

Pregledni rad
Review paper
DOI: 10.5937/PoljTeh2404108E

PRIMENA MAŠINSKOG UČENJA U POLJOPRIVREDI

**Olivera Ećim-Đurić*, Rajko Miodragović, Andrija Rajković, Mihailo Milanović,
Zoran Mileusnić, Aleksandra Dragičević**

*Univerzitet u Beogradu, Poljoprivredni fakultet, Institut za poljoprivrednu tehniku,
Beograd-Zemun, Republika Srbija*

Sažetak: Mašinsko učenje (eng. ML – Machines Learning), kao podskup veštačke inteligencije, igra ključnu ulogu u modernizaciji poljoprivrede, jer omogućava analizu velikih količina podataka i donošenje brzih i tačnih odluka u poljoprivrednoj proizvodnji. ML je korišćen u različitim fazama poljoprivrednog ciklusa, uključujući analizu zemljišta, kvalitet semena, detekciju bolesti useva, kontrolu korova, prepoznavanje biljnih vrsta i optimizaciju berbe. Različite metode ML, kao što su nadzirano učenje, nenadzirano učenje, polunadzirano učenje i pojačano učenje, koriste se u cilju poboljšanja tačnosti predviđanja i odluka u poljoprivredi. Veštačke neuronske mreže (eng. ANN - Artificial Neural Networks), posebno duboke neuronske mreže (eng. DNN - Deep Neural Networks) i konvolutivne neuronske mreže (eng. CNN - Convolutional Neural Networks), pokazale su se kao najefikasniji alati za analizu podataka, kao što su slike i numerički podaci, čime se omogućava precizno upravljanje poljoprivrednim praksama. Ove tehnologije omogućavaju optimizaciju resursa i smanjenje negativnog uticaja na životnu sredinu, čime se povećava održivost poljoprivredne proizvodnje. Primena mašinskog učenja u poljoprivredi predstavlja ključnu komponentu u razvoju precizne poljoprivrede, koja omogućava efikasno upravljanje proizvodnjom u realnom vremenu, smanjenje upotrebe resursa (kao što su voda, đubrivo i pesticidi), i povećanje prinosa. Iako su postignuti značajni napreci, postoji prostor za dalja istraživanja u razvoju novih modela ML koji će obuhvatiti sve faze poljoprivrednog ciklusa.

Ključne reči: *Precizna poljoprivreda, mašinsko učenje, veštačke neuronske mreže, obrada slike*


*Corresponding Author. E-mail: nera@agrif.bg.ac.rs
ORCID: 0000-0002-6321-8141

UVOD

Prema projekcijama na osnovu rasta stanovništva u poslednjih nekoliko decenija, očekuje se da će svetska populacija dostići broj i do 10 milijardi do 2050 [1]. Uporedo sa rastom stanovništva menja se i njegova struktura. Krajem 20 veka preko 60% stanovništva živelo je u ruralnim područjima, dok danas oko 54% stanovništva živi u velikim gradovima koji se sve više šire.

Porast stanovništva neminovno dovodi i do porasta potražnje za hranom, vodom i energijom koje su međusobno spregnute. FAO predviđanja za period u narednih trideset godina podrazumevaju porast svetske proizvodnje hrane za 60 do 70% [2]. Savremena poljoprivreda, kao osnovni stub ekonomija svih država mora ne samo da odgovori na ovaj zadatak, nego ujedno da se suoči i sa trajnim klimatskim promenama [3], neprekidnim iscrpljivanjem prirodnih resursa [4], kao i sa savremenim zahtevima po pitanju proizvodnje zdrave i bezbedne hrane kao posledice promena životnih navika savremenog stanovništva.

Poljoprivreda je jedina privredna grana čiji rast i razvoj prati evoluciju čovečantsva [5], kao što je prikazano na Slici 1. Poljoprivreda 1.0 odnosi se na period primene ljudske i životinjske snage, uz primenu relativno jednostavnih poljoprivrednih oruđa. I industrijska revolucija uvela je značajne promene i u poljoprivredi koja se može definisati kao Poljoprivreda 2.0.



Slika 1. Faze razvoja poljoprivrede, [5].

Figure 1. Stages of agricultural development, [5].

Razvoj poljoprivrednih mašina, kao i primena zaštitnih sredstava u biljnoj proizvodnji sa jedne strane, prouzrokovao je značajan porast poljoprivredne proizvodnje, ali na žalost sa druge strane, doveo i do zagađenja zemljišta i voda, prekomernog trošenja prirodnih resursa i preterane potrošnje energije. Ovi problemi su prilagođeni u Poljoprivredi 3.0 do kraja 20 veka, a nastali su pre svega kao posledica naglog rasta IT industrije koja je svoje mesto našla i u poljoprivredi. Racionalno gazdovanje poljoprivrednom tehnikom, ograničena upotreba hemijskih sredstava u primarnoj poljoprivrednoj proizvodnji, unapređeni sistemi navodnjavanja, pokazali su da se poljoprivredna proizvodnja lako može prilagoditi savremenim izazovima i trendovima koji su pred njom.


Danas je evolucija poljoprivredne proizvodnje došla do faze Poljoprivreda 4., koja se prema Ujedinjenim nacijama naziva i Digitalna poljoprivredna revolucija, [6].

Zahvaljujući primeni savremenih tehnologija kao što su Internet of Things, Big Data, Cloud Computing, Remoting Sensing Artificial Intelligence, efikasnost poljoprivredne proizvodnje može se značajno unaprediti, a da se pri tome proces proizvodnje bazira na održivom razvoju uz što je mogue manji negativan uticaj na životnu sredinu, trenutne prirodne resurse i potencijalno smanjenje efekta staklene baste, [7-9].

