



THE INFLUENCE OF THE HEATING PROFILE OF THE VOC SENSOR ON THE CHARACTERISTICS OF NEURAL NETWORKS IN MILK CLASSIFICATION

UTJECAJ PROFILA ZAGRIJAVANJA HOS SENZORA NA KARAKTERISTIKE NEURONSKIH MREŽA PRI KLASIFIKACIJI MLIJEKA

Đokić, Kristian, *Fakultet turizma i ruralnog razvoja, Sveučilište Josipa Jurja Strossmayera u Osijeku, Požega, Hrvatska, kdokic@ftrr.hr*

Popović, Miroslav, *Brightlightness, Hrvatska, miroslav.popovic@brightlightness.com*

Radišić, Bojan, *Fakultet turizma i ruralnog razvoja, Sveučilište Josipa Jurja Strossmayera u Osijeku, Požega, Hrvatska, bradistic@ftrr.hr*

Abstract: Cow's milk is very sensitive to spoilage processes that can negatively affect its quality. Several methods have been developed for the analysis of milk spoilage, and more recently solutions using e-nose are becoming more common. This paper analyzes the possibility of using the Bosch BME688 (BioMedical Engineering) sensor for versatile organic compounds (VOC) detection for milk age classification, i.e. the influence of the sensor's heating profile on classification accuracy. Samples of fresh, pasteurized and UHT (Ultra High Temperature) sterilized milk that were at room temperature (22°C) during the 3-day experiment were tested. The data obtained for each day were used to train neural network-based models with the aim of distinguishing the type of milk with a known time after opening, i.e. milking. The focus of the research was on the analysis of the impact of the sensor heating profile on classification accuracy, so data was collected every day using two different heating profiles. The research results indicate that it is optimal to use different heating profiles, because different gases are released in different stages of milk aging, so greater accuracy was achieved with one profile in the first part of the experiment, while in the second part greater accuracy was achieved with another profile.

Keywords: BME688, e-nose, milk, machine learning, neural networks, heating profile.

Sažetak: Kravlje mlijeko vrlo je osjetljivo na procese kvarenja koji mogu negativno utjecati na njegovu kvalitetu. Razvijeno je više metoda za analizu kvarenja mlijeka, a u novije vrijeme sve su češća rješenja pomoću e-nosa. U ovom se radu analizira mogućnost korištenja senzora za detekciju hlapivih organskih spojeva (HOS) Bosch BME688 (BioMedical Engineering) za klasifikaciju starosti mlijeka, odnosno utjecaj profila zagrijavanja senzora na točnost klasifikacije. Ispitani su uzorci svježeg, pasteuriziranog i UHT (Ultra High Temperature) steriliziranog mlijeka koji su bili na sobnoj temperaturi (22°C) tijekom 3-dnevnog pokusa. Dobiveni podaci za svaki dan korišteni su za treniranje modela temeljenih na neuronskoj mreži s ciljem razlikovanje vrste mlijeka s poznatim vremenom nakon otvaranja, odnosno mužnje. Fokus istraživanja bio je na analizi utjecaja profila zagrijavanja senzora na točnost klasifikacije, pa su podaci svakog dana prikupljeni uz korištenje dva različita profila zagrijavanja. Rezultati istraživanja ukazuju da je optimalno koristiti različite profile zagrijavanja, jer se u različitim fazama starenja mlijeka oslobađaju različiti plinovi, tako da se veća točnost postizala sa jednim profilom u prvom dijelu pokusa, dok se u drugom veća točnost postizala sa drugim profilom.

Ključne riječi: BME688, e-nos, mlijeko, strojno učenje, neuronske mreže, profil zagrijavanja

1. Uvod

Kravlje mlijeko podložno je procesima kvarenja koji mogu štetno utjecati na njegovu kvalitetu, a pri čemu dolazi do razvoja neugodnih mirisa uzrokovanih kemijskom razgradnjom. Brza identifikacija može ublažiti ovaj problem i osigurati sigurnost i kvalitetu hrane. Tijekom procesa kvarenja nastaju različiti hlapljivi organski spojevi (*HOS*), što rezultira razvojem specifičnih mirisa koji signaliziraju pad kvalitete. Stoga prepoznavanje ovih znakova kvarenja može pomoći u otkrivanju promjena u kvaliteti.

