

SAŽETAK

Umjetna inteligencija (AI) i strojno učenje (ML) sve su prisutniji u poljoprivrednom sektoru pa tako i u proizvodnji krmnih smjesa, gdje omogućuju proizvođačima optimizaciju procesa proizvodnje, smanjenje troškova i poboljšanje učinkovitosti. Implementacija nelinearnih modela, poput umjetnih neuronskih mreža (UNM), u ovoj domeni omogućava prepoznavanje uzoraka i rješavanje kompleksnih problema povezanih s krmnim smjesama. Primjena UNM u tehnologiji proizvodnje krmnih smjesa, uz ispravno odabranu strukturu, algoritme učenja i prijenosne funkcije, omogućava naprednu optimizaciju procesa, uključujući upravljanje proizvodnim postrojenjem, skladištenje i transport sirovina. Ovi modeli pružaju nove mogućnosti za poboljšanje kvalitete krajnjeg proizvoda, uzimajući u obzir sve faktore koji na nju utječu. Kroz ovu prilagodbu, AI pruža alate za brzo i učinkovito donošenje odluka, što rezultira poboljšanom automatizacijom i učinkovitosti u proizvodnji krmnih smjesa.

Ključne riječi: umjetna inteligencija, strojno učenje, optimizacija, modeliranje, krmne smjese.

UVOD

Poljoprivredna proizvodnja osigurava osnovne potrebe čovječanstva. Tijekom zelene revolucije, uvođenjem novih poljoprivrednih tehnika u prošlom stoljeću, poljoprivrednoj proizvodnji je omogućeno držati korak s rastućim zahtjevima za hranom i drugim poljoprivrednim proizvodima. Uz sve veće prepoznavanje negativnog utjecaja na okoliš, nove tehnike i pristupi trebali bi moći zadovoljiti buduće potrebe za proizvodnju hrane kao i smanjenje negativnih utjecaja na okoliš (Sishodia i sur., 2020.). Razumijevanje upravljanja u poljoprivrednim procesima podrazumijeva razmatranja velikog bro-

ja varijabli te spada u jedno od najtežih područja statističke kvantifikacije. Unatoč većoj produktivnosti, poljoprivredni sektor suočava se s novim izazovima. Umjetna inteligencija u poljoprivredi omogućava poljoprivrednicima stvaranje strategija upravljanja putem „precizne poljoprivrede“ za maksimiziranje rezultata (Linaza i sur., 2021.).

Internet stvari (eng. Internet of things – IoT) rezultirao je velikom količinom podataka u opticaju, koji se često nazivaju „velikim skupovima podataka“, koji donose nove mogućnosti praćenja u području poljoprivredno prehrambene proizvodnje. Suvremeni poljoprivredni sustavi proizvodnje hrane

Izv. prof. dr. sc. Ante Galić, e-mail: agalic@agr.hr, orcid.org/0000-0003-3655-4171; Prof. dr. sc. Stjepan Plietić, e-mail: splietic@agr.hr; Izv. prof. dr. sc. Igor Kovačev, e-mail: ikovacev@agr.hr, orcid.org/0000-0002-0392-1089; Doc. dr. sc. Krešimir Čopec, e-mail: kcopec@agr.hr, orcid.org/0000-0002-3568-994X; Ivan Brandić, mag. ing. agr. e-mail: ibrandic@agr.hr; Agronomski fakultet Sveučilišta u Zagrebu, Svetošimunska cesta 25, 10000 Zagreb, Hrvatska

suočavaju se sa sve većim pritiscima klimatskih promjena poput; dostupnosti vode i tla. Navedeni faktori predstavljaju prijetnju ekološkoj i ekonomskoj održivosti trenutnih i budućih sustava opskrbe hranom. Stoga su znanstvene i tehnološke inovacije nužne za proizvodnju dovoljne količine hrane, kako za ljudsku tako i za životinjsku konzumaciju (Jung i sur., 2021.). Korištenjem umjetne inteligencije u poljoprivredi moguće je optimizirati proces proizvodnje pomoću prediktivne analize, analize slika, tehnike učenja i analize uzoraka (Awasthi, 2020.). Umjetna inteligencija (AI) proučava se desetljećima i još uvijek je jedna od najzanimljivijih tema u suvremenoj znanosti. Pojam umjetne inteligencije prvi je uvrstio John McCarthy 1956. godine kada je održana prva znanstvena konferencija na tu temu. Glavni napredak posljednjih desetljeća nalazi se u pronalasku algoritama za pretraživanje, strojnog učenja kao i integracija statističkih analiza na sva istraživana područja (Shaw, 2001.). Prema Valerjevu (2006.), četiri kategorije koje određuju umjetnu inteligenciju su:

1. djelovanje poput ljudi (Turingov test),
2. mišljenje poput ljudi (kognitivno modeliranje),
3. racionalno mišljenje (zakon mišljenja),
4. racionalno djelovanje (racionalni agenti).