Poljoprivreda 4.0 može se takođe definisati kao i složen sistem sakupljanja informacija daljinskom detekcijom, satelitkim snimcima, primenom dronova i sl. Ove informacije se moraju prikupiti u realnom vremenu i veoma brzo obraditi kako bi farmerima bile dostupne za brzo donošenje odluka. Treba imati na umu, da se količina ovih informacija neprekidno uvećava tokom procesa proizvodnje, pa je stoga potrebno ustanoviti šablone u obradi informacija, kako bi se proces odluke sveo na najkraći vremenski period. Mašinsko učenje (eng. Machine Learning –ML) razvilo se upređo sa naprednim računarskim tehnologijama i računarima visokih performansi kako bi se proces obrade podataka, detektovanje šablona i na kraju razumevanje procesa u obradi velikog broja podataka moglo primeniti. Od svojih početaka, polovinom prološ veka do danas, ML je našlo primenu gotovo u svim sferama industrije u kojima se proces odlučivanja zasniva na obradi podataka, a svoju primenu našlo je uspešno ne samo u primarnoj poljoprivrednoj proizvodnji, nego i u prehrambenoj industriji, [10].

PRINCIP I TEHNIKE MAŠINSKOG UČENJA

Kao podskup veštačke inteligencije, ML se može definisati najjednostavnije kao tehnika kojom se omogućuje računaru da uspostavi veze i šablone iz velikog broja podataka i da odgovarajuća predviđanja [11]. U tradicionalnom programiranju, računaru se zadaju instrukcije preko napisanog koda, koje računar sekvencijalno izvršava. ML podrazumeva da računar sam pronađe odgovarajuće veze između ulaznih podataka, da "nauči" model i izvrši predviđanja izlaznih podataka. S obzirom na činjenicu da ML modeli rade sa velikim brojem podataka, nisu zavisni od skladištenja na računarima, već upravo imaju sposobnost da podatke skladište na mreži (Cloud computing) i da ih pozivaju sa mreže. Sa druge strane, ML modeli zahtevaju jake procesore za obradu podataka, pa je kvaliter računara jedan od doređujućih faktora takođe. Generano, kreiranje ML agoritama i modela ne zahteva posebna teorijska znanja iz oblasti za koje se formiraju, već samo dobra programerska znanja softvera koji se koristi.



Slika 2. Shematski prikaz ML modela, [12].
Figure 2. Schematic representation of the ML model, [12].

Model se obično trenira do zadate tačnosti, ili što manjih gubitaka – razlika između predviđenih i realnih podataka. Proces se ponavlja više puta, uz modifikaciju vrednosti hiperparametara – veličina kojima se upravlja modelom, dok se ne dobije što je moguće bolje poklapanje i na podacima za treniranje, ali i na podacima za validaciju modela [12].

U praksi se međutim pokazalo, da bez obzira na formalno postizanje matematičke konvergencije u treniranju modela, teorijska znanja su od izuzetne važnosti radi što je mogućeg kvalitetnijeg tumačenja dobijenih vrednosti, koja u nekim primena ML mogu imati veliki i finansijski, ali i životni uticaj. Primera radi, ukoliko postoji samo jedna izlazna veličina iz ML modela, analiziraju se tzv. "False positive" i "False negative" vrednosti. "False positive" ili lažno tačne vrednosti u sličaju primene ML u navodnjavanju ili primeni odgovarajućih pesticida mogu upravo putem netačne informacije da farmera navedu da primeni više zaštitnog sredstva nego što je potrebno ili da pojača sistem za navodnjavanje preko granice koja je potrebna biljakama. "False negative" ili lažno netačna informacija može da manji sadržaj azota u biljaka zameni sa pojavom bolesti, i da na taj način farmera navede da donese poptuno pogrešnu odluku. U drugim granama primene ML modela, npr u finansijama, ovakve vrednosti mogu dovesti do pogrešnih procesa u poslovanju i velikih finansijskih gubitaka, a u najoštrijem slučaju u medicini, do pogrešnog dijagnostifikovanja bolesti [13]. U najširoj klasifikaciji ML može se podeliti u četiri grupe:

- Nadzirano učenje (eng. Supervised Learning)
- Nenadzirano učenje (eng. Unsupervised Learning)
- Polunadzirano učenje (eng. Semisupervised Learning)
- Pojačano učenje (eng. Reinforcement Learning)


Bez obzira koja se grupa ML primenjuje, postupak fomiranja algoritma, modela i treniranja modela je identičan. Ulazni podaci se moraju prvo obraditi, tako što će se normalizovati, kao i izlazni podaci. U slučaju slika, one se prevode u tenzore, a svaki tenzor ima svoju oznaku. Neki ML modeli mogu da rade i sa podacima koji nedostaju, dok se kod nekih modela mora izvršiti prilagođavanje i isključiti ulazi sa nedostajućim vrednostima. Normalizovani podaci se dele na podatke za treniranje modela i validaciju (odnos 80:20 %), ili na podatke za treniranje, test i validaciju (80:10:10 %) ukoliko opstoji veliki broj podataka. Ne postoji precizan algoritam na koji se može pozvati u formiranju modela. Izborom hiperparametara, u većini slučajeva treniranje modela svodi se na model proba – test.

Nadzirano učenje

Nadzirano učenje je podkategorija ML u kojoj računar uči na osnovu seta označenih ulaznih i izlaznih podataka. U većini slučajeva, kao što je prikazano na Slici 3, ovi algoritmi i modeli se vezuju za prepoznavanje slika. Računar uči tako što povezuje naziv, kao izlaznu veličinu sa odgovarajućom slikom, kao ulaznom veličinom. Kada računar dobije novi nepoznati ulazni podatak da ga analizira, prvo ga deli na odgovarajuće osobine: oblik, tekstura, boja i sl, a zatim ove osobine upoređuje sa podacima iz kojih je učio. Kada pronade da osobine se u najvećem procentu poklapaju sa nekom od označenih veličina, ulaznom podatku dodeljuje tu oznaku.

Ovi ML algoritmi koriste se u modelima klasifikacije i regresije. Inicijalno, većina ML modela koristi ovaj tip, mada su danas neki drugi modeli popularniji.

U većini slučajeva, primena nekog drugog tipa ML, na kraju se svodi na analizu nadziranom učenjem.




Slika 3. Shematski prikaz nadziranog učenja, [14].

Figure 3. Schematic representation of supervised learning, [14].