U ovom radu korišten je modul BME (BioMedical Engineering) Development Kit, opremljen s osam Bosch BME688 senzora sposobnih detektirati različite plinove analizom njihovih jedinstvenih „elektroničkih potpisa“. Modul je korišten za provođenje eksperimenta na uzorcima mlijeka, i to svježeg mlijeka, pasteriziranog mlijeka i steriliziranog mlijeka na visokim temperaturama. Zadnje navedeno se u literaturi u pravilu naziva kraticom UHT (*ultra high temperature*). Uzorci mlijeka održavani su na konstantnoj temperaturi od 22 °C tijekom 3 dana trajanja pokusa. Mjerenje je obavljeno svakog dana u isto vrijeme u intervalima od 20 minuta za svaki od tri navedena uzorka, pri čemu se koristila i prazna Erlenmeyerova tikvica koja je predstavljala četvrti kontrolni uzorak. Istraživanje je prvenstveno usmjereno na analizu utjecaj dva različita profila zagrijavanja senzora na točnost klasifikacije, tako da je opisano mjerenje svakog dana obavljeno sa dva različita profila zagrijavanja senzora. Očekuje se da za ovu primjenu jedan od dva izabrana profila zagrijavanja senzora daje veću točnost i vrijednost F1 za mjerenja obavljena u sva 4 dana, a istraživanjem će se utvrditi koji je to profil. Mjera F1 je jedna od mjera točnosti modela strojnog učenja. Prikupljeni podaci korišteni su za treniranje osam modela za klasifikaciju kako bi se točno identificirala vrsta mlijeka na temelju proteklog vremena od otvaranja, odnosno mužnje. Proizvođači senzora ugradili su mogućnost treniranja i kasnijeg korištenja neuronske mreže u aplikaciju BME AI-Studio, koja se koristila u radu.

Ovaj rad se sastoji od pet dijelova. Nakon uvoda, dana je analiza postojeće literature, pri čemu je dan pregled korištenja senzora BME688 u radovima drugih autora, te korištenje algoritama umjetne inteligencije u detekciji kvarenja kravljeg mlijeka. Nakon toga u trećem dijelu je opisana metodologija istraživanja, a u četvrtom je opisano treniranje i rezultati mjerenja. U posljednjem petom dijelu je rasprava i zaključci.

2. Pregled literature

Pregled literature podijeljen je u dva dijela. Prvi dio uključuje radove koji opisuju mogućnosti korištenja umjetne inteligencije u detekciji kvarenja mlijeka koristeći različite senzore, a drugi daje pregled radova u kojima se koristi senzor Bosch BME688 za različite namjene.

2.1. Umjetna inteligencija za detekciju kvarenja mlijeka

Početakom 2000-ih, troslojna neuronska mreža je upotrijebljena za otkrivanje bakteriološki neispravnih uzoraka mlijeka. Četrnaest vodljivih polimernih senzora korišteno je u njihovoj verziji e-nosa. Autori ne navode jesu li ispravnost modela procjenjivali pomoću skupa testnih podataka, što možda nije bio uobičajeni postupak u to vrijeme. Unatoč tome, oni predlažu da primjena neuronskih mreža i tehnologije e-nosa ima potencijal za dalji napredak u razvoju novih, učinkovitih i brzih sustava kontrole kvalitete za sektor mlijeka (Magan, et al., 2001).

U literaturi se između ostalih susreću dvije specifične metodologije za kategorizaciju kvarenja mlijeka. Obje metode koriste fotografije uzoraka, međutim, razlika leži u činjenici da jedna koristi konvencionalne fotografije, dok druga koristi slike snimljene termalnom kamerom. Autori predlažu

korištenje konvolucijske neuronske mreže za klasificiranje slika, što rezultira točnošću od 99% za obične slike i 98% točnosti za termalne fotografije. Predloženi model ima značajno višu razinu točnosti u usporedbi s VGG16, VGG19 i ResNet (Nur Farzanah Faghira Kamarudin, et al., 2024).