Proizvodnja krmnih smjesa već duže vrijeme predstavlja zanimljivo područje za primjenu suvremenih tehnologija. Jedan od glavnih razloga tome je sprječavanje pojava incidentnih situacija, kao što su:

- kontaminacija sirovina bakterijama, mikotoksinama ili drugim štetnim tvarima što može dovesti do zdravstvenih problema kod životinja koje konzumiraju takvu hranu;
- prisutnost antibiotika u krmnim smjesama što za posljedicu može imati razvoj rezistencije na antibiotike kod životinja, prenošenje rezistentnih bakterija na ljude putem hrane te smanjenje učinkovitosti antibiotika u liječenju bolesti kod životinja i ljudi;
- greške prilikom formulacije hrane za životinje, kao što su pogrešni omjeri hranjivih tvari ili dodavanje nedopuštenih sastojaka, mogu utjecati na prehrambenu vrijednost hrane i zdravlje životinja;
- nepropisna obrada hrane, poput nedovoljnog zagrijavanja ili nedostatne sterilizacije što može rezultirati prisutnošću patogenih mikroorganizama koji mogu uzrokovati bolesti kod životinja;

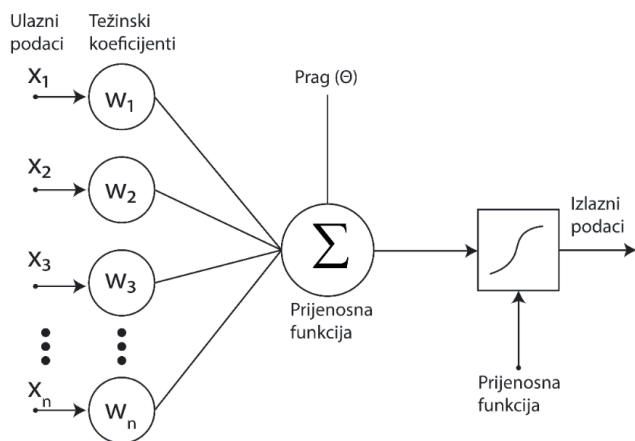
- kontaminacija tijekom proizvodnje;
- neispravno pakiranje ili neadekvatno skladištenje koje može dovesti do gubitka hranjivih tvari i povećanog rizika od kontaminacije;
- loša kvaliteta sirovina koja može rezultirati nedostatkom hranjivih tvari, slabom prehrambenom vrijednošću smjese i potencijalno lošim zdravstvenim učincima na životinje;
- nedovoljno pridržavanje propisa i standarda što može dovesti do kršenja sigurnosnih i kvalitativnih standarda i time ugroziti zdravlje životinja i sigurnost hrane.

Kako bi identificirali i spriječili takve incidentne situacije te osigurali siguran i kvalitetan proizvod važno je da proizvođači krmnih smjesa implementiraju stroge kontrolne mjere, provode redovite inspekcije te u poslovanje uvedu tehnologije poput umjetne inteligencije i strojnog učenja. Što se tiče gospodarske opravdanosti ulaganja u ove tehnologije ona se očituje prije svega u: povećanju produktivnosti, povećanju kakvoće i nadzora proizvodnog ciklusa i proizvodnih linija, povećanju kakvoće i nadzora gotovog proizvoda, povećanju efikasnosti i pojednostavljenju poslovanja, optimalnoj potrošnji energije, podizanju tehnološke i poslovne discipline, brzom i potpunom pregledu rada i poslovanja.