Nenadzirano učenje

Nenadzirano učenje je podkategorija ML koja obrađuje neoznačene podatke. Značavanje podataka može se tumačiti kao inicijalni ML algoritam, gde se podaci klasifikuju u odgovarajuće kategorije. U slučaju da podaci nisu označeni, nenadzirano učenje podrazumeva da računar sam mora da nauči da izvrši klasifikaciju podataka na osnovu njihovih polaznih parametara, kao što su na primer, boja, oblik, dimenzije i sl. Podacima se svakako na izlazu mogu dodeliti oznake ako je to neophodno.




Slika 4. Shematski prikaz nenadziranog učenja, [15].

Figure 4. Schematic representation of unsupervised learning, [15].

Polunadzirano učenje

Polunadziranom učenje je specijalna kombinacija prethodna dva tipa ML, u kom se ulazni podaci dele u dve grupe: veliku grupu neobebeženih podataka i malu grupu obebeženih podataka. Kako je na Slici 4 prikazano, računaru se dodeljuju podaci koji nisu obebeženi i manji deo podataka koji je obebežen. Njegov zadatak je da za novi ulaz prepozna da nije ni jedan od podataka koji su obebeženi, pa da ovaj podatak klasifikuje u tačno odgovarajuću kategoriju.




Slika 5. Shematski prikaz nenadziranog učenja, [16].

Figure 5. Schematic representation of unsupervised learning, [16].

Pojačano učenje

Pojačano učenje je još jedan tip kombinacije nadziranog i nenadziranog učenja, ali za razliku od polunadziranog učenja, u ovom učenju daje se nagrada za povrtane informacije algoritmu da uči i poboljša buduće rezultate. Pojačano učenje u mnogome liči na princip odlučivanja ljuskog mozga, pa se može koristiti u mrežama sa veštačkim neuronima (eng. Artificial Neural Networks – ANN). Prednost ovih modela je što u slučaju pojave greške u početnim fazama učenja, upravo sistem u kom sebe algoritam koriguje može značiti da kasnije do iste greške neće uopšte ni dolaziti. Sa druge strane, mana modela je što zahtevaju mnogo podataka za treniranje u cilju dobijanja modela koji predviđa sa visokom tačnošću.




Slika 6. Shematski prikaz nenadziranog učenja, [17].

Figure 6. Schematic representation of unsupervised learning, [17].

Veštačke neuronske mreže (ANN), koje su se pokazale kao mreže koje daju najbolje rezultate u primeni u poljoprivredi [18]. Koncipirani da simuliraju rad ljudskog mozga, ovi modeli su sposobni da uče iz reprezentativnog skupa podataka. Pogodne su za širok dijapazon problema, pa čak i situacijama kada klasični modeli regresije ne daju očekivane rezultate. U osnovi se sastoje iz tri sloja: ulaznog, "skrivenog sloja" i izlaznog sloja, kao što je prikazano na Slici 7. Ulazni sloj sadrži set podataka koji treba da se obrade, i između kojih se funkcijama aktivacije u "skrivenim slojevima" pronalaze međusobne zavisnosti, da bi se na kraju u izlaskom sloju dobili očekivani podaci. Duboke neuronske mreže (eng. Deep Neural Networks - DNNs) kao podskup ANN modela koriste višestruke "skriveno slojeve" između ulaznih i izlaznih podataka, a moguće je ih primeniti i u nadziranom i nenadziranom učenju, [19].

Poseban tip DNNs-a su konvolutivne neuronske mreže (eng. Convolution Neural Networks - CNN) koje za razliku od tradicionalni mogu da organizuju neurone u mrežama u tri dimenzije [20]. Posebno je izražena njihova primena u obradi slika, gde mogu da postignu izuzetno visoku tačnost. Pored ovih mreža, postoji veliki broj mreža koje se mogu koristiti, a koje su manje zastupljene u analizama u poljoprivredi [21,22].



Slika 7. Primer DNNs modela u sušenju prehrambenih proizvoda
Figure 7. Example of DNNs model in drying food products

MAŠINSKO UČENJE U POPLJOPRIVREDI: PREGLED PRIMENE

U okviru jednog proizvodnog ciklusa, farmeri moraju da izvrše odgovarajuće zadatke, bilo da je reč o ratarskoj, povrtarskoj ili voćarsko-vinogradarskoj proizvodnji, kao što je prikazano na Slici 6. Uopšteno, neophodna je priprema semena, priprema zemljišta, sejanje, navodnjavanje i đubrenje, održavanje useva primenom pesticida ili obrezivanje, proces branja ili žetve i na kraju primena post-žetvenih tehnologija kako bi proizvodi u dužem vremenskom periodu pre svega ostali mikrobiloški ispravni i kao takvi plasiran krajnjem potrošaču.




Slika 8. Faze u poljoprivrednoj proizvodnji, [23].
Figure 8. Stages in Agricultural production, [23].

Precizna poljoprivredna treba da obuhvati sve faze i korake u proizvodnji i da primenom odgovarajuće obrade prikupljenih popdataka u realnom vremenu na osnovu prethodnih saznanja pruži farmeru tačne informacije na osnovu kojih može da primeni adekvatne agrotehničke mere. ML upravo tu pruža velike mogućnosti za pravilnu obradu podataka. Bilo da je reč o modelima selektovanja, regresije, stabla odluke ili širokog spektra veštačkih neuronskih mreža koje mogu da vrše obradu slika, numeričkih i kategorijskih veličina, ML je u mogućnosti da za svaki pojedinačni segment kvantifikuje odgovarajuće parametre.

Upravljanje zemljištem

Upravljanje zemljištem je od izuzetne važnosti u početnim fazama ratarske i voćarske proizvodnje. Tradicionalne tehnike analiza zemljišta podrazumevaju uzorkovanje i laboratorijske analize koje mogu biti skupe, a zahtevaju i mnogo rada. Mapiranje zemljišta, u cilju detektovanja problema erozije, neravnoteže hranljivih materija izazvane prekomernim đubrenjem i degradacijom zemljišta, tekstura, organska materija i na kraju sadržaj hranljivih materija veoma pristupačno se mogu rešiti primenom ML. Sa druge strane, baze podataka koje se obrađuju u modelima mogu biti i regionalno povezane, pa se na taj način mogu uspostaviti zajednički modeli na izuzetno velikim površinama. Metod primene zavisi od tipa podataka koji su na raspolaganju, a mogu biti numerički podaci, gde je najlakše primeni ANN, ili ukoliko je mapiranje izvršeno fotografisanjem, mogu se primeniti CNN [24-32].