Pojedini autori bave se sveobuhvatnom analizom tehnika koje se koriste u praćenju kvalitete mlijeka i otkrivanju kvarenja. Jedan od radova dolje spomenutih autora sadrži poseban dio koji govori o korištenju tehnologije e-nosa. Autori daju primjere različitih primjena, kao što je razlikovanje svježeg i pokvarenog mlijeka na temelju aktivnosti mikroba, kategoriziranje mlijeka na temelju broja mikroba, grupiranje mlijeka prema sezoni u kojoj je proizvedeno, otkrivanje neugodnih okusa kako bi se osigurala kvaliteta mlijeka, određivanje roka trajanja mlijeka, razlikovanje UHT i pasteriziranog mlijeka, prepoznavanje normalnih i abnormalnih mirisa u UHT mlijeku, razlikovanje mlijeka iz različitih mljekara na temelju sadržaja masti, određivanje podrijetla mlijeka, prepoznavanje kontaminiranog mlijeka i razlikovanje zdravog mlijeka od mlijeka krava s mastitisom. Nadalje, autori navode algoritme koji se koriste za obradu dobivenih podataka korištenjem e-nosa (analiza glavnih komponenti, neuronske mreže i neizrazita logika) (Poghossian, et al., 2019).

U literaturi je predstavljena i brza metoda za predviđanje ukupne populacije bakterija u mlijeku integracijom tehnologije e-nosa s neuronskom mrežom. Kvalitativni model postigao je stopu točnosti od 100% u identificiranju uzoraka mlijeka s visokim, umjerenim ili niskim razinama ukupnog broja bakterija i za podskupine testa i za validaciju. Iznimno visok koeficijent višestruke determinacije ($R^2 > 0,99$) utvrđen je između projiciranih vrijednosti ukupnog broja bakterija generiranih kvantitativnim modelom i referentnih vrijednosti. Rezultati studije pokazali su da je korištenje umjetnih neuronskih mreža i tehnologije e-nosa dalo precizne prognoze ukupnog broja bakterija u mlijeku (Yang & Wei, 2021).

2.2. Korištenje senzora BME688

BME688 se susreće u nekim radovima, na primjer za klasifikaciju svježine hrane na temelju njezinog mirisa. Autori predlažu korištenje više stupanjskog klasifikatora, koji početno kategorizira hranu u četiri klase, zatim dodjeljuje oznaku hrane odgovarajućoj kategoriji i na kraju određuje njezinu svježinu. Autori su upotrijebili BME AI Studio za prikupljanje podataka i izdvajanje karakteristika, nakon čega su trenirali modele stabla odlučivanja, višeslojnog perceptrona i konvolucijsku neuronsku mrežu (Xu, et al., 2021).

BME688 drugi autori koriste za kvantificiranje indeksa kvalitete zraka u istraživanju učinkovitosti zeolita za uklanjanje hlapljivih organskih spojeva tijekom procesa ekstruzije reciklirane plastike. BME688 se koristi za mjerenje kombinirane količine hlapivih organskih spojeva i onečišćujućih tvari prisutnih u zraku. Nakon prikupljanja sirovih podataka, autori su koristili odgovarajući algoritam za pretvaranje sirovih numeričkih podataka u indeks kvalitete zraka (IAQ). IAQ ljestvica se kreće od 500, što predstavlja visoko kontaminirani zrak, do 0, što označava čist zrak. Autori su koristili IAQ kao dokaz u prilog svom konceptu (Garofalo, et al., 2023).

Pojedini autori uspoređivali su BME688 sa drugim sensorima, pa su otkrili da senzor BME688 pokazuje bolju reakciju na mravlju kiselinu, a senzor SGP41 je bolji za 9 od 10 ispitanih hlapivih organskih spojeva. Nadalje, senzor SGP41 može detektirati sva VOC otapala koja se koriste i imaju volumen veći od 100 μL na obje ispitne udaljenosti. Na udaljenostima od 40 cm i 100 cm, BME688 nije uspio detektirati alarmni prag za heksan, toluen, benzen, dietil eter i heksan (Neubert, et al., 2021).