MODELI STROJNOG UČENJA

Modeli umjetnih neuronskih mreža (UNM, eng. Artificial Neural Networks), koristeći se svojstvima nelinearnog modeliranja, mogu se primijeniti kao sofisticirani matematički alati za predviđanje određenih izlaznih vrijednosti, koristeći pri tome podatke dobivene iz različitih analitičkih procesa (Giwa i sur., 2015.; Dashti i sur., 2019.). Umjetne neuronske mreže spadaju u područje umjetne inteligencije te se u posljednje vrijeme sve više koriste za predviđanje u različitim područjima. Za razliku od postojećih regresijskih modela, UNM mogu obuhvatiti velik broj podataka povezivanjem zavisnih i nezavisnih varijabli nelinearnim vezama određujući moguće interakcije između istih (Pattanayak i sur., 2021.). Osnovne značajke UNM obuhvaćaju strukturu, algoritam učenja mreže i prijenosnu funkciju koja se koristi za „prijenos“ izračunatih vrijednosti s jednog umjetnog neurona na drugi. Odabirom ulaznih podataka, UNM mogu transformirati podatke prema željenoj

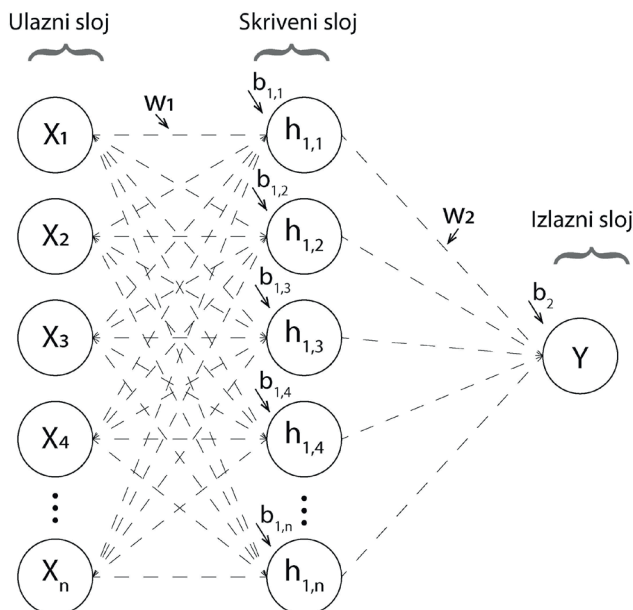
izlaznoj vrijednosti. Kako bi se odredila učinkovitost UNM-a u predviđanju uspoređuju se eksperimentalno dobivene i izračunate vrijednosti (Grossi i Buscema, 2007.; Kartal i Özveren, 2020.). Iako postoji više oblika UNM, u primjeni, osobito u predviđanju, najefikasniji oblik mreže je višeslojna perceptronska mreža (eng. Multi-layer Perceptron - MLP) (Pattanayak i sur., 2021.). Umjetne neuronske mreže su sustavi koji obrađuju podatke na sličan način kao neuroni u ljudskom mozgu, gdje se umjetni neuroni povezuju različitim geometrijskim vezama (Emel i Taşkin, 2002.). Koncept umjetnih neuronskih mreža je jedan od najznačajnijih oblika umjetne inteligencije za predviđanje (Staub i sur., 2015.).



Slika 1. Struktura umjetnog neurona
 Picture 1 Structure of an artificial neuron

Gharehbaghi (2016.) ističe kako umjetne neuronske mreže prikazuju ukupnu međupovezanost sustava. Te mreže prilagođavaju se na temelju iskustva, prihvaćajući različite ulazne podatke i generirajući krajnje izlazne podatke.

Višeslojna mreža sastoji se od tri sloja: ulaznog, skrivenog i izlaznog sloja (Slika 2.) Svaki sloj se sastoji od niza neurona a veze između neurona određene su pomoću težinskih koeficijenata. Optimizacijom težinskih koeficijenata među neuronima računa se krajnji željeni izlaz (Pattanayak i sur., 2021.). Osnovna jednadžba za računanje izlaznih podataka u neuronskoj mreži prema Pattanayak i sur., (2021.) glasi:



Slika 2. Struktura umjetne neuronske mreže;
 x – podaci ulaznog sloja; w – težinski koeficijent;
 b – prag osjetljivosti (bias); Y – izlazni podatak.

Picture 2 Structure of artificial neural network;
 x – input layer data; w – weight coefficient;
 b – bias threshold; Y – output data.

$$Y_i = W_2 \tan \text{sig}(W_1 X_i + B_1) + B_2$$

gdje su:

- Y_i - izlazni vektor,
- X_i - ulazni vektor,
- W_1 - težinski vektor između skrivenog i ulaznog sloja,
- B_1 - vektor osjetljivosti (eng. bias) skrivenog sloja,
- W_2 - težinski vektor između izlaznog i skrivenog sloja,
- B_2 - vektor osjetljivosti skrivenog sloja.