Slika 9. AI model kretanja vode kroz zemljište, [34].
Figure 9. AI model of water movement through soil, [34].

Seme

Kvalitet semena je od izuzetne važnosti za predviđanje prinosa i određivanje kvaliteta proizvodnje. U industrijskoj proizvodnji semena, klafikacija se uglavnom obavlja ručno, što daje mogućnost češće pojave greške i povećanje otpada.

Automatizovano selektovanje semena moguće je obezbediti primenom različitih ML modela, koji u osnovi imaju korišćenje kompjuterskog vida, tj. obradu slike. Iako su i ranije zabeleženi primeri obrade slike u cilju detekcije, a zatim i klasterovanja semena CNN mreže su se pokazale kao najpraktičnije i najpreciznije rešenje u ovom slučaju [34-38]




Slika 10. Određivanje kvaliteta semena primenom CNN modela, [39].

Figure 10. Seed quality assessment using CNN model, [39].

Bolesti useva

Bolesti useva su još jedan važan faktor za predviđanje kvaliteta prinosa, s obzirom na činjenicu da ukoliko se ne detektuju na vreme ili ne primeni odgovarajuće zaštitno sredstvo mogu značajno smanjiti ukupan prinos. Klasična poljoprivreda podrazumevala je obučene agronome koji su vizuelno detektovali bolesti i donosili odluke koji pesticid i kada terba primeniti. Današnja precizna poljoprivreda upravo pomaže da se razvoj bolesti otkrije na vreme, primeni pravi pesticid i u odgovarajućoj količini. I ovde je detektovanje zasnovano na vizuelnoj promeni, kao što je promena boje lista, uvenuće, pojava pega na listovima i plovdovima, uvijanje lista i sl. Tehnološki napredak je omogućio da se detektovanje promena sensorima, ali isto tako i slikanje pogotovo autonomnim vozilima u realnom vremenu kako bi se otkrila vrsta promene i površina koja je zahvaćena promenom, pa se mogu praviti i prostorne mape distribucije bolesti. I u ovom slučaju obrada slike se pokazala kao najbolje rešenje, a različiti tipovi ML modela su pokazali dobra predviđanja. Za dobar model u ovom slučaju neophodno je obezbediti veliki broj slika zdravih biljaka i veliki broj biljaka zahvaćenih odgovarajućom bolešću u različitim fazama razvijanja bolesti. Slike se prvo klasteruju prema nazivima, a modeli treba da budu trenirani da sa dovoljnom preciznošću na osnovu slike daju pouzdanu informaciju na osnovu koje se kasnije odlučuje o primeni odgovarajućeg pesticida [40-52].




Slika 11. Detektovanje bolesti vizualizacijom i klasifikacijom, [53].

Figure 11. Disease detection by visualization and classification, [53].

Detekcija korova

Korovi se relativno lako i invazivno šire po površinama polja pre svega zbog svoje proizvodnje semena i dugovečnosti. Može se reći da se oni takmiče sa usevima za resurse kao što su prostor, svetlost, hranljive materije i dostupnost vode, a uglavnom izbijaju ranije od useva.


Kontrola korova može da se vrši dvojako, mehaničkim tretiranjem i primenom herbicida. Često je mehanički tretman težak za izvođenje, i neefikasan, pa je primena herbicida mnogo češća u praksi. Velika upotreba herbicida u dužem vremenskom periodu na žalost dovodi do otpornosti korova, a sa druge strane opasna je i po životnu sredinu. Primena dronova u ovom slučaju za fotografisanje, a zatim obrada slike različitim ML metodama može u mnogome da smanji primenu herbicida. ML model može da pruži informacije o trenutnoj fazi rasta korova, rasprostranjenosti na polju i da se na osnovu toga donese odluka o primeni odgovarajućeg herbicida u doziranoj količini [54-61].



Slika 12. Detekcija korova snimanjem i obradom slike, [62].
Figure 12. Weed detection by recording and image processing, [62].

Prepoznavanje useva


Biljne vrste mogu se identifikovati i klasifikovati ispitivanjem zaličitih organa kao što su koren, stabljike, listovi, cvetovi, plodovi, seme. Ova tehnika je poslednjih godina veoma popularna u taksonomiji biljaka i otkrivanju novih vrsta. Najčešći metod koji se primenjuje je prepoznavanje biljke na osnovu lista. Primena dronova i ovde je od velike važnosti za otkrivanje svojstava biljaka, a kasnija obrada slike i velika baza podataka primenom ML mogu da obezbedu dobru klasifikaciju [63-67].



Slika 13. Detekcija useva CNN modelima, [68].
Figure 13. Crop detection with CNN models, [68].

Kvalitet useva

Kvalitet useva ima značaj uticaj za kasnije plasiranje na tržištu. Rezultat je primene svih agrotehničkih mera od setve žetve, i ubiranja plodova u optimalnoj fazi zrelosti. Najčešći indeksi na osnovu kojih se određuje optimalno vreme berbe su čvrstoća mesa, sadržaj rastvorljivih materija, boja kože. U praksi se često primenjuje i selektivna berba kako bi se poboljšao kvalitet. Ovi podaci se neophodni i u kasnijim fazama skladištenja i čuvanja poljoprivrednih proizvoda na odgovarajućim uslovima. Podaci koji se mogu dobiti iz ove faze proizvodnje mogu biti numerički, kategorički ili slike. U zavisnosti od podataka mogu se primenjivati klasični ANN modeli, a mogu i kombinovani obradom slike i ostalih podataka. Značaj optimalne berbe može se sagledati i sa smanjivanjem nepotrebnog bacanje hrane, ili propadanja proizvoda u toku procesa skladištenja, [69-73].



