following variables were monitored: total number of aerobic mesophilic bacteria AMB in rinsing water, total number of yeasts and moulds in rinsing water, total number of AMB in pasteurized milk, total number of AMB in air and total number of yeasts and moulds in air. These variables were analysed by methods of descriptive statistics, principal component analysis, and the method of artificial intelligence - decision tree. By the method of principal component analysis it is shown that the greatest impact on the quality of the final product have variables connected to microbiological cleanness of air. The method of decision tree has resulted in determination of new internal standards for total number of AMB and yeasts and moulds in the air.

Key words: microbiological quality, principal components analysis, decision tree, fresh cheese, production

Literatura

1. Bertelli, D., Plessi, M., Sabatini, A.G., Lolli, M., Grillenzoni, F. (2007): Classification of Italian honeys by mid-infrared diffuse reflectance spectroscopy (DRIFTS), *Food Chemistry* 101, 1565-1570.
2. Carter, M., Elsner, J. (1997): A statistical method for forecasting rainfall over Puerto Rico, *Water and Forecasting* 12, 515-525.
3. El-Hofi, M., El-Tanboly, E.S., Ismail, A. (2010): Implementation of the hazard analysis critical control point (HACCP) system to white cheese production line, *Acta Scientiarum Polonorum Technologia Alimentaria* 9 (3), 331-342.
4. Elsner, G., Lehmilller, G., Kimberlain, T. (1999): Objective classification of Atlantic hurricanes, *Journal of Climate* 9, 2880-2889.
5. Forsythe, S.J. (1988): *The Microbiological Risk Assessment of Food*, Blackwell Science Ltd., Oxford, str. 35.
6. Hoque, M.O., Feng, Q.H., Toure, P., Dem, A., Critchlow, C.W., Hawes, S.E., Wood, T., Jeronimo, C., Rosenbaum, E., Stern, J., Yu, M.J., Trink, B., Kiviat, N.B., Sidransky, D. (2006): Detection of aberrant methylation of four genes in plasma DNA for the detection of breast cancer, *Journal of Clinical Oncology* 24, 4262-4269.
7. Jay, J.M. (2000): *Modern Food Microbiology*, 6.izd., Aspen Publishers, Inc. Gaithersburg, Maryland, str. 408.
8. Kannebley, G.S., Porto, G.S., Pazzelo, E.T. (2005): Characteristics of Brazilian innovative firms: An empirical analysis based on PINTEC - industrial research on technological innovation, *Research Policy* 34, 515-527.
9. Klančar, G., Škrjanc I. (2002): Metoda glavnih komponent pri odkrivanju in izolaciji napak: primer hidravličnega procesa in procesa fermentacije, *Elektrotehniški vestnik* 69 (5), 311-316.
10. Loh, W.Y., Shih, Y.S. (1997): Split selection methods for classification trees, *Statistica Sinica* 7, 815-840
11. Mahesh, P., Mather P.M. (2003): An assessment of the effectiveness of decision tree methods for land cover classification, *Remote Sensing Environment* 86, 554-565.
12. Manly, B.F.J. (1986): *Multivariate Statistical Methods: A primer*, Chapman and Hall, New York, str. 59.
13. Matijević, B., Blažić, M. (2008): Primjena spektroskopskih tehnika i kemometrijske metode u tehnologiji mlijeka, *Mljekarstvo* 58 (2), 151-169.
14. Pravilnik o mikrobiološkim standardima za namirnice (1994) *Narodne novine* 46, Zagreb.
15. Raspor, P. (2006): New dimensions of food safety, Book of Abstract of 2 Food Microbiology and Safety Congress, Bologna, str. 131.
16. Rencher, A.C. (2002): *Methods of Multivariate Analysis*, 2. izd., John Wiley & Sons, Inc., Nw York, str. 380.
17. Stabla odlučivanja http://dms.irb.hr/tutorial/hr_tut_dtrees.php (pristupljeno 30. svibnja 2008.)
18. Stahl, K. (2005): Influence of hydroclimatology and socioeconomic conditions on water-related international relations, *Water International* 30, 270-282.
19. StatSoft, Inc.USA (2008): STATISTICA (Data Analysis Software System) ver.7.1
20. Sim, M.Y.M., Shya, T.J., Ahmad, M.N., Shakaff, A.Y., Othman, A.R., Hitam, M.S. (2003): Monitoring of Quality With Disposable Taste Sensor, *Sensors* 3 (9), 340-349.
21. Yap Mee Sim, M., Jau Shya, T., Noor Ahmad, M., Md Shakaff, A.Y., Rahman Othman, A., Suzuri Hitam, M. (2003): Monitoring of Quality With Disposable, *Taste Sensor* 3, 340-349.