Prema Bašiću i sur., (2008.) najčešći oblik prijenosne funkcije jest sigmoidalna funkcija. Sigmoidalna funkcija je derivabilna, što predstavlja bitnu prednost pri postupku učenja neuronske mreže. Sigmoidalna funkcija je definirana kao:

$$f(x) = \frac{1}{1 + e^{-x}}$$

Modeli potpornih vektora (MPV) su algoritmi koji se baziraju na optimizaciji hiper-ravnina koje razdvajaju podatke. Oni se mogu koristiti za klasifikaciju ili regresiju. Kada se MPV-e koriste kao regresijski modeli, obično se podaci podijele na skup za učenje i skup za testiranje kako bi se utvrdila efikasnost modela (García Nieto i sur., 2019.). Modeli slučajnih šuma za regresiju učinkoviti su alat u predviđanju te se definiraju kao algoritmi učenja koji pomoću više nasumičnih grana odluke predviđaju izlaznu vrijednost s obzirom na prosječnu vrijednost obrađenih podataka, uključuju metode predviđanja u obliku klasifikacije i regresije, te koriste konačan (određeni) broj nasumičnih grana (Scornet i sur., 2015.; Biau i Scornet, 2016.). Kod navedenih modela važno je odrediti intervale koji sadrže vrijednosti s određenom vjerojatnošću predviđanja. Modeli za predviđanje koriste podatke prosječne vrijednosti bez vrijednosti odstupanja (Zhang i sur., 2020.).

PREPORUKE KORIŠTENJA AI U RH

U organizaciji „Znanstvenog vijeća za tehnološki razvoj i Znanstvenog vijeća za istraživačku infrastrukturu Hrvatske“ Hrvatska akademija znanosti i umjetnosti sa „Znanstvenim centrom izvrsnosti za znanost o podacima i kooperativne sustave“ donosi dokument preporuke nacionalne posebnosti i ciljeva korištenja umjetne inteligencije u Republici Hrvatskoj. U sklopu dokumenta navedena je potreba ostvarivanja idućih ciljeva:

1. potaknuti razvoj tehnoloških i industrijskih kapaciteta Republike Hrvatske i primjene umjetne inteligencije u svim područjima gospodarstva kao i u privatnom i javnom sektoru;
2. pripremiti društvo za socioekonomske promjene u Republici Hrvatskoj uzrokovane umjetnom inteligencijom;
3. osigurati odgovarajući etički i pravni okvir u Republici Hrvatskoj za primjenu umjetne inteligencije.

Djelovanje u području umjetne inteligencije u Republici Hrvatskoj treba uskladiti s digitalnom preobrazbom i uspostaviti odgovarajući inovacijski ekosustav jer je djelotvorna primjena umjetne inteligencije moguća samo u visoko digitaliziranom okruženju. Digitalna preobrazba obuhvaća prepoznatljivija područja kao što su: računarstvo u oblaku, internet

stvari, robotika, digitalne platforme, raspodijeljene poslovne knjige, kognitivno računarstvo i internet sljedeće generacije.

MOGUĆNOSTI PRIMJENE MODELA STROJNOG UČENJA

Suvremeni postupci proizvodnje krmnih smjesa uključuju niz složenih koraka koji zahtijevaju strogu kontrolu, pridržavanje propisa i osiguranje kako kvalitete hrane, tako i sigurnosti radnika. Sama proizvodnja uključuje niz procesa, poput prijema sirovina, mljevenja, odmjeravanja, miješanja, kondicioniranja, peletiranja, hlađenja, pakiranja i drugih. Imajući u vidu prirodu poslovno tehnološkog procesa, strojno učenje se nameće kao jedna od mogućnosti unapređenja proizvodnje i to u pogledu:

1. Kontrole kvalitete. Modeli strojnog učenja mogu „učiti“ u svrhu analize podataka iz različitih izvora kao što su npr. podaci o sastojcima smjese, podaci o radnoj okolini i o zdravstvenom stanju životinja kako bi predvidjeli kvalitetu krmne smjese. Analizom velikih skupova podataka, modeli strojnog učenja mogu prepoznati obrasce i donositi predviđanja koja pomažu u optimizaciji kvalitete hrane. U istraživanju koje su proveli Zhu i sur. (2021.), analizirana je primjena dubokog učenja i strojnog vida u procesu prerade poljoprivredno prehrambenih proizvoda. U tu svrhu, korištene su tradicionalne metode strojnog učenja, kao i tehnike strojnog vida koje se mogu primijeniti za navedeno područje. Rezultati istraživanja ukazuju na to da primjena strojnog vida može značajno poboljšati efikasnost procesa, što je ključno za osiguravanje kvalitete i sigurnosti proizvoda. Wang i sur. (2021.) proveli su istraživanje u kojem su analizirali primjene strojnog učenja (ML) za praćenje i predviđanje sigurnosti hrane. Autori iznose da primjena strojnog učenja omogućuje visoku točnost predviđanja, što upućuje na to da ML modeli predstavljaju obećavajuću metodu za praćenje i predviđanje sigurnosti hrane. U analiziranim studijama najčešće korišteni algoritmi su Bayesove mreže (BN) za analizu strukturiranih podataka, zbog jednostavnosti razumijevanja modela i mogućnosti lakog uključivanja stručnog znanja, te neuronske mreže (NN) za analizu nestrukturiranih podataka, jer su bolje prilagođene za obradu slikovnih i tekstualnih podataka. Nadalje, Wang i sur. (2021.) identificiraju nekoliko smjernica za buduće studije koje

primjenjuju ML modele za praćenje i predviđanje sigurnosti hrane. Autori također, nude prijedloge za izvore podataka i ulazne varijable koje bi mogle biti korisne u budućim primjenama strojnog učenja u ovoj domeni.

2. Smanjenja gubitaka. Na bilo kojoj proizvodnoj liniji pa čak i različitim proizvodima na istoj liniji postoje različiti gubici i neučinkovitosti: od otpada koji može nastati tijekom tehnološkog procesa, odbacivanja zbog kvalitete, varijacija u veličini i obliku, neujednačene boje i tako dalje, a uzroci tih gubitaka također se dramatično razlikuju od proizvodne linije do proizvodne linije. Bilježeći varijacije na ulazu u proizvodnu liniju kao i među drugim faktorima tijekom proizvodnje, modeli strojnog učenja mogu pomoći pri otkrivanju korelacija koje bi mogle proći nezamijećene ljudskim promatračima. Pathumnakul i sur. (2009.) implementirali su umjetne neuronske mreže (ANN) u proces proizvodnje stočne hrane, analizirajući parametre poput parametara procesa, nutritivnih sastojaka i omjera korištenih sirovina. Autori navode da se kroz precizno predviđanje stope proizvodnje izbjegava potreba za skupim testnim proizvodnjama. Ovaj pristup proizvodnim operacijama omogućuje da se uzmu u obzir troškovi proizvodne i sirovina prilikom odlučivanja o najekonomičnijoj formuli za proizvodnju stočne hrane.

3. Analize sastojaka. Regresijski modeli strojnog učenja mogu se koristiti za analizu kemijskog sastava različitih sastojaka krmne smjese, poput sadržaja proteina, masti i vlakana. To može pomoći u optimizaciji formulacija hrane identificiranjem idealne kombinacije sastojaka za određenu vrstu životinje ili fazu razvoja.

4. Prediktivnog održavanja. Jedna potencijalna primjena modela strojnog učenja je prediktivno održavanje. To je korak dalje od preventivnog održavanja, koje uključuje servisiranje ili zamjenu opreme prema unaprijed određenom rasporedu. Prediktivno održavanje je program kontinuiranog praćenja opreme i razvijanja profila njezinog rada koji ukazuje kada je potrebno obratiti pozornost na pojedini segment opreme. Navedeni modeli pomažu u razvoju tog profila kroz kontinuiranu procjenu parametara poput temperature i vibracija. Osjetnici koji prate rad dijelova opreme poput motora, prijenosnika i slično, neprekidno šalju povratne podatke koji se analiziraju i na osnovi njih se razvija profil za

zamjenu opreme. Međutim, program preventivnog održavanja nije jednostavan ni lagan za provedbu. Zahtijeva specijalizirano znanje, posebno za pojedine parametre poput vibracija, koji su podložni mnogim vanjskim varijablama. Zbog toga je pronalaženje uzoraka kvarova otežano te bi daljnja istraživanja trebala usmjeriti na razvoj novih metoda i algoritama koji će omogućiti još bolje rezultate.

5. Upravljanja inventarom. Analizom podataka iz prethodnih narudžbi, rasporeda proizvodnje i razine inventara, modeli strojnog učenja mogu predvidjeti optimalne količine sirovina potrebne za zadovoljenje buduće proizvodnje.

6. Kontrole radne okoline u kojoj se proizvode krmne smjese. Vezano uz navedeno, modeli strojnog učenja mogu se koristiti za optimizaciju temperature, vlažnosti i protoka zraka u proizvodnim objektima.