Slika 14. Detekcija kvaliteta plodova paradajza obradom slike, [74].
Figure 14. Detection of tomato fruit quality by image processing, [74].

ZAKLJUČAK

Brojni radovi koji su poslednjih godina objavljeni na temu primene ML u poljoprivredi pokazuju da je ova tema u vrhu istraživanja. Obzirom na multidisciplinarnost teme, zahteva anagžovanje stručnjaka širokog spektra, što joj takođe daje na aktuelnosti. Iako u radu nisu pokriveni svi aspekti primene ML u ratarskoj, voćarskoj i vinogradarskoj proizvodnji, a posebno u stočarskoj, iz pregleda se može videti da još postoje nerešena pitanja koja daju prostor za istraživanje i sa strane detekcija problema, načina prikupljanja i obrade podataka, a posebno modifikovanja i pronalaženja novih modela ML koji bi u budućnosti mogli da obuhvate čitav proizvodni proces.

Precizna poljoprivreda u osnovi uključuje uoptrebu algoritama ML, kako bi se u realnom vremenu donele važne i tačne odluke o upravljanju proizvodnjom.

Cilj ML modela je da na osnovu prkipljenih podataka mogu da daju realno predviđanje uz maksimalni ućinak u prinosu, a uz minimiziranje ulaznih parametara, kao što su navodnjavanje, đubrenje i primena pesticida.

U većini primera su prikazani ML modeli koji uključuju obradu slike su među najčešćim, što se poklapa sa tehnikama precizne poljoprivrede i načinom uzorkovanja podataka. Ovi modeli i dalje mogu da se razvijaju, posebno u namenskoj primeni u poljoprivredi, a otvoren je prostor za modele koji kombinuju numeričke i grafičke podatke, što otvara vrata za projektovanje složenih biotehničkih informacionih sistema u budućnosti.

LITERATURA

- [1] Food and Agriculture Organization. 2017. The Future of Food and Agriculture—Trends and Challenges. Food and Agriculture Organization of the United Nations: Rome, Italy.
- [2] Powell, N., Ji, X., Ravash, R., Edlington, J., Dolferus, R. 2012. Yield stability for cereals in a changing climate. *Functional Plant Biology*, 39(7), pp. 539-552. <https://doi.org/10.1071/FP12078>.
- [3] Thayer, A.W., Vargas, A., Castellanos, A.A., Lafon, C.W., McCarl, B.A., Roelke, D.L., Winemiller, K.O., Lacher, T.E. 2020. Integrating agriculture and ecosystems to find suitable adaptations to climate change. *Climate*, 8(10), pp. 1-12. <https://doi.org/10.3390/cli8010010>.
- [4] Nassani, A.A., Awan, U., Zaman, K., Hyder, S., Aldakhil, A.M., Abro, M.M.Q. 2019. Management of natural resources and material pricing: Global evidence. *Resources Policy*, 64, pp. 101500. <https://doi.org/10.1016/j.resourpol.2019.101500>.
- [5] Tekinerdogan, B. 2018. Strategies for technological innovation in Agriculture 4.0. Wageningen University, Wageningen, The Netherlands.
- [6] Rose, D.C., Chilvers, J. 2018. Agriculture 4.0: Broadening responsible innovation in an era of smart farming. *Frontiers in Sustainable Food Systems*, 2, pp. 87. <https://doi.org/10.3389/fsufs.2018.00087>.
- [7] Kovács, I., Husty, I. 2018. The role of digitalization in the agricultural 4.0—How to connect the industry 4.0 to agriculture? *Hungarian Agricultural Engineering*, 33, pp. 1-7. <https://doi.org/10.17676/HAE.2018.33.38>.
- [8] Bakkari, M., Khatory, A. 2017. Industry 4.0: Strategy for more sustainable industrial development in SMEs. *Proceedings of the IEOM 7th International Conference on Industrial Engineering and Operations Management*, Rabat, Morocco, April 11-13, pp. 43-49.
- [9] Lee, J., Bagheri, B., Kao, H.-A. 2015. A cyber-physical systems architecture for Industry 4.0-based manufacturing systems. *Manufacturing Letters*, 3, pp. 18-23. <https://doi.org/10.1016/j.mfglet.2014.12.001>.
- [10] Tambakhe, M.D., Gulhane, V.S., Karnewar, J.S. 2019. Machine learning application in the field of agriculture: A review. *International Journal of Research in Advent Technology*, 7(4), pp. 274-276. [10.32622/ijrat.732019123](https://doi.org/10.32622/ijrat.732019123).
- [11] Venkatasubramanian, V. 2018. The promise of artificial intelligence in chemical engineering: Is it Here, Finally?. *AIChE Journal*, 65. No.2., pp. 466-478. <https://doi.org/10.1002/aic.16489>.
- [12] Müller, A.C., Guido, S. 2016. *Introduction to Machine Learning with Python – A Guide for Data Scientists*. O'Reilly Media.