Senzor BME688 je u nekim istraživanjima uspoređivan sa drugim sensorima u analizi kvalitete zraka. Autori ističu problem skupih senzora i potencijalnu netočnost korištenja CO_2 senzora kao mjere kvalitete zraka. Prema autorima, nedostaci trenutno dostupnih senzora su dugotrajna kalibracija i mjerenje, što u određenim situacijama otežava prikupljanje podataka u stvarnom vremenu. Unatoč

tome, autori tvrde da najnoviji plinski senzori dostupni na tržištu olakšavaju uspostavu isplativih i pouzdanih sustava za praćenje kvalitete zraka (Marinov, et al., 2021).

BME688 se osim navedenog koristio i za promatranje pčela kada grinja *Varroa* napadne pčelinju zajednicu. Autori su košnicu opremili sensorima koji konstantno prate razinu kiselosti. To omogućuje ugradnju automatizirane opreme, što rezultira stabilnijom terapijom protiv varoe (Senger, et al., 2023).

Provedena je i studija u kojoj su autori razvili osobni monitor izloženosti za procjenu štetnih učinaka zagađivača na ljudsko zdravlje. Autori predstavljaju jeftin sustav otvorenog koda sastavljen od lako dostupnih komponenti. Uređaj je namijenjen za nošenje oko vrata radi kontinuiranog praćenja, što može biti korisno za praćenje osobne izloženosti zagađivačima, a i za epidemiološka istraživanja. Namjena uređaja je mjerenje i praćenje razine ugljikovog monoksida, ugljikovog dioksida, ozona, sumporovodika, temperature, tlaka, kretanja, te koncentracije hlapljivih organskih spojeva. Dodatno, sposoban je mjeriti broj čestica u zraku u različitim rasponima veličina, uključujući PM_{0,5}, PM_{1,0}, PM_{2,5}, PM_{4,0} i PM₁₀ (onečišćenje česticama). Senzor BME688 je sastavni dio uređaja (Yetkin, et al., 2023).

Korištenjem senzora BME688 dizajniran je uređaj koji procjenjuje kvalitetu zraka. Uređaj se razlikuje od sličnih jer iskorištava električnu energiju iz razlike u temperaturi između tla i zraka korištenjem termoelektričnog generatora. Studija predstavlja matematički model koji simulira ponašanje bežičnih senzorskih mreža u okruženju. Simulacija uključuje model senzora koji se napaja istosmjernom strujom pojačanom pretvaračem kroz termoelektrični generator. Simulacija emulira procese prikupljanja podataka, prijenosa podataka i upravljačkih algoritama. Studija prati broj radnih ciklusa uređaja, potrošnju energije, trajanje pražnjenja, kvarove i dodatne troškove (Paterova, et al., 2021).


Senzor BME688 je isto tako korišten u istraživanju primjene senzora za otkrivanje opasnih plinova, koji se mogu pojaviti u slučaju nesreće ili istjecanja. Kako bi kontinuirano pratili ukupne hlapljive organske spojeve, autori su koristili BME688 i SGP30 senzore. Prema nalazima autora, opisani senzori su prikladni za rano otkrivanje para otapala u laboratorijima. Na reakciju senzora i primjenjivost sustava utječu uspostavljene veze, udaljenost između čvora senzora i izvora pare te brzina automatiziranog sustava dojava (Neubert, et al., 2021).

3. Metodologija i mjerenje

Senzor BME688 elektronički je uređaj koji može otkriti različite plinove, a proizvođač je omogućio da promjenom parametara detekcije prilagodimo senzor željenom plinu. Da bi se to uspješno odradilo, bitno je podvrgnuti ga različitim sastavima plina tijekom procesa prilagođavanja i treniranja. Za senzor BME688 proizvođač navodi slijedeće prednosti:

- optimalna energetska učinkovitost
- male dimenzije
- povećana osjetljivost i razlučivanje kada je izložen raznolikom nizu plinova
- osjetljivost i selektivnost se mogu podešavati tijekom rada.
- mogućnost mjerenja temperature, relativne vlažnosti i tlaka.

BME Board x8, koji se ponekad naziva i BME Development Kit, modul je koji dolazi s osam BME688 senzora posebno dizajniranih za provođenje eksperimenata. Ovaj modul olakšava istovremeno testiranje i prikupljanje podataka uz korištenje više različitih konfiguracija. To poboljšava točnost i smanjuje duljinu procesa razvoja. Podaci se čuvaju na vanjskoj Micro SD (*Secure Digital*) kartici, koja se može umetnuti u sam modul. Modul je vidljiv na slici 1 (www.bosch-sensortec.com, 2024).




Slika 1 - BME razvojna ploča (Izvor: autori)

Senzor BME688 koristi metalni oksid, kao što je SnO_2 , koji se zagrijava na temperature iznad 300°C za detekciju plinova. Molekule kisika lijepe se na površinu metalnog oksida i privlače elektrone, kao što je O^- . Plinovi koji imaju redukcijska svojstva, kao što je ugljični monoksid (CO), reagiraju s molekulama kisika kako bi proizveli plinoviti ugljični dioksid (CO_2), što dovodi do povećanja električne vodljivosti. Senzor tlaka koristi piezo-električnu tehnologiju za pretvaranje promjena tlaka u električni naboj, koji se zatim koristi za određivanje temperature. Senzor vlažnosti sastoji se od polimera koji mijenja svoju otpornost kao odgovor na promjene u razinama vlažnosti. Osam senzora BME688 se vide na modulu na slici 1 (www.bosch-sensortec.com, 2024).

Unutrašnjost senzora BME688 izložena je temperaturnim fluktuacijama na način da se unutar senzora nalazi mali grijač koji se može kontrolirati softverski. Promjena temperature se provodi tijekom ciklusa skeniranja. Unutrašnjost senzora može se zagrijati na jednu od deset unaprijed određenih temperatura, na temelju odabranog profila grijača. Površinski kemijski sastav komponente senzora razlikuje se ovisno o određenom načinu zagrijavanja koji se koristi tijekom ciklusa skeniranja. Osjetljivost i selektivnost senzora ovise o profilu grijača. Odabir prikladne konfiguracije grijača prema pojedinačnoj primjeni ključan je za postizanje najboljih performansi senzora. To se postiže sekvencijalnim procesom koji se sastoji od 10 različitih faza. Slike 2 i tablica 1 prikazuju profil zagrijavanja HP-354, dok slika 3 i tablica 2 prikazuju profil zagrijavanja HP-504. Navedeni profili zagrijavanja korišteni su u ovom radu, mada aplikacija BME AI-Studio nudi više različitih gotovih profila.


HP-354



Slika 2 – Grafički prikaz profila zagrijavanja HP-354 (Izvor: autori)

Tablica 1 – Temperaturne vrijednosti profila zagrijavanja HP-354 (Izvor: autori)


Korak	Vrijeme	Temperatura
1	0,7s	320°C
2	0,98s	100°C
3	2,38s	100°C
4	6,58s	100°C
5	7,28s	200°C
6	7,98s	200°C
7	8,68s	200°C
8	9,38s	320°C
9	10,08s	320°C
10	10,78s	320°C

HP-504**Slika 3 - Grafički prikaz profila zagrijavanja HP-504 (Izvor: autori)****Tablica 2 - Temperaturne vrijednosti profila zagrijavanja HP-504 (Izvor: autori)**

Korak	Vrijeme	Temperatura
1	3,36s	210°C
2	3,64s	265°C
3	6,72s	265°C
4	7s	320°C
5	10,08s	320°C
6	13,44s	265°C
7	16,8s	210°C
8	20,16s	155°C
9	23,52s	100°C
10	26,88s	155°C


Nakon završetka svakog koraka, mjerenje se dokumentira i sprema na SD karticu modula.

Radni ciklus kombinacija je ciklusa skeniranja i ciklusa mirovanja. Ciklus skeniranja odnosi se na jednu iteraciju profila zagrijavanja. Duljina svakog ciklusa skeniranja može se utvrditi uzimajući u obzir vremenski okvir korištenog profila grijača. Ciklus mirovanja može se definirati kao interval tijekom kojeg senzor ostaje u stanju mirovanja i ne provodi nikakva mjerenja. Ukupno trajanje radnog ciklusa izravno utječe na vrijeme odziva algoritma. Slika 4 prikazuje primjer radnog ciklusa od 5 ciklusa skeniranja i 10 ciklusa mirovanja.



Slika 4 – Radni ciklus mjerenja (Izvor: autori)

Osim definiranja radnog ciklusa moguće je za različite senzore na modulu postaviti različite profile zagrijavanja. U ovom istraživanju ta mogućnost nije korištena i svi senzori su se zagrijavali u skladu sa jednim izabranim profilom. Sam softver omogućuje izbor i paralelno korištenje četiri profila, što ubrzava razvoj i pronalaženje najoptimalnijeg profila zagrijavanja senzora za željenu aplikaciju. Na slici 5 je slika sučelja programa BME AI-Studio sa postavkama modula.



Slika 5 – Sučelje programa BME AI-Studio s postavkama modula (Izvor: autori)

Korišteni uzorci od po 200 ml mlijeka dobiveni su iz tri različita izvora. Prvi uzorak uzet je od lokalnog proizvođača mlijeka i sastoji se od svježeg mlijeka bez dodatne obrade. Drugi uzorak sastojao se od pasteriziranog mlijeka koje je kupljeno u lokalnoj trgovini i imalo je rok trajanja od 10 dana. Treći uzorak je trajno tzv. UHT mlijeko koje ima rok trajanja od 6 mjeseci. Nadalje, prazna


Erlenmeyerova tikvica korištena je kao četvrti uzorak, odnosno slijepa proba. BME Development Kit modul umetnut je u svaki od četiri tikvice s uzorkom u trajanju od 20 minuta, tijekom kojih su podaci dokumentirani na SD kartici modula. Mjerenje je ponavljano u intervalima od 24 sata, što je rezultiralo prikupljanjem podataka u rasponu od 3 dana. Slika 6 prikazuje uzorke u tikvicama koji su pohranjeni na sobnoj temperaturi.




Slika 6 – Uzorci mlijeka u tikvicama (Izvor: autori)

4. Treniranje i rezultati

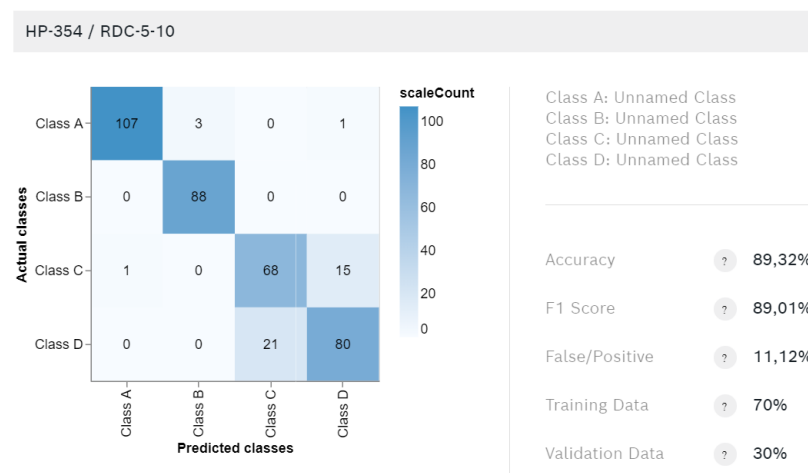
Kao što je navedeno, svakog dana prikupljeno je po dva skupa podataka, sa različitim profilima zagrijavanja senzora (HP-354 i HP-504). Svaki skup sastojao se od 80 minuta mjerenja, pri čemu je modul bio u svakoj tikvici po 20 minuta. S tim podacima trenirano je osam neuronskih mreža za klasifikaciju uzoraka. U nastavku su matrice konfuzije dobivene iz samog programa BME AI Studio nakon treniranja neuronskih mreža. Na slikama od 7 do 14 se osim matrica konfuzije vide i prethodno opisane klase (Air, Sirovo, Svježe i Trajno), kao i ostali podaci o treniranim neuronskim mrežama (Točnost, F1-mjera, Postotak lažno pozitivnih rezultata, Postotak podataka za treniranje, Postotak podataka za validaciju).




Slika 7 – Matrica konfuzije i ostali podaci o neuronskoj mreži treniranoj na podacima prvog dana uz profil grijanja HP-354 (Izvor: autori)




Slika 8 - Matrica konfuzije i ostali podaci o neuronskoj mreži treniranoj na podacima prvog dana uz profil grijanja HP-504 (Izvor: autori)




Slika 9 - Matrica konfuzije i ostali podaci o neuronskoj mreži treniranoj na podacima drugog dana uz profil grijanja HP-354 (Izvor: autori)




Slika 10 - Matrica konfuzije i ostali podaci o neuronskoj mreži treniranoj na podacima drugog dana uz profil grijanja HP-504 (Izvor: autori)




Slika 11 - Matrica konfuzije i ostali podaci o neuronskoj mreži treniranoj na podacima trećeg dana uz profil grijanja HP-354 (Izvor: autori)



Slika 12 - Matrica konfuzije i ostali podaci o neuronskoj mreži treniranoj na podacima trećeg dana uz profil grijanja HP-504 (Izvor: autori)



Slika 13 - Matrica konfuzije i ostali podaci o neuronskoj mreži treniranoj na podacima četvrtog dana uz profil grijanja HP-354 (Izvor: autori)




Slika 14 - Matrica konfuzije i ostali podaci o neuronskoj mreži treniranoj na podacima četvrtog dana uz profil grijanja HP-504 (Izvor: autori)

U tablici 3 su prikupljeni podaci svih osam neuronskih mreža. U redovima sa bijelom pozadinom su podaci dobiveni uz korištenje profila zagrijavanja HP-354, dok su redovi sa sivom pozadinom dobiveni uz korištenje profila zagrijavanja HP-504.

Tablica 3 – Karakteristike svih 8 neuronskih mreža (Izvor: autori)


Redni broj	Profil zagrijavanja	Točnost	F1	Netočno/ Pozitivni	Podaci za treniranje	Podaci za testiranje
1	HP-354	78,01%	78,33%	21,67%	70%	30%
2	HP-504	68,52%	67,67%	32,33%	70%	30%
3	HP-354	89,32%	89,01%	10,99%	70%	30%
4	HP-504	87,85%	86,19%	13,81%	70%	30%
5	HP-354	99,44%	99,46%	0,54%	70%	30%
6	HP-504	100,00%	100,00%	0%	70%	30%
7	HP-354	88,27%	88,76%	11,24%	70%	30%
8	HP-504	99,11%	99,07%	0,93%	70%	30%

Na slici 15 je grafikon koji prikazuje točnost neuronskih mreža, pri čemu su plavim stupcima prikazane vrijednosti dobivene korištenjem profila zagrijavanja HP-354, dok se narančastim stupcima prikazuju vrijednosti dobivene korištenjem profila zagrijavanja HP-504.



Slika 15 – Grafikon sa tačnošću svih osam neuronskih mreža (Izvor: autori)

Na slici 16 je grafikon koji prikazuje vrijednosti F1 svih 8 neuronskih mreža, pri čemu su plavim stupcima prikazane vrijednosti dobivene korištenjem profila zagrijavanja HP-354, dok se narančastim stupcima prikazuju vrijednosti dobivene korištenjem profila zagrijavanja HP-504.



Slika 16 – Grafikon sa tačnošću svih osam neuronskih mreža (Izvor: autori)

5. Zaključci

BME AI Studio omogućuje izbor od čak 17 različitih profila zagrijavanja grijača. U trenutnoj verziji ne nudi se samostalno kreiranje profila, ali vjerojatno je da će ta mogućnost biti dostupna u novijim verzijama softvera. Kao što je prethodno navedeno u ovom radu korištena su dva profila zagrijavanja (HP-354 i HP-504), a autori su očekivali da će korištenje jednog od profila rezultirati većom tačnošću za sve četiri neuronske mreže bazirane na tim podacima. Rezultati su demantirali tu hipotezu i očigledno je da profil HP-354 daje neuronske mreže sa većom tačnošću za prvi i drugi dan

mjerenja, dok profil HP-504 daje neuronske mreže sa većom tačnošću za treći i četvrti dan mjerenja. Očigledno se u procesu kvarenja mlijeka pojavljuju razni plinovi na koje je senzor uz korištene profile zagrijavanja više, odnosno manje osjetljiv.

Može se zaključiti da izbor samo jednog profila zagrijavanja nije optimalno rješenje, a idealno bi bilo prilagođavati profil zagrijavanja plinu, odnosno aplikaciji. Trenutno to nije moguće jer nije podržano u softveru BME AI Studio, ali proizvođači navode da će se softver doradivati na osnovu potreba korisnika. Spomenuti softver nije otvorenog koda, tako da nisu moguće izmjene što donekle usporava primjenu samih senzora.

Ovim istraživanjem analizirao se utjecaj profila zagrijavanja na karakteristike neuronskih mreža koje služe za klasifikaciju starosti različitih vrsta mlijeka. Samo istraživanje dio je projekta kojem je cilj istražiti mogućnosti primjene e-nosa i strojnog učenja za klasifikaciju jestivih namirnica, pri čemu je naglasak dan na senzore hlapivih organskih spojeva. Dalja istraživanja bit će usmjerena na usporedbu i optimizaciju različitih algoritama za kreiranje modela za klasifikaciju, kao i analizu ostalih profila zagrijavanja.

6. Literatura

1. Al-Okby, M. F. R., Roddelkopf, T., Fleischer, H. & Thurow, K., 2022. Evaluating a Novel Gas Sensor for Ambient Monitoring in Automated Life Science Laboratories. *Sensors*, Svezak 22, p. 8161.
2. Garofalo, E. i dr., 2023. Assessment of Melt Compounding with Zeolites as an Effective Deodorization Strategy for Mixed Plastic Wastes and Comparison with Degassing. *Polymers*, Svezak 15, p. 1858.
3. Magan, N., Pavlou, A. & Chrysanthakis, I., 2001. Milk-sense: a volatile sensing system recognises spoilage bacteria and yeasts in milk. *Sensors and Actuators B: Chemical*, Svezak 72, p. 28–34.
4. Marinov, M. B., Ganev, B. T. & Nikolov, D. N., 2021. *Indoor air quality assessment using low-cost commercial off-the-shelf sensors*. s.l., an., p. 1–4.
5. Neubert, S. i dr., 2021. Flexible IoT gas sensor node for automated life science environments using stationary and mobile robots. *Sensors*, Svezak 21, p. 7347.
6. Nur Farzanah Faghira Kamarudin, P., Mohd Zarifie Hashim, N., Mat Ibrahim, M. & Dwi Sulistiyo, M., 2024. Milk Spoilage Classification through Integration of RGB and Thermal Data Analysis. *International Journal of Computing and Digital Systems*, Svezak 16, p. 1–10.
7. Paterova, T. i dr., 2021. Environment-monitoring IoT devices powered by a TEG which converts thermal flux between air and near-surface soil into electrical energy. *Sensors*, Svezak 21, p. 8098.
8. Poghossian, A., Geissler, H. & Schöning, M. J., 2019. Rapid methods and sensors for milk quality monitoring and spoilage detection. *Biosensors and Bioelectronics*, Svezak 140, p. 111272.
9. Senger, D. i dr., 2023. Evaluating and optimising formic acid treatment against varroa mites on honey bees with MOx-sensors and a control loop. *Smart Agricultural Technology*, Svezak 6, p. 100342.
10. Vasafi, P. S. i dr., 2021. Anomaly detection during milk processing by autoencoder neural network based on near-infrared spectroscopy. *Journal of Food Engineering*, Svezak 299, p. 110510.
11. www.bosch-sensortec.com, 2024. *Gas Sensor BME688*. [Mrežno]
Available at: <https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bme688-ds000.pdf> [Pokušaj pristupa 15 March 2024].

12. Xu, A., Cai, T., Shen, D. & Wang, A., 2021. Food Odor Recognition via Multi-step Classification. *arXiv preprint arXiv:2110.09956*.
13. Yang, Y. & Wei, L., 2021. Application of E-nose technology combined with artificial neural network to predict total bacterial count in milk. *Journal of Dairy Science*, Svezak 104, p. 10558–10565.
14. Yetkin, O. i dr., 2023. *HYPER-LOCAL AIR ZONE EVALUATOR (HAZE): AN OPEN SOURCE SYSTEM FOR PERSONAL ENVIRONMENTAL EXPOSURE MONITORING*. s.l., an., p. V001T04A003.