7. Detekcije stranih tijela. Kontaminacija stranim tijelima jedan je od glavnih razloga povlačenja hrane s tržišta i odbijanja od strane potrošača (Soon i sur., 2020.). Ova vrsta kontaminacije šteti potrošačima i dovodi do gubitka vjernosti proizvođaču, uzrokujući velike troškove povlačenja. Primjeri stranih tijela su kukci, staklo, metal, guma i slično. Ta tijela slučajno mogu dospjeti u krmne smjese tijekom bilo kojeg koraka u procesu proizvodnje. Na primjer, sitni kamenčići ili kamenje, kukci i grančice mogu dospjeti u hranu tijekom bilo kojeg koraka berbe, prerade, rukovanja ili pripreme. Iako stupanj opasnosti od stranih tijela ovisi o veličini, vrsti, tvrdoći i vidljivosti tijela, konzumiranje hrane koja sadrži strana tijela može izazvati gušenje ili određene bolesti (Mohd Khairi i sur., 2018.). Detekcija stranih tijela golim okom je teška. S druge strane, suvremene tehnologije i metode prepoznavanja sada omogućuju njihovu laku detekciju. Primjeri takvih tehnologija uključuju rendgensko snimanje, ultrazvuk, toplinsko snimanje kao i analizu slika i videozapisa (Mohd Khairi i sur., 2018.). Ove tehnike su precizne i neinvazivne, što ih čini prihvatljivom u procesu proizvodnje krmnih smjesa. Pored otkrivanja prisutnosti stranih tijela modeli strojnog učenja mogu se osposobiti za otkrivanje i drugih nedostataka u krmnim smjesama, poput pojave nakupina (grudica) te pri otkrivanju navedenih anomalija aktiviraju upozorenja kako bi obavijestili operatore o potencijalnim problemima.

8. Održavanja higijene. Tradicionalni sustavi čišćenja često su bili neučinkoviti kada je u pitanju održavanje higijene. S druge strane, suvremene tehnologije temeljene na umjetnoj inteligenciji koriste različite osjetnike, poput ultrazvučnog osjetnika kako bi pružile algoritmima strojnog učenja podatke koji se mogu koristiti za identifikaciju nečistoća i ostataka hrane na opremi.

9. Nadzora pakiranja. Nakon pripreme, krmne smjese se pakiraju kako bi se očuvala njihova kvaliteta te olakšalo skladištenje i transport. Han (2005.) navodi da ambalaža sprječava oštećenje hrane uzrokovano biološkim, kemijskim i fizičkim čimbenicima tijekom cijelog lanca opskrbe. Neautomatizirani nadzor pakiranja hrane može rezultirati ljudskom pogreškom i niskom učinkovitošću (npr. miješanje nepoželjnih predmeta u pakiranje). Ovi nedostaci mogu se riješiti korištenjem novih tehnologija, poput sustava strojnog vida, za nadzor obrade hrane i pakiranja.

10. Razvoj proizvoda. Proizvođači krmnih smjesa mogu koristiti tehnologiju strojnog učenja kako bi analizirali i identificirali ponašanje i potrebe kupaca. Dobiveni podaci zatim se mogu koristiti za proizvodnju „personaliziranih“ proizvoda koji zadovoljavaju te potrebe i pomažu proizvođačima u povećanju prodaje.

Sveukupno gledajući, može se reći da će metode strojnog učenja u bliskoj budućnosti imati sve značajniju ulogu u procesima proizvodnje krmnih smjesa. Koristeći analitiku velikih skupova podataka i napredne algoritme proizvođači krmnih smjesa mogu ostvariti konkurentsku prednost i potaknuti rast kako bi poboljšali kvalitetu proizvoda, smanjili otpad, optimizirali lanac opskrbe te poboljšali sigurnost hrane i korisničko iskustvo. Kako industrija napreduje, može se očekivati sve više transformacijskih primjena navedenih tehnologija u sigurnosti hrane i proizvodnji, a proizvođači koji prihvate ove tehnologije povećavaju svoje izgleda za uspjeh u ovoj brzo mijenjajućoj industriji.

Iako primjena navedenih tehnologija nudi značajne prednosti, postoje i određeni izazovi povezani s njihovom implementacijom. Ključni izazov predstavlja zahtjev za velikom količinom visokokvalitetnih i dobro strukturiranih podataka kako bi se algoritmi optimizirali. Proizvođači krmnih smjesa trebaju

osigurati da su podaci upotrijebljeni za strojno učenje točni, reprezentativni i bez pristranosti. To može biti izazovno s obzirom na složenost i varijabilnost procesa proizvodnje. Još jedan izazov je trošak implementacije sustava i osposobljavanja radnika. Razvoj modela i njihova integracija u postojeće proizvodne sustave mogu biti skupi te često zahtijevaju značajna ulaganja u hardver, softver i osoblje koje mora biti osposobljeno za upravljanje tim sustavima i tumačenje generiranih podataka. Osim toga, ne postoji univerzalno rješenje i svaki proizvođač mora pažljivo razmotriti svoje jedinstvene potrebe i ciljeve prije ulaganja u tehnologiju.

ZAKLJUČCI

Očito je da dolazi vrijeme značajnih promjena u samoj proizvodnji krmnih smjesa. Sukladno tome, dodatnu je pozornost potrebno usmjeriti na utvrđivanje prikladnosti i iskoristivosti suvremenih tehnologija. Jedna od tih tehnologija je i internet stvari čija je primjena rezultirala velikom količinom podataka u opticaju koji donose nove mogućnosti praćenja proizvodnih procesa. Nadalje, primjena modela strojnog učenja omogućuje unaprijeđenje učinkovitosti proizvodnje, smanje troškove i optimizaciju procesa. U tom smislu, algoritmi umjetne inteligencije i strojnog učenja mogu se uspješno koristiti kao nelinearni modeli za prepoznavanje uzoraka i rješavanje složenih problema. Navedeni modeli u konačnici omogućuju olakšanu automatizaciju procesa kao i sposobnost ubrzanog donošenja odluka. Pri tome je potrebno uzeti u obzir proizvodno postrojenje, skladištenje i transport sirovina, kao i sve čimbenike koji utječu na krajnju kvalitetu proizvoda.

LITERATURA

1. Awasthi, Y. (2020.): Press „a” for artificial intelligence in agriculture: A review. *International Journal on Informatics Visualization*, 4(3): 112–116. <https://doi.org/10.30630/ijov.4.3.387>
2. Bašić, B. D., Čupić M., Šnajder J., (2008.): Umjetne neuronske mreže, Umjetna inteligencija, Fakultet elektrotehnike i računarstva, Zagreb (2008.).
3. Biau, G., Scornet, E. (2016.): A random forest guided tour. *Test*, 25(2): 197–227. <https://doi.org/10.1007/s11749-016-0481-7>