- [13] Siqueira, V.S., Borges, M.M., Furtado, R.G., Dourado, C.N., Costa, R.M. 2021. Artificial intelligence applied to support medical decisions for the automatic analysis of echocardiogram images: A systematic review. *Artificial Intelligence in Medicine*, 120(5), 102165. <https://doi.org/10.1016/j.artmed.2021.102165>.
- [14] K. Dnuggets. Understanding supervised learning: Theory and overview. Dostupno na: <https://www.kdnuggets.com/understanding-supervised-learning-theory-and-overview>. [Pristupljeno 29.11.2024.].
- [15] TechVidvan. Unsupervised learning. Dostupno na: <https://techvidvan.com/tutorials/unsupervised-learning> [Pristupljeno 29.11.2024.].
- [16] Sharma, G. A gentle introduction to semi-supervised learning. *Medium*. Dostupno na: https://medium.com/@gayatri_sharma/a-gentle-introduction-to-semi-supervised-learning-7afa5539beea. [Pristupljeno 29.11.2024.].
- [17] TechVidvan. Reinforcement learning. Dostupno na: <https://techvidvan.com/tutorials/reinforcement-learning>. [Pristupljeno 29.11.2024.].
- [18] Chen, Y.Y., Lin, Y.H., Kung, C.C., Chung, M.H., Yen, I.H. 2019. Design and implementation of cloud analytics-assisted smart power meters considering advanced artificial intelligence as edge analytics in demand-side management for smart homes. *Sensors*, 19(9), 2047. <https://doi.org/10.3390/s19092047>.
- [19] LeCun, Y., Bengio, Y., Hinton, G. 2015. Deep learning. *Nature*, 521(7553), pp. 436–444. <https://doi.org/10.1038/nature14539>.
- [20] De Oliveira, M.A., Monteiro, A.V., Vieira Filho, J. 2018. A new structural health monitoring strategy based on PZT sensors and convolutional neural network. *Sensors*, 18(9), 2955. <https://doi.org/10.3390/s18092955>.
- [21] Anagnostis, A., Benos, L., Tsaopoulos, D., Tagarakis, A., Tsolakis, N., Bochtis, D. 2021. Human activity recognition through recurrent neural networks for human–robot interaction in agriculture. *Applied Sciences*, 11(5), 2188. <https://doi.org/10.3390/app11052188>.
- [22] Pisner, D.A.; Schnyer, D.M. Support Vector Machine; Mechelli, A., Vieira, S.B.T.-M.L., Eds.; Academic Press: Cambridge, MA, USA, 2020; Chapter 6; pp. 101–121. ISBN 978-0-12-815739-8
- [23] Tripathi, P., Kumar, N., Rai, M., Shukla, P.K., Verma, K.N. 2023. Applications of Machine Learning in Agriculture. In: M. Khan, B. Gupta, A. Verma, P. Praveen, & C. Peoples (Eds.), *Smart Village Infrastructure and Sustainable Rural Communities*, IGI Global Scientific Publishing, pp. 99–118. <https://doi.org/10.4018/978-1-6684-6418-2.ch006>.
- [24] Lampridi, M., Sørensen, C., Bochtis, D. 2019. Agricultural sustainability: A review of concepts and methods. *Sustainability*, 11, 5120. <https://doi.org/10.3390/su11185120>.
- [25] Suchithra, M.S., Pai, M.L. 2020. Improving the prediction accuracy of soil nutrient classification by optimizing extreme learning machine parameters. *Information Processing in Agriculture*, 7(1), pp. 72–82. <https://doi.org/10.1016/j.inpa.2019.06.001>.
- [26] Nahvi, B., Habibi, J., Mohammadi, K., Shamshirband, S., Saleh Al Razgan, O. 2016. Using self-adaptive evolutionary algorithm to improve the performance of an extreme learning machine for estimating soil temperature. *Computers and Electronics in Agriculture*, 124, pp. 68–79. <https://doi.org/10.1016/j.compag.2016.03.025>.
- [27] Johann, A.L., de Araújo, A.G., Delalibera, H.C., Hirakawa, A.R. 2016. Soil moisture modeling based on stochastic behavior of forces on a no-till chisel opener. *Computers and Electronics in Agriculture*, 121, pp. 420–428. <https://doi.org/10.1016/j.compag.2015.12.020>.
- [28] Gebbers, A.V.I. 2010. Precision agriculture and food security. *Science*, 327(5967), pp. 828–831. <https://doi.org/10.1126/science.1183899>.

- [29] Chakravarti, A., Joshi, N., Panjiar, H. 2015. Rainfall runoff analysis using artificial neural network. *Indian Journal of Science and Technology*, 8(14), pp. 1–7. <https://doi.org/10.17485/ijst/2015/v8i14/54370>.
- [30] Besalatpour, A., Hajabbasi, M.A., Ayoubi, S., Gharipour, A., Jazi, A.Y. 2012. Prediction of soil physical properties by optimized support vector machines. *International Agrophysics*, 26(2), pp. 121–129. <https://doi.org/10.2478/v10247-012-0017-7>.
- [31] Azizi, A., Gilandeh, Y.A., Mesri-Gundoshmian, T., Saleh Bigdeli, A.A., Moghaddam, H.A. 2020. Classification of soil aggregates: A novel approach based on deep learning. *Soil and Tillage Research*, 199, 104586. <https://doi.org/10.1016/j.still.2020.104586>.
- [32] Zema, D.A., Nicotra, A., Mateos, L., Zimbone, S.M. 2018. Improvement of the irrigation performance in water users associations integrating data envelopment analysis and multi-regression models. *Agricultural Water Management*, 205, pp. 38–49. <https://doi.org/10.1016/j.agwat.2018.04.032>.
- [33] Sawarkar, M., Rode, S.V. 2017. Digital image processing applied to seed purity test. *International Journal of Innovative Research in Electrical, Electronics, Instrumentation and Control Engineering*, 5(5). <https://doi.org/10.17148/IJIREEICE.2017.5539>.
- [34] Awais, M., Naqvi, S.M.Z.A., Zhang, H., et al. 2023. AI and machine learning for soil analysis: An assessment of sustainable agricultural practices. *Bioresources and Bioprocessing*, 10(90). <https://doi.org/10.1186/s40643-023-00710-y>.
- [35] Belsare, P.P., Dewasthale M.M. 2013. Application of image processing for seed quality assessment: A survey. *International Journal of Engineering Research & Technology (IJERT)*, 2(2), Paper ID IJERTV2IS2152.
- [36] Sivakumar, D., SuriyaKrishnaa, K., Akshaya, P., Anuja, G.V., Devadharshini, G.T. 2019. Computerized growth analysis of seeds using deep learning method. *International Journal of Recent Technology and Engineering*, 7(6S5). Paper ID F13380476S519/2019©BEIESP.
- [37] Huang, S., Fan, X., Sun, L., Shen, Y., Suo, X. 2019. Research on classification method of maize seed defect based on machine vision. *Journal of Sensors*, 2019, Article ID 2716975. <https://doi.org/10.1155/2019/2716975>.
- [38] Young, J., Se, J.K., Dayeon, K., Keondo, L., Wan, C.K. 2018. Super-high-purity seed sorter using low-latency image-recognition based on deep learning. *IEEE Robotics and Automation Letters*, 3(4), pp. 2377–2382. <https://doi.org/10.1109/LRA.2018.2849513>.
- [39] Bhurtel, M., Shrestha, J., Lama, N., Bhattarai, S., Uprety, A., & Guragain, M. K. 2019. Deep learning based seed quality tester. In Science, Engineering and Technology (SET) Conference, pp. 1-10.
- [40] Alagumariappan, P., Dewan, N.J., Muthukrishnan, G.N., et al. 2020. Intelligent plant disease identification system using machine learning. *Engineering Proceedings*, 2, 49. <https://doi.org/10.3390/ecsa-7-08160>.
- [41] Savary, S., Ficke, A., Aubertot, J.-N., Hollier, C. 2012. Crop losses due to diseases and their implications for global food production losses and food security. *Food Security*. <https://doi.org/10.1007/s12571-012-0200-5>.
- [42] Sujatha, R., Chatterjee, J.M., Jhanjhi, N.Z., Brohi, S.N. 2021. Performance of deep learning vs machine learning in plant leaf disease detection. *Microprocessors and Microsystems*, 80. <https://doi.org/10.1016/j.micpro.2020.103615>.
- [43] Karadag, K., Tenekeci, M.E., Tasaltı, R., Bilgili, A. 2018. Detection of pepper fusarium disease using machine learning algorithms based on spectral reflectance. *Sustainable Computing: Informatics and Systems*, 8. <https://doi.org/10.1016/j.suscom.2019.01.001>.
- [44] Pandya, I.Y. 2018. Pesticides and their applications in agriculture. *Asian Journal of Applied Science and Technology (AJAST)*, 2(2), pp. 894–900. ISSN: 2456-883X.

- [45] Arsenovic, M., Karanovic, M., Sladojevic, S., Anderla, A., Stefanovic, D. 2019. Solving current limitations of deep learning-based approaches for plant disease detection *Symmetry (Basel)*, 11, 939. <https://doi.org/10.3390/sym11070939>.
- [46] Barbedo, J.G.A. 2019. Plant disease identification from individual lesions and spots using deep learning. *Biosystems Engineering*, 180, pp. 96–107. <https://doi.org/10.1016/j.biosystemseng.2019.02.002>.
- [47] Saleem, M.H., Potgieter, J., Arif, K.M. 2019. Plant disease detection and classification by deep learning. *Plants*, 8, 468. <https://doi.org/10.3390/plants8110468>.
- [48] Harvey, C.A., Rakotobe, Z.L., Rao, N.S., Dave, R., Razafimahatratra, H., Rabarijohn, R.H., Rajaofara, H., MacKinnon, J.L. 2014. Extreme vulnerability of smallholder farmers to agricultural risks and climate change in Madagascar. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 369(1639), 20130089, <https://doi.org/10.1098/rstb.2013.0089>.
- [49] Wu, H., Wiesner-Hanks, T., Stewart, E.L., DeChant, C., Kaczmar, N., Gore, M.A., Nelson, R.J., Lipson, H. 2019. Autonomous detection of plant disease symptoms directly from aerial imagery. *The Plant Phenome Journal*, 2(1), pp. 1–9, <https://doi.org/10.2135/tppj2019.03.0006>.
- [50] Abdu, A.M., Mokji, M.M., Sheikh, U.U. 2020. Automatic vegetable disease identification approach using individual lesion features. *Computers and Electronics in Agriculture*, 176, 105660. <https://doi.org/10.1016/j.compag.2020.105660>.
- [51] Picon, A., Alvarez-Gila, A., Seitz, M., Ortiz-Barredo, A., Echazarra, J., Johannes, A. 2019. Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild. *Computers and Electronics in Agriculture*, 161, pp. 280–290, <https://doi.org/10.1016/j.compag.2018.04.002>.
- [52] Wiesner-Hanks, T., Wu, H., Stewart, E., DeChant, C., Kaczmar, N., Lipson, H., Gore, M.A., Nelson, R.J. 2019. Millimeter-level plant disease detection from aerial photographs via deep learning and crowdsourced data. *Frontiers in Plant Science*, 10, 1550, <https://doi.org/10.3389/fpls.2019.01550>.
- [53] Nawaz, M., Nazir, T., Javed, A., et al. 2022. A robust deep learning approach for tomato plant leaf disease localization and classification. *Scientific Reports*, 12, 18568. <https://doi.org/10.1038/s41598-022-21498-5>.
- [54] Su, W.H. 2020. Advanced Machine Learning in Point Spectroscopy, RGB- and Hyperspectral-Imaging for Automatic Discriminations of Crops and Weeds: A Review. *Smart Cities*, 3, pp. 767–792, <https://doi.org/10.3390/smartcities3030039>.
- [55] Ahmad, J., Muhammad, K., Ahmad, I., Ahmad, W., Smith, M.L., Smith, L.N., Jain, D.K., Wang, H., Mehmood, I. 2018. Visual features based boosted classification of weeds for real-time selective herbicide sprayer systems. *Computers in Industry*, 98, pp. 23–33, <https://doi.org/10.1016/j.compind.2018.02.005>.
- [56] Bah, M.D., Hafiane, A., Canals, R. 2018. Deep learning with unsupervised data labeling for weed detection in line crops in UAV images. *Remote Sensing*, 10(11), 1690. <https://doi.org/10.3390/rs10111690>.
- [57] Barrero, O., Perdomo, S.A. 2018. RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields. *Precision Agriculture*, 19(5), pp. 809–822, <https://doi.org/10.1007/s11119-017-9558-x>.
- [58] Sabzi, S., Abbaspour-Gilandeh, Y. 2018. Using video processing to classify potato plants and three types of weed using hybrid of artificial neural network and particle swarm algorithm. *Measurement*, Volume 126, pp. 22–36. <https://doi.org/10.1016/j.measurement.2018.05.037>.
- [59] Teimouri, N., Dyrmann, M., Nielsen, P.R., Mathiassen, S.K., Somerville, G.J., Jorgensen, R.N. 2018. Weed growth stage estimator using deep convolutional neural networks. *Sensors*, 18(5), 1580. <https://doi.org/10.3390/s18051580>.