4. Dashti, A., Noushabadi, A. S., Raji, M., Razmi, A., Ceylan, S., Mohammadi, A. H. (2019.): Estimation of biomass higher heating value (HHV) based on the proximate analysis: Smart modeling and correlation. *Fuel*, 257 (March): 115931. <https://doi.org/10.1016/j.fuel.2019.115931>
5. Emel, G., Taşkin Ç. (2002.): Genetik Algoritmalar ve Uygulama Alanları, Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı:1, s.129-152
6. García Nieto, P. J., García-Gonzalo, E., Sánchez Lasheras, F., Paredes-Sánchez, J. P., Riesgo Fernández, P. (2019.): Forecast of the higher heating value in biomass torrefaction by means of machine learning techniques. *Journal of Computational and Applied Mathematics*, 357: 284–301. <https://doi.org/10.1016/j.cam.2019.03.009>
7. Gharehbaghi, K. (2016.): Artificial neural network for transportation infrastructure systems. *MATEC Web of Conferences*, 81. <https://doi.org/10.1051/mateconf/20168105001>
8. Giwa, S. O., Adekomaya, S. O., Adama, K. O., Mukaila, M. O. (2015.): Prediction of selected biodiesel fuel properties using artificial neural network. *Frontiers in Energy*, 9(4): 433–445. <https://doi.org/10.1007/s11708-015-0383-5>
9. Grossi, E., Buscema, M. (2007.): Introduction to artificial neural networks. *European Journal of Gastroenterology and Hepatology*, 19(12): 1046–1054. <https://doi.org/10.1097/MEG.0b013e3282f198a0>
10. Han, J.H. (2005.): New technologies in food packaging: Overview. *Innovations in Food Packaging*, Elsevier, 3-11.
11. Hrvatska akademija znanosti i umjetnosti (2019.): Preporuke – Europske strateške odrednice o umjetnoj inteligenciji.
12. Jung, J., Maeda, M., Chang, A., Bhandari, M., Ashapure, A., & Landivar-Bowles, J. (2021.): The potential of remote sensing and artificial intelligence as tools to improve the resilience of agriculture production systems. *Current Opinion in Biotechnology*, 70: 15–22. <https://doi.org/10.1016/j.copbio.2020.09.003>
13. Kartal, F., Özveren, U. (2020.): A deep learning approach for prediction of syngas lower heating value from CFB gasifier in Aspen plus®. *Energy*, 209. <https://doi.org/10.1016/j.energy.2020.118457>
14. Linaza, M. T., Posada, J., Bund, J., Eisert, P., Quartulli, M., Döllner, J., Pagani, A., Olaizola, I. G., Barriguinha, A., Moysiadis, T., Lucat, L. (2021): Data-driven artificial intelligence applications for sustainable precision agriculture. *Agronomy*, 11(6). <https://doi.org/10.3390/agronomy11061227>
15. Mohd Khairi, M.T., Ibrahim, S., Md Yunus, M.A., Faramarzi M. (2018.): Noninvasive techniques for detection of foreign bodies in food: a review. *J. Food Process. Eng.*, 41 (6), Article e12808
16. Pattanayak, S., Loha, C., Hauchhum, L., Sailo, L. (2021.). Application of MLP-ANN models for estimating the higher heating value of bamboo biomass. *Biomass Conversion and Biorefinery*, 11(6), 2499–2508. <https://doi.org/10.1007/s13399-020-00685-2>
17. Scornet, E., Biau, G., Vert, J. P. (2015.): Consistency of random forests. *ANNals of Statistics*, 43(4): 1716–1741. <https://doi.org/10.1214/15-AOS1321>
18. Shaw, M. Subramaniam, C. Tan, G. W., Welge, M. (2001.): Knowledge management and data mining for marketing. *Decision Support Systems*. 31(1): 127-137.
19. Sishodia, R. P., Ray, R. L., Singh, S. K. (2020.): Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, 12(19): 1–31. <https://doi.org/10.3390/rs12193136>
20. Soon, J.M., Brazier, A.K., Wallace, C.A. (2020.): Determining common contributory factors in food safety incidents—a review of global outbreaks and recalls 2008–2018. *Trends in Food Science & Technology*, 97: 76-87.
21. Staub, S., Karaman, E., Kaya, S., Karapınar, H., Güven, E. (2015.): Artificial Neural Network and Agility. *Procedia - Social and Behavioral Sciences*, 195: 1477-1485. [10.1016/j.sbspro.2015.06.448](https://doi.org/10.1016/j.sbspro.2015.06.448).
22. Valerjev, P. (2006.): Povijest i perspektiva razvoja umjetne inteligencije u istraživanju uma. *Knjiga Mozak i um - Trajni izazov čovjeku*, M. S., Žebec, G., Sabol, M., Šakić, M., KotrlaTopić, (Ur.), Zagreb: Institut društvenih znanosti Ivo Pilar, 105-122.
23. Zhang, H., Zimmerman, J., Nettleton, D., Nordman, D. J. (2020.): Random Forest Prediction Intervals. *American Statistician*, 74(4): 392–406. <https://doi.org/10.1080/00031305.2019.1585288>
24. Zhu, L., Spachos, P., Pensini, E., Plataniotis, K.N. (2021.): Deep learning and machine vision for food processing: A survey. *Current Research in Food Science*, 4: 233 - 249.
25. Wang, X., Bouzemrak, Y., Lansink, A.O., van der Fels-Klerx, H.J. (2022.): Application of machine learning to the monitoring and prediction of food safety: A review. *Compr Rev Food Sci Food Saf. Jan*; 21(1): 416-434. doi: 10.1111/1541-4337.12868. Epub 2021 Dec 14. PMID: 34907645.

SUMMARY

Artificial intelligence (AI) and machine learning (ML) are increasingly present in agriculture, particularly in the production of feed mixtures, where they enable producers to optimize production processes, reduce costs, and improve efficiency. The implementation of nonlinear models, such as artificial neural networks (UNM), in this field enables pattern recognition and the solution of complex problems related to feed mixtures. The application of UNM in the technology of feed mixture production, with a properly chosen structure, learning algorithms and transfer functions, allows advanced optimization of the process, including the management of the production plant, storage and transportation of materials. These models offer new opportunities to improve the quality of the final product, taking into account all the factors that influence it. Through this customization, AI provides tools for fast and efficient decision making, leading to improved automation and efficiency in compound feed production.

Keywords: Artificial intelligence, machine learning, optimization, modelling, feed mixtures.