- [60] Partel, V., Kakarla, S.C., Ampatzidis, Y. 2019. Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. *Computers and Electronics in Agriculture*, 157, pp.339–350, <https://doi.org/10.1016/j.compag.2018.12.048>.
- [61] Kamath, R., Balachandra, M., Prabhu, S. 2020. Paddy crop and weed discrimination: A multiple classifier system approach. *International Journal of Agronomy*, 2020, <https://doi.org/10.1155/2020/6474536>.
- [62] Zhang, H., Wang, Z., Guo, Y., Ma, Y., Cao, W., Chen, D., Yang, S., Gao, R. 2022. Weed Detection in Peanut Fields Based on Machine Vision. *Agriculture*, 12(10), 1541. <https://doi.org/10.3390/agriculture12101541>.
- [63] Ji, S., Zhang, C., Xu, A., Shi, Y., Duan, Y. 2018. 3D convolutional neural networks for crop classification with multi-temporal remote sensing images. *Remote Sensing*, 10(1), 75, <https://doi.org/10.3390/rs10010075>.
- [64] Nemmaoui, A., Aguilar, M.A., Aguilar, F.J., Novelli, A., Garcia Lorca, A. 2018. Greenhouse crop identification from multi-temporal multi-sensor satellite imagery using object-based approach: A case study from Almería (Spain). *Remote Sensing*, 10(11), 1751, <https://doi.org/10.3390/rs10111751>.
- [65] Piedelobo, L., Hernandez-Lopez, D., Ballesteros, R., Chakhar, A., Del Pozo, S., Gonzalez-Aguilera, D., Moreno, M.A. 2019. Scalable pixel-based crop classification combining Sentinel-2 and Landsat-8 data time series: Case study of the Duero river basin. *Agricultural Systems*, 171, pp. 36–50, <https://doi.org/10.1016/j.agsy.2019.01.005>.
- [66] Sun, C., Bian, Y., Zhou, T., Pan, J. 2019. Using of multi-source and multi-temporal remote sensing data improves crop-type mapping in the subtropical agriculture region. *Sensors*, 19(10), 2401, <https://doi.org/10.3390/s19102401>.
- [67] Wei, S., Zhang, H., Wang, C., Wang, Y., Xu, L. 2019. Multi-temporal SAR data large-scale crop mapping based on U-Net model. *Remote Sensing*, 11(1), 68, <https://doi.org/10.3390/rs11010068>.
- [68] Ngugi, H.N., Ezugwu, A.E., Akinyelu, A.A., et al. 2024. Revolutionizing crop disease detection with computational deep learning: A comprehensive review. *Environmental Monitoring and Assessment*, 196, 302. <https://doi.org/10.1007/s10661-024-12454-z>.
- [69] Genze, N., Bharti, R., Grieb, M., Schultheiss, S.J., Grimm, D.G. 2020. Accurate machine learning-based germination detection, prediction, and quality assessment of three grain crops. *Plant Methods*, 16(1), pp. 1–11, <https://doi.org/10.1186/s13007-020-00699-x>.
- [70] De Medeiros, A.D., Pinheiro, D.T., Xavier, W.A., da Silva, L.J., dos Santos Dias, D.C.F. 2020. Quality classification of *Jatropha curcas* seeds using radiographic images and machine learning. *Industrial Crops and Products*, 146, <https://doi.org/10.1016/j.indcrop.2020.112162>.
- [71] Lee, J., Nazki, H., Baek, J., Hong, Y., Lee, M. 2020. Artificial intelligence approach for tomato detection and mass estimation in precision agriculture. *Sustainability*, 12(21), 9138, <https://doi.org/10.3390/su12219138>.
- [72] Yang, B., Gao, Y., Yan, Q., Qi, L., Zhu, Y., Wang, B. 2020. Estimation method of soluble solid content in peach based on deep features of hyperspectral imagery. *Sensors*, 20(18), 5021, <https://doi.org/10.3390/s20185021>.
- [73] Kamath, R., Balachandra, M., Prabhu, S. 2020. Crop and weed discrimination using Laws' texture masks. *International Journal of Agricultural and Biological Engineering*, 13(1), pp. 191–197, <https://doi.org/10.25165/j.ijabe.20201301.4920>.
- [74] Perales Gómez, Á.L., López-de-Teruel, P.E., Ruiz, A., et al. 2022. FARMIT: Continuous assessment of crop quality using machine learning and deep learning techniques for IoT-based smart farming. *Cluster Computing*, 25, pp. 2163–2178. <https://doi.org/10.1007/s10586-021-03489-9>.

APPLICATION OF MACHINE LEARNING IN AGRICULTURE

**Olivera Ećim-Đurić, Rajko Miodragović, Andrija Rajković, Mihailo Milanović,
Zoran Mileusnić, Aleksandra Dragičević**

*University of Belgrade, Faculty of Agriculture, Institute of Agricultural Engineering,
Belgrade-Zemun, Republic of Serbia*

Abstract. Machine learning (ML) is a key technology driving the modernisation of agriculture. It enables large data sets to be analysed and precise decisions to be made at all stages of agricultural production.

ML is used for soil analysis, plant disease detection, weed control, crop species identification and harvest optimisation. Various techniques such as supervised, unsupervised and reinforcement learning help to improve the accuracy of predictions and decisions. Artificial neural networks (ANN), in particular deep neural networks (DNN) and convolutional neural networks (CNN), efficiently analyse images and numerical data and enable precise management of agricultural practises. These technologies contribute to sustainability by reducing the negative impact on the environment and optimising the use of resources.

While significant progress has already been made, there is still potential for further development of ML models that cover all phases of the agricultural cycle and make precision agriculture more efficient and safer

Key words: *Precision agriculture, machine learning, artificial neural networks, image processing.*

Submitted: 02.12.2024.

Prijavljen:

Revised: 06.12.2024.

Ispravljen:

Accepted: 12.12.2024.

Prihvaćen: