

Strojno i duboko učenje u poljoprivredi:

Kako umjetna inteligencija mijenja način na koji razumijemo tlo i proizvodimo hranu

Strojno učenje (ML) i duboko učenje (DL) su brzo razvijajuće ključne discipline unutar šireg područja umjetne inteligencije (AI) s velikim utjecajem na sve privredne grane što uključuje i poljoprivredu. Kroz analizu podataka i prepoznavanje obrazaca, ove tehnologije omogućavaju donošenje preciznih odluka i optimizaciju procesa u poljoprivrednoj proizvodnji.

Strojno učenje (ML)

Strojno učenje (eng. *machine learning* ili ML) je podskup umjetne inteligencije u okviru kojeg se razvijaju algoritmi modeli koji omogućavaju računalima učenje iz podataka i donošenje odluka bez eksplicitnog programiranja (Alpaydin, 2020). Temeljno, strojno učenje koristi statističke metode za analizu podataka, identificiranje obrazaca i poboljšanje performansi modela kroz iskustvo. Algoritmi strojnog učenja koriste skupove podataka za učenje na temelju kojih se stvara model za stvaranje predikcije ili klasifikacije (Murphy, 2012). Postoji tri glavna oblika strojnog učenja: nadzirano učenje (eng. *supervised learning*) i nenadzirano učenje (eng. *unsupervised learning*). Kod nadziranog učenja model uči na temelju označenih podataka, pri čemu su ulazni podaci povezani s ispravnim izlazima. Cilj je naučiti poveznicu između ulaza i izlaza kako bi se omogućile precizne predikcije na novim podacima (Goodfellow i sur., 2016). Kod nenadziranog učenja model uči iz podataka bez unaprijed definiranih oznaka, tražeći skrivene obrasce i strukture unutar podataka. Primjeri uključuju klasteriranje i redukciju dimenzionalnosti (Hastie i sur., 2009). Strojno učenje koristi različite algoritme kao što su regresija, stablo odluke, k-najbliži susjedi (k-NN), slučajna šuma (eng. *random forest*) i podrška vektorima (SVM, eng. *support vector machine*) za prepoznavanje obrazaca u podacima (James i sur., 2013). Ovi algoritmi mogu s velikom točnošću učiti iz povijesnih podataka, analizirati trenutne informacije i predviđati buduće rezultate. U poljoprivredi se strojno učenje koristi za analizu podataka o tlu, vremenskim uvjetima, upotrebi vode, gnojiva i pesticida. Algoritmi strojnog učenja mogu predviđati prinose usjeva na temelju uvjeta tla, te omogućiti poljoprivrednicima optimiziranje resursa i smanjivanje gubitaka (Kamilaris & Prenafeta-Boldú, 2018).

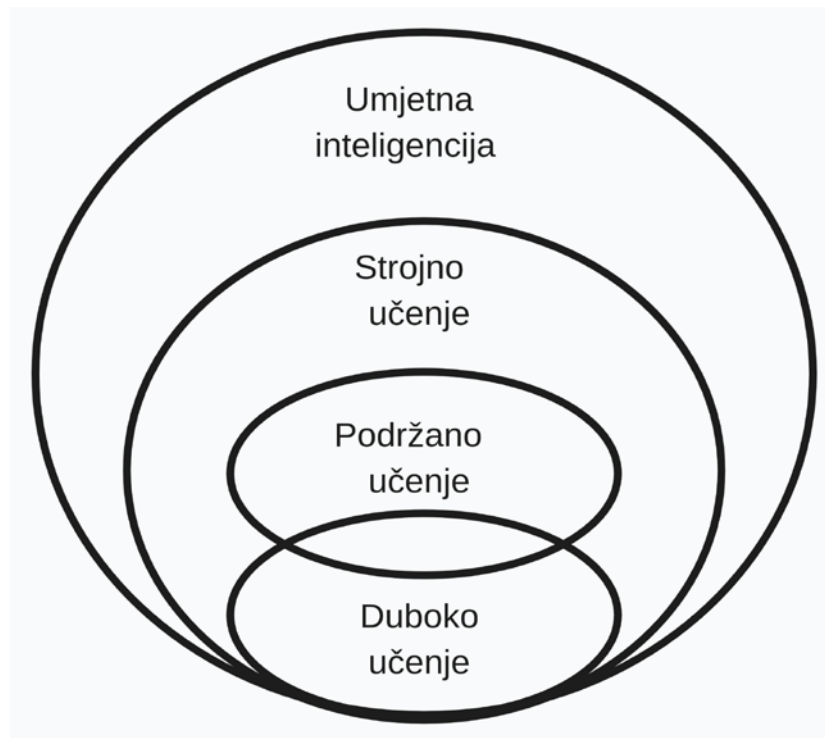
Duboko učenje (DL)

Duboko učenje (DL) je specifična vrsta strojnog učenja koja koristi umjetne neuronske mreže (ANN, eng. *artificial neural networks*) s višestrukim slojevima za analizu i prepoznavanje složenih obrazaca u podacima (LeCun i sur., 2015). Dok strojno učenje može koristiti jednostavnije algoritme, duboko učenje se oslanja na tzv. duboke neuronske mreže s više skrivenih slojeva za analizu velike količine podataka. Dakle, temelj dubokog učenja su umjetne neuronske mreže, koje se, u osnovi, sastoje od ulaznog sloja, jednog ili više skrivenih slojeva te izlaznog sloja (Schmidhuber, 2015). Svaki neuron unutar mreže prima ulazne signale, koji se ponderiraju, kombiniraju i prolaze kroz tzv. aktivacijsku funkciju kako bi proizveli izlaz. Proces učenja uključuje prilagodbu težinskih varijabli među neuronima kako bi se minimizirala pogreška modela (Goodfellow i sur., 2016). Specifične arhitekture dubokog učenja su tzv. konvolucijske neuralne mreže (CNN) čija se specifična arhitektura dubokog učenja koristi posebno za analizu slika, kao i rekurentne neuronske mreže (RNN) čija arhitektura je prilagođena za

analizu sekvencijalnih podataka kao što su npr. vremenske serije. Duboko učenje se od strojnog učenja razlikuje po složenosti i količini podataka. Duboko učenje može obraditi složenije podatke u usporedbi sa strojnim učenjem jer koristi više slojeva za analizu. Nadalje, duboko učenje zahtijeva veće količine podataka i jaču računalnu snagu za učinkovito učenje, dok strojno učenje može funkcionirati i s manjim skupovima podataka i slabijim računalima (Jordan & Mitchell, 2015). Duboko učenje omogućava analizu satelitskih slika i podataka s dronova za identifikaciju različitih vrsta tla, određivanje vlage, te praćenje rasta usjeva. Konvolucijske neuronske mreže koriste se za prepoznavanje bolesti usjeva iz slika, čime se smanjuje potreba za ručnim pregledima i omogućava brza intervencija (Kussul i sur., 2017).

Podržano učenje (RL)

Podržano učenje (eng. *reinforcement learning*) dio je strojnog učenja u kojemu agent (algoritam) uči kroz interakciju s okolinom pri čemu koristi povratne informacije u obliku nagrada ili kazni kako bi poboljšao svoje djelovanje (Sutton i Barto, 2018). Pomoću podržanog učenja izrađuju se alati za optimizaciju procesa odnosno ekspertni sustavi.



Slika 1. Slika prikazuje hijerarhiju unutar umjetne inteligencije (AI). Umjetna inteligencija obuhvaća različite tehnike, koje omogućuju računalima učenje iz podataka. Unutar strojnog učenja nalazi se podržano učenje, tehnika koja koristi povratne informacije za poboljšanje performansi, dok duboko učenje predstavlja specifičnu vrstu strojnog učenja koja koristi umjetne neuronske mreže za obradu velikih količina podataka i rješavanje kompleksnih problema.

Tradicionalne metode analize podataka u poljoprivredi često su spore i neprecizne dok s druge strane, strojno i duboko učenje omogućavaju brže i preciznije analize, optimizaciju resursa i preciznije predviđanje prinosa ili pojavubolesti. Algoritmi ML i DL mogu analizirati velike količine podataka o tlu, vremenu i usjevima u stvarnom vremenu, što omogućava brže donošenje odluka. Poljoprivrednici

moгу koristiti umjetnu inteligenciju (AI) za optimalnu upotrebu vode, gnojiva i pesticida, što smanjuje troškove i utjecaj na okoliš (Akhter i sur., 2021). Osim toga algoritmi mogu predviđati prinose i prepoznati znakove bolesti prije nego što postanu vidljivi, omogućujući pravovremenu intervenciju i smanjenje gubitaka (Kamal i sur., 2019). Strojno i duboko učenje transformiraju poljoprivredu pružajući alate za precizno upravljanje resursima, povećanje produktivnosti i smanjenje negativnog utjecaja na okoliš, čineći poljoprivredu održivijom i učinkovitijom.

Prikupljanje i analiza podataka o tlu

Korištenje strojnog i dubokog učenja u poljoprivredi uvelike se oslanja na prikupljanje i analizu podataka o tlu. S obzirom na ključnu ulogu tla u poljoprivrednoj proizvodnji, prikupljanje podataka s pomoću različitih tehnologija omogućava precizniju i učinkovitiju obradu zemljišta, te povećava produktivnost i održivost poljoprivredne prakse. S razvojem tehnologije, prikupljanje podataka o tlu postalo je mnogo preciznije, pa poljoprivrednici sada imaju pristup različitim izvorima podataka dobivenim putem senzora tla, satelitskih snimki, snimki s dronova, laboratorijskih analiza. Senzori tla su uređaji postavljeni direktno u tlo radi mjerenja različitih parametara kao što su vlažnost, temperatura, sadržaj hranjivih tvari i pH vrijednost. Takvi senzori omogućavaju kontinuirano praćenje uvjeta tla u stvarnom vremenu, čime se osiguravaju podaci potrebni za donošenje pravovremenih i informiranih odluka. Podaci prikupljeni sensorima tla koriste se za optimizaciju navodnjavanja i gnojidbe, čime se smanjuje nepotrebno trošenje resursa (Tangesalu i sur., 2023). Satelitske snimke pružaju podatke o velikim površinama tla, omogućavajući poljoprivrednicima praćenje promjene u strukturi i stanju tla tijekom vremena. Satelitske slike visoke rezolucije koriste se za analizu sadržaja vlage, pokrova vegetacije i detekciju erozije tla (Inoue i sur., 2020). Strojnim učenjem se mogu analizirati satelitske slike kako bi se identificirala područja s različitim tipovima tla ili područja koja zahtijevaju posebnu pozornost glede navodnjavanja i hranjivih tvari (Drusch i sur., 2012).

Dronovi opremljeni kamerama visoke rezolucije koriste se za prikupljanje podataka o tlu na manjim, specifičnim područjima. Opremljeni različitim sensorima, dronovi mogu pružiti podatke o sadržaju vlage, temperaturi tla, razini klorofila u vegetaciji te omogućiti identifikaciju štetnika i bolesti (Tsouros i sur., 2019). Podaci dobiveni dronovima mogu se pomoću strojnog učenja koristiti detaljno kartiranje vlažnosti tla, koje poljoprivrednicima omogućava precizno navodnjavanje (Phang i sur., 2023).

Tradicionalne metode koje uključuju uzimanje uzoraka tla i njihovu analizu u laboratorijima pružaju informacije o kemijskom sastavu tla, poput koncentracije hranjivih tvari (npr. dušik, fosfor, kalij), pH vrijednosti i sadržaja organske tvari (Teshom i sur., 2024). Iako su ove metoda precize, proces uzorkovanja i analize može biti skup i dugotrajan, a prikupljeni podaci često predstavljaju samo mali dio ukupne površine poljoprivrednog zemljišta.

Vrste podataka za ML i DL

Podaci o tlu koji se mogu procesuirati s ML i DL mogu se podijeliti na: fizikalna svojstva tla, kemijska svojstva tla, vlažnost tla, temperaturu tla i pH vrijednost tla. Od fizikalnih svojstava tla najvažniji su tekstura, poroznost i gustoća. Tekstura tla je udio pijeska, mulja i gline u tlu, što utječe na sposobnost tla da zadržava vodu i hranjive tvari (Hillel, 2008), a poroznost tla je količina zraka i vode koja može proći kroz tlo, što utječe na drenažu i opskrbu korijenja biljaka kisikom. Gustoća tla (specifična masa određenog volumena) utječe na sposobnost tla da podrži biljke i zadrži vodu (Dexter, 2004). U kemijska

svojstva tla spadaju koncentracije esencijalnih hranjivih tvari poput dušika (N), fosfora (P) i kalija (K), koje su ključne za rast biljaka (Brady & Weil, 2016) te količina organske tvari u tlu, koja poboljšava plodnost i sposobnost tla za zadržavanje vode (Lal, 2004). Vlažnost je ključni čimbenik rasta usjeva, a određuje se pomoću senzora tla, satelitskih slika ili dronova (Gong i sur., 2017). Temperatura tla utječe na klijanje sjemena, rast korijena i mikrobiološke aktivnosti u tlu. Podaci o temperaturi tla mogu se prikupljati senzorima ili satelitskim snimkama. pH tla utječe na dostupnost hranjivih tvari biljaka i aktivnost mikroorganizama. Optimalna pH vrijednost varira ovisno o vrsti usjeva (Foth & Ellis, 1997).

Obrada podataka puitem ML i DL

Strojno učenje koristi različite metode za analizu podataka o tlu kako bi se iz njih izvukle korisne informacije i donijele bolje odluke o upravljanju zemljištem. Regresijski modeli se koriste za predviđanje kontinuiranih varijabli, poput vlažnosti tla, na temelju skupa ulaznih značajki (Ahumada i sur., 2020). Na primjer, pomoću linearne regresije mogu se predvidjeti promjene vlažnosti tla na temelju klimatskih uvjeta, što poljoprivrednicima omogućava planiranje navodnjavanja. Klasifikacija je tehnika strojnog učenja koja se koristi za razvrstavanje uzoraka u unaprijed definirane kategorije. Na primjer, algoritmi kao što su podrška vektorima (SVM) i k-najbliži susjedi (k-NN) mogu se koristiti za klasifikaciju tipova tla na temelju njihovih kemijskih i fizičkih svojstava (Ramcharan i sur., 2017). To omogućava precizno određivanje najbolje vrste usjeva za određeno tlo. Klasteriranje je metoda nenadziranog učenja koja grupira podatke na temelju sličnosti. U poljoprivredi se koristi za identificiranje zona unutar poljoprivrednog zemljišta koje dijele slična svojstva tla, čime se omogućava precizno upravljanje resursima (Cai i sur., 2019).

Duboko učenje koristi neuronske mreže s višestrukim slojevima za obradu složenih podataka o tlu. Na primjer, konvolucijske neuronske mreže (CNN) koriste se za analizu slika tla, dok rekurentne neuronske mreže (RNN) mogu predvidjeti promjene u vlažnosti tla na temelju vremenskih serija podataka (Cai i sur., 2020). Pomoću algoritama strojnog učenja, kao što su Random Forest, poljoprivrednici mogu dobiti uvid u najvažnije čimbenike koji utječu na prinos usjeva i planirati poljoprivredne prakse prema tim podacima (Attri i sur., 2023).

Primjene strojnog učenja u poljoprivredi

Strojno učenje (ML) postalo je ključni alat u modernoj poljoprivredi, pružajući mogućnost za preciznije upravljanje resursima, povećanje prinosa i smanjenje negativnog utjecaja na okoliš. Različite primjene ML-a, kao što su predviđanje prinosa usjeva, optimizacija navodnjavanja, upravljanje gnojivom i identifikacija bolesti, transformiraju način na koji poljoprivrednici donose odluke. Jedan od najvažnijih izazova u poljoprivredi je točno predviđanje prinosa usjeva, što omogućava bolju alokaciju resursa i planiranje (Basso & Liu, 2019). Strojno učenje koristi se za predviđanje prinosa na temelju podataka o tlu, vremenskim uvjetima, agrotehničkim mjerama i povijesnim podacima o usjevima. Linearna regresija i višestruka linearna regresija koriste se za kvantificiranje utjecaja različitih čimbenika na prinos. Random Forest algoritam može identificirati ključne čimbenike koji utječu na prinos i pružiti precizna predviđanja (Akhter i Sofi 2021.). U studiji koja je ispitala prinos pšenice, Random Forest pokazao je visoku točnost u predviđanju na temelju agronomskih i klimatskih podataka (Feng i sur., 2019). Duboko učenje putem neuronskih mreža također se koristi za predviđanje prinosa. Primjer je

upotreba umjetnih neuronskih mreža (ANN) u predviđanju prinosa soje na temelju podataka o tlu, kišnim padalinama i temperaturama (Chlingaryan i sur., 2018).

Korištenje ML-a omogućava poljoprivrednicima da unaprijed identificiraju potencijalne izazove i optimiziraju upotrebu resursa, što rezultira povećanjem produktivnosti i smanjenjem rizika od neuspjeha usjeva. Navodnjavanje je ključni aspekt poljoprivredne proizvodnje, ali je često izazov pronaći ravnotežu između prekomjerne i nedovoljne opskrbe vodom. Strojno učenje pomaže u preciznoj kontroli i optimizaciji navodnjavanja na temelju trenutne vlažnosti tla, vremenskih prognoza i potreba usjeva (Ojha i sur., 2015).

K-nearest neighbors (k-NN) algoritam koristi se za klasifikaciju različitih područja poljoprivrednog zemljišta prema potrebama za vodom. U jednoj studiji, k-NN je uspješno korišten za identifikaciju vlažnosti tla u različitim zonama, omogućavajući precizno navodnjavanje (Raja i sur., 2020). Podrška vektorima (SVM) je algoritam korišten za optimizaciju raspodjele vode na temelju trenutne razine vlage i predviđenih vremenskih uvjeta, što je rezultiralo značajnim smanjenjem potrošnje vode (Kasera i sur., 2024). Kombinacija senzora tla i neuronskih mreža može omogućiti precizno praćenje vlage u tlu i automatsku prilagodbu navodnjavanja. U studiji koja je koristila duboke neuronske mreže, model je bio u stanju precizno predviđati optimalne količine vode potrebne za navodnjavanje usjeva (Eli-Chukwu, 2019).

Korištenje ML-a za optimizaciju navodnjavanja omogućava poljoprivrednicima da smanje potrošnju vode i minimiziraju gubitke, čime se doprinosi održivoj poljoprivredi. Optimalno korištenje gnojiva ključno je za održavanje zdravlja tla i povećanje prinosa usjeva, ali prekomjerna upotreba može dovesti do zagađenja okoliša. Strojno učenje može analizirati podatke o tlu i usjevima kako bi preporučilo optimalne količine i vrste gnojiva. Na temelju analiza tla, vremenskih uvjeta i faze rasta biljaka, regresijski modeli koriste se za izračunavanje optimalnih količina gnojiva. Algoritmi kao što je Decision Tree koriste se za donošenje odluka o primjeni gnojiva na temelju karakteristika tla, vrsti usjeva i agronomskih preporuka (Akter i Sofi., 2021). Konvolucijske neuronske mreže (CNN) mogu analizirati slike tla i biljaka za identifikiranje znakova nedostatka hranjivih tvari, što omogućava preciznu prilagodbu gnojidbe (Jahromi i sur., 2023).

Primjena ML-a omogućava poljoprivrednicima da smanje troškove gnojidbe, poboljšaju prinos i minimiziraju negativne učinke na okoliš. Identifikacija i kontrola bolesti usjeva predstavljaju značajan izazov u poljoprivredi, a tradicionalne metode inspekcije često su dugotrajne i nepouzdana. Strojno učenje nudi učinkovite alate za automatsko prepoznavanje bolesti i štetnika na usjevima pomoću analize slika i podataka.

Konvolucijske neuronske mreže (CNN) se koriste za prepoznavanje bolesti na temelju slika biljaka. Na primjer, u studiji koja je koristila CNN za prepoznavanje bolesti u usjevima rajčice, algoritam je postigao visoku točnost u prepoznavanju različitih vrsta bolesti (Ferentinos, 2018). Strojno učenje putem nadziranog učenja, npr. modeli kao što je Random Forest koriste se za analizu podataka o vremenu, vlažnosti i temperaturi kako bi se predvidjelo izbijanje bolesti (Boulent i sur., 2019). Algoritmi strojnog učenja koriste se za prepoznavanje prisutnosti štetnika na usjevima pomoću senzora i slika, što omogućava brzu intervenciju i zaštitu usjeva (Barbedo, 2013). Automatsko prepoznavanje bolesti omogućava poljoprivrednicima da rano identificiraju probleme i poduzmu mjere prije nego što dođe do ozbiljnih šteta, što rezultira značajnim uštedama i povećanjem prinosa.

Duboko učenje i analize tla

Duboko učenje (DL) postalo je jedan od najvažnijih alata za analizu tla u poljoprivredi jer omogućava automatiziranu analizu složenih podataka i pruža precizne informacije o stanju tla. DL se temelji na korištenju umjetnih neuronskih mreža s višestrukim slojevima, što omogućava prepoznavanje uzoraka i značajki u velikim količinama podataka o tlu.

Analiza satelitskih slika i podataka s dronova omogućava pristup detaljnim informacijama o stanju tla i vegetacije, što je ključno za procjenu produktivnosti poljoprivrednog zemljišta. Duboko učenje omogućava automatsko prepoznavanje uzoraka na slikama visoke rezolucije te identifikaciju promjena u stanju tla u realnom vremenu.

Konvolucijske neuronske mreže (CNN) koriste se za obradu satelitskih slika velikih površina poljoprivrednog zemljišta. CNN omogućava prepoznavanje različitih tipova tla, vlažnosti i pokrova vegetacije. Na primjer, CNN je uspješno korišten za klasifikaciju poljoprivrednih parcela na temelju tipova tla u različitim regijama, što je pomoglo u identifikaciji potencijalno produktivnih područja (Ma i sur., 2019). Dronovi opremljeni kamerama visoke rezolucije prikupljaju slike tla i vegetacije, koje se zatim analiziraju pomoću dubokog učenja. Studija koju su proveli Rahman i sur. (2021) pokazala je da CNN može precizno klasificirati različite faze rasta usjeva i prepoznati znakove bolesti, omogućujući poljoprivrednicima pravovremenu intervenciju. RNN su također korištene za analizu podataka sa satelitskih slika i dronova, osobito za praćenje vremenskih serija podataka o promjenama stanja tla tijekom vremena (Maggiori i sur., 2016). Ovo omogućava praćenje sezonskih promjena u vegetaciji i vlažnosti tla, pružajući važne informacije za planiranje poljoprivrednih aktivnosti.

Upotreba CNN-a za analizu satelitskih podataka sa Sentinel-2 omogućila je precizno mapiranje tipova tla i vegetacijskih indeksa u poljoprivrednim područjima (Phiri i sur., 2020). Upotreba dronova za prikupljanje podataka u kombinaciji s dubokim učenjem omogućila je automatsko prepoznavanje područja koja su podložna eroziji tla i zahtijevaju intervenciju (Bendig i sur., 2015).

Duboko učenje omogućava razvoj naprednih modela za detekciju uzoraka i klasifikaciju različitih tipova tla, što je ključno za preciznu poljoprivredu. Klasifikacija tla uključuje prepoznavanje karakteristika kao što su tekstura, sastav i vlažnost, što utječe na izbor usjeva i poljoprivrednih praksi.


Generative Adversarial Networks (GANs) se koriste za generiranje sintetičkih podataka o tlu, što može pomoći u obuci modela za klasifikaciju tla kada su dostupni podaci ograničeni (Guerra i sur., 2024). CNN su pokazali visoku točnost u klasifikaciji tipova tla na temelju satelitskih slika i podataka s dronova. Na primjer, CNN je korišten za prepoznavanje i klasifikaciju područja s različitim tipovima tla (npr. pješčano, ilovasto, glinasto) s točnošću većom od 90% (Zhang i sur., 2020). Duboko učenje omogućava praćenje promjena vlažnosti tla kroz različita vremenska razdoblja, što je ključno za optimizaciju navodnjavanja. CNN i LSTM (Long Short-Term Memory) mreže korištene su za analizu satelitskih podataka kako bi se identificirala sušna područja i predvidjele promjene u vlažnosti tla (Guerra i sur., 2024).

Integracija podataka

Jedna od najvećih prednosti dubokog učenja je sposobnost integracije različitih izvora podataka kako bi se dobila sveobuhvatna slika stanja tla. Kombinacija satelitskih slika, podataka s dronova i podataka

sa senzora tla omogućava precizniju analizu i donošenje informiranih odluka. Multimodalni modeli dubokog učenja kombiniraju različite vrste podataka, uključujući slike, vremenske serije i tekstualne podatke, radi preciznije analize tla (Xu i sur., 2019). Na primjer, model koji koristi satelitske slike i podatke sa senzora može pružiti detaljnu procjenu plodnosti tla i potreba za navodnjavanjem. Upotreba Long Short-Term Memory (LSTM) mreža se koristi za obradu vremenskih serija podataka o vlažnosti i temperaturi tla, omogućujući predviđanje budućih stanja na temelju prošlih podataka (Park i sur., 2022). Ovo je posebno korisno za poljoprivrednike u planiranju navodnjavanja i gnojidbe. U studiji Teshome i sur. (2024), podaci dobiveni sa senzora tla kombinirani su sa satelitskim slikama kako bi se stvorio model dubokog učenja koji može precizno procijeniti sadržaj vlage u tlu u realnom vremenu. Ova kombinacija omogućila je preciznije navodnjavanje i povećanje produktivnosti usjeva.

Kombinacija radarskih podataka sa satelita Sentinel-1 i senzorskih podataka s tla omogućila je preciznu analizu vlažnosti tla pomoću dubokog učenja (Chung i sur., 2022), a podaci prikupljeni dronovima korišteni su zajedno s podacima sa senzora kako bi se kreirala karta plodnosti tla koja je pomogla poljoprivrednicima u optimizaciji gnojidbe i navodnjavanja (Bendig i sur., 2015).



Slika 2. Ova slika prikazuje pametnu poljoprivredu koja koristi tehnologije poput IoT uređaja, dronova, satelita i umjetne inteligencije (AI) za optimizaciju proizvodnje. IoT senzori na terenu prikupljaju podatke o usjevima i tlu, dok dronovi i sateliti pružaju dodatne informacije iz zraka. AI obrađuje te podatke i pomaže poljoprivrednicima u donošenju boljih odluka o upravljanju zemljištem i usjevima, čime se poboljšava prinos i smanjuju troškovi.

Prednosti primjene AI u poljoprivredi

Primjena umjetne inteligencije (AI) u poljoprivredi donosi brojne prednosti koje transformiraju tradicionalne metode uzgoja i upravljanja poljoprivrednim resursima. AI omogućava preciznije i učinkovitije upravljanje resursima, povećava produktivnost, promiče održivost i omogućava brže donošenje odluka. U nastavku su detaljno opisane glavne prednosti primjene AI u poljoprivredi. Jedna

od najvažnijih prednosti AI-a u poljoprivredi je sposobnost preciznog upravljanja resursima, što dovodi do povećanja produktivnosti i smanjenja troškova. Korištenje AI-a omogućava poljoprivrednicima optimizaciju upotrebu vode, gnojiva i pesticida, smanjujući tako nepotrebne troškove i povećavajući prinose. AI sustavi koriste senzore i algoritme strojnog učenja za praćenje vlage u tlu, vremenskih uvjeta i potreba biljaka, što omogućava precizno navodnjavanje (Eli-Chukwu, 2019). Primjena AI-a može značajno smanjiti količinu potrošene vode, što je ključno u područjima s ograničenim zalihama vode. Studija koju su proveli Jiménez i sur. (2020) pokazala je da je upotreba AI-a za optimizaciju navodnjavanja smanjila potrošnju vode za više od 30%, dok je prinos usjeva povećan za 20%.

AI može analizirati podatke o tlu, vegetaciji i potrebama biljaka kako bi se odredile optimalne količine i vrste gnojiva (Akhter i Sofi., 2021). Ovim pristupom poljoprivrednici mogu smanjiti prekomjernu upotrebu gnojiva, što ne samo da smanjuje troškove nego i sprječava zagađenje okoliša. Primjena AI-a rezultirala je povećanjem prinosa u različitim usjevima, uključujući pšenicu, kukuruz i rižu, s prosječnim povećanjem prinosa od 15% do 25% (Feng i sur., 2019).

Algoritmi AI-a omogućuju poljoprivrednicima predviđanje prinose usjeva na temelju vremenskih uvjeta, stanja tla i agronomskih praksi (Basso & Liu, 2019). To im omogućava planiranje aktivnosti poput žetve i skladištenja unaprijed, smanjujući gubitke i povećavajući učinkovitost.

Održivost

AI igra ključnu ulogu u promicanju održive poljoprivrede, omogućujući smanjenje negativnog utjecaja poljoprivrednih aktivnosti na okoliš. Upotreba AI-a pomaže u minimiziranju upotrebe pesticida, vode i gnojiva, čime se smanjuje zagađenje i degradacija okoliša. AI sustavi za prepoznavanje i praćenje bolesti i štetnika omogućuju poljoprivrednicima da precizno cilje na područja zahvaćena štetnicima, umjesto da koriste pesticide na cijelom polju (Boulent i sur., 2019). Na taj način smanjuje se ukupna količina korištenih pesticida, što doprinosi zaštiti tla i vodnih resursa. Studija koju je proveo Barbedo (2013) pokazala je da je upotreba AI-a za praćenje štetnika rezultirala smanjenjem upotrebe pesticida za 40% bez smanjenja prinosa. Korištenje AI sustava za precizno navodnjavanje može smanjiti gubitak vode i osigurati da biljke dobivaju točno onoliko vode koliko im je potrebno. To je osobito važno u regijama s ograničenim vodenim resursima (Ojha i sur., 2015). Primjena AI-a u optimizaciji navodnjavanja smanjila je upotrebu vode za 20-40% u usporedbi s tradicionalnim metodama (Kasera i sur., 2024). AI se koristi za praćenje i analizu kvalitete tla te za optimizaciju gnojidbe, čime se sprječava prekomjerna upotreba gnojiva koja može dovesti do zagađenja tla i podzemnih voda. Precizno upravljanje gnojidbom putem AI-a može značajno smanjiti ispiranje hranjivih tvari i eroziju tla, čime se održava njegova plodnost na dugoročnoj osnovi.

Točno i brzo donošenje odluka

AI omogućava analizu velikih količina podataka u realnom vremenu, što poljoprivrednicima pomaže u bržem i točnijem donošenju odluka. To je ključno u situacijama koje zahtijevaju brzu reakciju, kao što su izbijanja bolesti, promjene vremenskih uvjeta ili prilagodbe u upravljanju resursima. AI sustavi mogu analizirati vremenske podatke i predviđati promjene, što poljoprivrednicima omogućava prilagodbu aktivnosti poput navodnjavanja, sjetve i žetve (Kompenburg i sur., 2020). To pomaže u izbjegavanju rizika povezanih s ekstremnim vremenskim uvjetima.

Primjena AI-a u prepoznavanju bolesti usjeva omogućava poljoprivrednicima identifikaciju i pravovremenu reakciju na probleme u ranim fazama razvoja bolesti, smanjujući gubitke u prinosu (Ferentinos, 2018). Algoritmi strojnog učenja mogu analizirati slike biljaka i prepoznati znakove bolesti s visokom točnošću, često prije nego što su simptomi vidljivi golim okom. AI sustavi su u nekim slučajevima postigli točnost od 98% u prepoznavanju bolesti biljaka, što je znatno brže i preciznije od tradicionalnih metoda inspekcije (Chlingaryan i sur., 2018).

Robotski sustavi opremljeni AI-om koriste se za obavljanje zadataka kao što su plijevljenje, žetva i sadnja, što smanjuje potrebu za ručnim radom i povećava učinkovitost (Saiz-Rubio & Rovira-Más, 2020). Automatizacija omogućava poljoprivrednicima da brže reagiraju na promjene na terenu i povećaju produktivnost. Studije pokazuju da upotreba robotskih sustava u poljoprivredi može smanjiti troškove rada za 30-50% (Bechar & Vigneault, 2017).

Izazovi i ograničenja

Iako primjena umjetne inteligencije (AI) u poljoprivredi donosi brojne prednosti, postoji niz izazova i ograničenja koja usporavaju širu primjenu ovih tehnologija. Neki od ključnih izazova uključuju prikupljanje i kvalitetu podataka, pristupačnost i troškove implementacije, te potrebu za edukacijom i prihvaćanjem novih tehnologija od strane poljoprivrednika.

Jedan od glavnih izazova u primjeni AI u poljoprivredi je prikupljanje i osiguranje kvalitete podataka. AI modeli ovise o velikim skupovima podataka za treniranje, što znači da je kvaliteta i dostupnost podataka ključna za uspješnu implementaciju. Ruralna područja često imaju ograničen pristup modernoj tehnologiji za prikupljanje podataka, što otežava dobivanje točnih i ažuriranih podataka o uvjetima tla, vremenu i usjevima (Kamilaris & Prenafeta-Boldú, 2018). Nedostatak podataka može dovesti do nepouzdanih AI modela koji nisu prilagođeni lokalnim uvjetima, čime se smanjuje njihova učinkovitost i korisnost. Za razvoj pouzdanih AI modela potrebni su kvalitetni, reprezentativni i dobro strukturirani podaci. Često se podaci prikupljaju iz različitih izvora (senzori, sateliti, dronovi), što može dovesti do nedosljednosti u kvaliteti i formatu (Chlingaryan i sur., 2018). Nepravilno ili nepotpuno prikupljanje podataka može dovesti do pogrešnih odluka i smanjene učinkovitosti AI modela (Wolfert i sur., 2017). U mnogim zemljama u razvoju, pristup tehnologiji za prikupljanje podataka je ograničen zbog visokih troškova i nedostatka infrastrukture (Fountas i sur., 2020). To stvara jaz između razvijenih i nerazvijenih poljoprivrednih sustava u smislu primjene AI tehnologija.

Implementacija tehnologija strojnog učenja (ML) i dubokog učenja (DL) u poljoprivredi zahtijeva značajna ulaganja, što predstavlja izazov za mnoge poljoprivrednike, posebno one u ruralnim ili manje razvijenim područjima. Korištenje naprednih AI alata, kao što su senzori, dronovi, sateliti i računalne platforme, može biti skupo, a mnogi poljoprivrednici si ne mogu priuštiti te troškove (Henrietta i sur., 2024). Troškovi održavanja i nadogradnje ovih tehnologija dodatno povećavaju financijski teret, čineći ih nepristupačnim za manja poljoprivredna gospodarstva (Fleming i sur., 2021). Pristup brzom internetu i električnoj energiji često je ograničen u ruralnim područjima, što otežava implementaciju AI tehnologija (Wolfert i sur., 2017). Bez odgovarajuće infrastrukture, poljoprivrednici nisu u mogućnosti u potpunosti iskoristiti potencijal AI-a. Uvođenje AI tehnologija zahtijeva edukaciju poljoprivrednika i osposobljavanje za korištenje novih alata. Međutim, nedostatak pristupa edukaciji i resursima za obuku može biti prepreka za primjenu AI tehnologija (Liakos i sur., 2018). Potrebne su kontinuirane investicije u edukaciju i tehničku podršku kako bi se poljoprivrednicima omogućilo uspješnu primjenu AI tehnologije na svojim gospodarstvima (Rijswijk i sur., 2019). Itraživanje

provedeno u Australiji pokazalo je da su visoki troškovi i nedostatak pristupa AI tehnologijama glavni razlozi zašto manji poljoprivrednici izbjegavaju ulaganje u ove tehnologije (Fleming i sur., 2021).

Jedan od ključnih izazova uvođenja AI tehnologija u poljoprivredi je spremnost poljoprivrednika da prihvate i usvoje nove tehnologije. Tradicionalne poljoprivredne prakse duboko su ukorijenjene, a mnogi poljoprivrednici mogu biti skeptični prema korištenju tehnologija koje ne razumiju u potpunosti. Poljoprivrednici su često oprezni kada je riječ o promjenama u tradicionalnim praksama, posebno ako ne vide odmah koristi ili ako smatraju da su AI tehnologije prekomplikirane (Klerkx i sur., 2019). Nedostatak povjerenja u tehnologije također može biti uzrokovan strahom od gubitka kontrole nad procesima proizvodnje (Rose i sur., 2018). Poljoprivrednici često nemaju potrebna znanja i vještine za korištenje AI tehnologija, zbog čega je nužna edukacija kako bi se povećala njihova sposobnost i povjerenje u primjenu AI-a (Liakos i sur., 2018). Nedostatak edukacijskih programa i tehničke podrške u mnogim ruralnim područjima otežava primjenu AI tehnologija u praksi (Fountas i sur., 2020). Istraživanja pokazuju da su poljoprivrednici koji su bolje informirani o prednostima AI tehnologija spremniji investirati i koristiti ih na svojim gospodarstvima (Weltzien, 2016). Međutim, u mnogim slučajevima, poljoprivrednici nisu svjesni potencijala AI-a i nisu voljni ulagati vrijeme i novac u učenje novih tehnologija (Eastwood i sur., 2019).

Realni primjeri implementacije ML i DL

Stvarni primjeri iz prakse pokazuju kako se strojno učenje i duboko učenje uspješno primjenjuju u analizi tla, optimizaciji poljoprivredne proizvodnje i preciznom upravljanju resursima. Ove tehnologije omogućuju poljoprivrednicima optimizaciju upotrebu resursa, poboljšuju prinose i smanjuju negativan utjecaj na okoliš. Istovremeno, mnogi startupovi i istraživačke institucije aktivno rade na razvoju AI rješenja za poljoprivredu, što ubrzava širenje i primjenu ovih inovativnih tehnologija.

1. Netafim

Netafim, izraelski lider u poljoprivrednoj tehnologiji, razvio je sustav navodnjavanja temeljen na AI koji koristi senzore za praćenje vlažnosti tla i vremenskih uvjeta, a zatim primjenjuje algoritme strojnog učenja za optimizaciju navodnjavanja (Netafim, 2021). Ovaj sustav omogućava precizno navodnjavanje u stvarnom vremenu, smanjujući potrošnju vode do 30% i povećavajući prinos za više od 15%. Optimizacija navodnjavanja rezultirala je značajnim uštedama vode, što je osobito važno u sušnim područjima kao što je Izrael (Assouline i sur., 2015).

2. PlantVillage

PlantVillage, projekt vođen od strane Sveučilišta Penn State, koristi duboko učenje za prepoznavanje bolesti biljaka na temelju fotografija snimljenih pametnim telefonima (Hughes & Salathé, 2015). PlantVillage koristi konvolucijske neuronske mreže (CNN) za analizu slika i prepoznavanje bolesti s visokom točnošću. Aplikacija omogućava poljoprivrednicima diljem svijeta lakšu i bržu identifikaciju bolesti usjeva u ranoj fazi, čime se smanjuje uporaba pesticida i povećava produktivnost (Mohanty i sur., 2016). PlantVillage je dostupan u više od 60 zemalja i koristi ga više od milijun poljoprivrednika.

3. Startup FarmShots

FarmShots, startup sa sjedištem u SAD-u, koristi satelitske snimke i algoritme strojnog učenja za analizu stanja usjeva i tla. Njihov sustav identificira područja s manjkom hranjivih tvari i predlaže optimalne količine gnojiva (FarmShots, 2020). Poljoprivrednici mogu pratiti zdravlje svojih usjeva u stvarnom vremenu i precizno primijeniti gnojiva, što smanjuje troškove i zagađenje okoliša. FarmShots je smanjio upotrebu gnojiva za 20% i povećao prinose za više od 10% u usporedbi s tradicionalnim metodama gnojidbe (Schimmelpfennig, 2016).

4. Startup Resson

Resson, kanadski startup, razvio je AI platformu koja koristi podatke prikupljene s dronova i senzora za otkrivanje štetnika i bolesti na usjevima. Algoritmi strojnog učenja analiziraju slike i podatke te pružaju poljoprivrednicima informacije o lokaciji i opsegu problema (Resson, 2021). Poljoprivrednici mogu poduzeti ciljane mjere za suzbijanje štetnika, što smanjuje upotrebu pesticida i štiti okoliš. Ressonova tehnologija omogućila je poljoprivrednicima da smanje upotrebu pesticida za 40%, što je dovelo do smanjenja troškova i zaštite okoliša (Vincent, 2018).

5. IBM Watson Decision Platform for Agriculture

IBM Watson Decision Platform koristi strojno učenje i analitiku za pružanje preporuka poljoprivrednicima u vezi s navodnjavanjem, gnojidbom i zaštitom usjeva. Sustav koristi podatke o vremenskim uvjetima, satelitske slike i podatke sa senzora kako bi poljoprivrednicima pomogao u donošenju informiranih odluka (IBM, 2021). Poljoprivrednici mogu koristiti platformu za optimizaciju upravljanja svojim poljima, što dovodi do povećanja prinosa i smanjenja troškova. U jednoj studiji, korištenje IBM Watson platforme rezultiralo je povećanjem prinosa usjeva za 30% i smanjenjem upotrebe vode za 20%.

6. Blue River Technology

Blue River Technology, startup iz Kalifornije, razvio je sustav „See & Spray“ koji koristi računalni vid i strojno učenja za prepoznavanje korova u poljima te cilja prskanje herbicidima samo na korov, čime se smanjuje upotreba herbicida za 90% (Blue River Technology, 2020). Ovaj sustav značajno smanjuje troškove i negativan utjecaj na okoliš.

7. Prospera Technologies

Izraelski startup Prospera Technologies koristi strojno učenje za analizu slika usjeva prikupljenih iz staklenika i polja, pružajući podatke o zdravlju biljaka i optimalnom vremenu za zalijevanje i gnojidbu (Prospera Technologies, 2021).

8. Sveučilište Wageningen u Nizozemskoj

Ovo sveučilište je vodeće u istraživanju primjene AI-a u poljoprivredi. Jedan od njihovih projekata je "Digital Farming", koji koristi strojno učenje za optimizaciju upravljanja poljoprivrednim resursima, kao što su voda i hranjive tvari (Wageningen University, 2021).

9. AgFunder

AgFunder je globalna platforma koja podržava istraživačke projekte i startupove u poljoprivredi koristeći AI i big data tehnologije (AgFunder, 2019). AgFunder je podržao brojne inicijative koje razvijaju AI rješenja za precizno upravljanje usjevima, navodnjavanje i zaštitu biljaka.

10. Projekt SoilGrids

SoilGrids je globalni projekt koji koristi strojno učenje za stvaranje detaljnih karata svojstava tla na globalnoj razini (Hengl i sur., 2017). Projekt koristi podatke iz različitih izvora, uključujući laboratorijske analize tla, satelitske snimke i podatke o vremenu, kako bi generirao karte koje prikazuju fizikalna i kemijska svojstva tla na različitim dubinama. Poljoprivrednici, istraživači i donositelji odluka mogu koristiti ove karte za planiranje poljoprivrednih aktivnosti, odabir usjeva i optimizaciju gnojidbe. SoilGrids omogućava brzu i točnu procjenu stanja tla na velikim površinama, što pomaže u planiranju održivih poljoprivrednih praksi.

11. Projekt EOS Crop Monitoring

EOS Crop Monitoring koristi strojno učenje i satelitske podatke za praćenje usjeva u stvarnom vremenu i predviđanje prinosa (EOS Data Analytics, 2021). Platforma analizira vegetacijske indekse, meteorološke podatke i stanje tla te pruža poljoprivrednicima informacije o stanju usjeva, potrebama za navodnjavanjem i gnojidbom. Poljoprivrednici mogu koristiti ove podatke za optimizaciju upravljanja usjevima, planiranje žetve i smanjenje rizika od štetnih utjecaja vremenskih uvjeta. Ova tehnologija pomaže poljoprivrednicima da povećaju prinose za 10-15% i smanje troškove proizvodnje (EOS Data Analytics, 2021).

12. Projekt iUNU LUNA

iUNU je američki startup koji je razvio LUNA, AI sustav koji koristi kamere i senzore za praćenje rasta biljaka u staklenicima (iUNU, 2021). LUNA koristi strojno učenje za analizu podataka o temperaturi, vlažnosti, količini svjetla i stanju biljaka te automatski prilagođava uvjete u stakleniku kako bi se osigurao optimalan rast biljaka. Sustav omogućava precizno upravljanje staklenicima, smanjujući potrebu za ljudskim radom i povećavajući učinkovitost. Poljoprivrednici koji koriste LUNA sustav zabilježili su povećanje prinosa od 20-30% i smanjenje potrošnje resursa poput vode i energije.

13. Projekt DeepMind i Google Earth Engine

DeepMind, u suradnji s Google Earth Engine, razvio je model dubokog učenja za predviđanje vlažnosti tla na temelju satelitskih podataka (Google Earth Engine, 2021). Model koristi podatke prikupljene sa satelita Sentinel-1 i Sentinel-2 za analizu vlažnosti tla na globalnoj razini. Poljoprivrednici mogu koristiti ove podatke za optimizaciju navodnjavanja, čime se štedi voda i smanjuje trošak proizvodnje. Ovaj projekt omogućava preciznije upravljanje vodom na poljoprivrednim zemljištima i pomaže u borbi protiv suše u poljoprivrednim regijama.

14. Projekt Xarvio™ Digital Farming Solutions

Xarvio™ Digital Farming Solutions, projekt koji je pokrenula tvrtka BASF, koristi strojno učenje i analitiku za pružanje preciznih preporuka poljoprivrednicima o vremenu sadnje, gnojdbi i zaštiti usjeva (BASF, 2021). Xarvio™ platforma analizira podatke sa senzora, satelitske slike, vremenske podatke i povijesne informacije o usjevima kako bi pružila prilagođene savjete poljoprivrednicima. Platforma pomaže poljoprivrednicima prilikom optimizaciji korištenja resursa kao što su voda, gnojiva i pesticidi, omogućujući preciznije upravljanje poljima. Poljoprivrednici koji koriste Xarvio™ zabilježili su povećanje prinosa do 10% i smanjenje upotrebe gnojiva i pesticida za 20-30%.

15. Projekt Deepfield Robotics

Deepfield Robotics, podružnica njemačkog koncerna Bosch, razvila je AI sustav za automatizirano prepoznavanje i uklanjanje korova pomoću robota opremljenih kamerama i sensorima (Bosch, 2021). Sustav koristi algoritme dubokog učenja za razlikovanje korova od usjeva u stvarnom vremenu te cilja samo korove, čime se smanjuje upotreba herbicida. Robotski sustav može autonomno prolaziti kroz polja, prepoznati korov i ukloniti ga ili primijeniti herbicide samo tamo gdje je to potrebno. Ovaj sustav može smanjiti upotrebu herbicida za više od 90%, značajno smanjujući troškove i negativan utjecaj na okoliš.

Budućnost AI u poljoprivredi

Primjena umjetne inteligencije (AI) u poljoprivredi ubrzano se razvija i obećava transformirati sektor na globalnoj razini. Očekuje se da će AI igrati ključnu ulogu u budućim inovacijama, pružajući poljoprivrednicima napredne alate za održivo upravljanje resursima, povećanje prinosa i prilagodbu klimatskim promjenama. U nastavku su opisane ključne inovacije koje će oblikovati budućnost AI-a u poljoprivredi te kako će pridonijeti održivom upravljanju prirodnim resursima i prehrani rastuće svjetske populacije.

Jedan od najvažnijih pravaca razvoja AI u poljoprivredi je primjena autonomnih sustava za obradu tla, sadnju i žetvu. Autonomni traktori i poljoprivredni strojevi opremljeni AI-om i računalnim vidom već se koriste za preciznu obradu tla, sadnju i žetvu usjeva bez potrebe za ljudskom intervencijom (Bechar & Vigneault, 2017). AI algoritmima koji omogućuju samostalno obrađivanje tla i sadnju usjeva (John Deere, 2020). Ovi sustavi mogu obraditi velika poljoprivredna područja s visokom razinom preciznosti

i učinkovitosti, što smanjuje troškove rada i povećava produktivnost. Korištenje autonomnih sustava omogućava poljoprivrednicima u preciznijoj obradi tla, smanjujući potrošnju goriva i emisiju stakleničkih plinova, što doprinosi održivijoj poljoprivredi (Reddy i sur., 2021).

Klimatske promjene predstavljaju veliki izazov za poljoprivredu, ali AI tehnologije mogu pomoći poljoprivrednicima u prilagodbi promjenjivim uvjetima. Algoritmi strojnog učenja koriste se za analizu povijesnih podataka o klimatskim obrascima i predviđanje budućih promjena, što omogućava poljoprivrednicima prilagodbu svoje prakse kako bi izbjegli negativne utjecaje (Malik i sur., 2023). AI modeli mogu predvidjeti suše, poplave i ekstremne vremenske uvjete te pružiti preporuke za optimalno vrijeme sjetve i žetve. Na primjer, sustav Watson Decision Platform for Agriculture koristi podatke o vremenu i strojnog učenja za predviđanje klimatskih promjena i preporučuje strategije poljoprivrednicima za prilagodbu (IBM, 2021). Predviđanje klimatskih promjena pomaže poljoprivrednicima minimizaciju rizika, povećaju otpornost na klimatske promjene i osiguraju održivu proizvodnju hrane.

Pametna poljoprivreda (eng. smart farming) predstavlja budućnost poljoprivrede, a AI je ključna komponenta ove transformacije. Pametna poljoprivreda koristi AI, Internet stvari (eng. *internet of things*, IoT), senzore i big data za automatizaciju i optimizaciju različitih poljoprivrednih operacija, uključujući navodnjavanje, gnojidbu i zaštitu usjeva (Wolfert i sur., 2017). Jedan od vodećih projekata pametne poljoprivrede je Smart Agri-Farm, koji koristi AI za praćenje rasta usjeva, upravljanje navodnjavanjem i gnojidbom, te optimizaciju prinosa na temelju podataka prikupljenih sa senzora i dronova (Kamilaris i sur., 2019). Integracija AI u pametne poljoprivredne prakse omogućava precizno upravljanje resursima, što smanjuje troškove i povećava učinkovitost, dok istovremeno smanjuje negativan utjecaj na okoliš.

Održivost je jedan od ključnih ciljeva moderne poljoprivrede, a AI može značajno doprinijeti postizanju tog cilja kroz optimizaciju upravljanja resursima i smanjenje otpada. AI omogućava precizno praćenje potreba biljaka i tla, čime se smanjuje upotreba resursa kao što su voda, gnojiva i pesticidi (Liakos i sur., 2018). Na primjer, sustavi navodnjavanja temeljeni na AI tehnologiji mogu osigurati točnu količinu vode koju biljke trebaju, smanjujući potrošnju vode do 50% u usporedbi s tradicionalnim metodama navodnjavanja (Eli-Chukwu, 2019). AI sustavi za upravljanje gnojidbom analiziraju podatke o tlu, vremenskim uvjetima i potrebama biljaka kako bi odredili optimalne količine gnojiva, čime se smanjuje ispiranje hranjivih tvari u podzemne vode i smanjuje zagađenje. Korištenje AI-a za upravljanje resursima može pomoći poljoprivrednicima da smanje troškove, povećaju prinose i zaštite okoliš. Procjenjuje se da će globalna populacija doseći 9,7 milijardi ljudi do 2050. godine, što će zahtijevati povećanje proizvodnje hrane za 70% (FAO, 2017). AI može pomoći u postizanju ovog cilja optimizacijom poljoprivredne proizvodnje i povećanjem prinosa. Algoritmi strojnog učenja omogućuju predviđanje prinosa usjeva na temelju podataka o uvjetima tla, klimatskim uvjetima i agrotehničkim mjerama, što pomaže poljoprivrednicima da unaprijed planiraju aktivnosti i optimiziraju proizvodnju (Basso & Liu, 2019). AI može povećati produktivnost usjeva za 20-30%, čime se osigurava dovoljna količina hrane za rastuću populaciju (Henrietta i sur., 2024).

AI tehnologije također mogu pomoći u očuvanju bioraznolikosti i održavanju zdravih ekosustava. Korištenje AI za preciznu primjenu pesticida, herbicida i gnojiva smanjuje negativan utjecaj na ne ciljane organizme i okoliš (Eastwood i sur., 2019). Sustavi AI-a mogu analizirati interakcije između biljaka, tla i okoliša te pružiti preporuke za poljoprivredne prakse koje podržavaju očuvanje bioraznolikosti i

zdravlje tla. Ovi pristupi pomažu u održavanju ekološke ravnoteže i osiguravaju dugoročnu održivost poljoprivrede.

Zaključak

Primjena strojnog i dubokog učenja u poljoprivredi donosi revoluciju u načinu na koji razumijemo i upravljamo poljoprivrednim procesima. Kroz analizu velike količine podataka prikupljenih putem senzora, satelitskih snimki i dronova, ove tehnologije omogućuju preciznije upravljanje resursima, optimizaciju proizvodnje i održivo korištenje prirodnih resursa. Algoritmi strojnog učenja i dubokog učenja postaju ključni alati za predviđanje prinosa, prepoznavanje bolesti i štetnika, te prilagođavanje navodnjavanja i gnojidbe u stvarnom vremenu, čime se povećava produktivnost i smanjuje negativan utjecaj na okoliš.

U budućnosti se očekuje daljnji razvoj autonomnih sustava u poljoprivredi, pametne poljoprivrede temeljene na AI-u, te primjena AI tehnologija u prilagodbi klimatskim promjenama. Unatoč izazovima poput visokih troškova implementacije i potrebe za edukacijom poljoprivrednika, umjetna inteligencija nudi značajan potencijal za transformaciju poljoprivrednog sektora prema održivijoj, produktivnijoj i učinkovitijoj praksi. Ovi inovativni pristupi omogućit će nam pronalaženje rješenja na rastuće zahtjeve za proizvodnjom hrane, istovremeno smanjujući pritisak na okoliš i osiguravajući dugoročnu održivost poljoprivrednih resursa.

Literatura:

1. AgFunder. (2019). *AgFunder Agrifood Tech Investing Report*. <https://agfunder.com>
2. Ahumada, O., Villalobos, J. R., & Munoz-Carpena, R. (2020). Smart agriculture: An information and communication technology approach for efficient resource management. *Computers and Electronics in Agriculture*, 169, 105246. doi:10.1016/j.compag.2020.105246
3. Akhter R, Shabir Ahmad Sofi. Precision agriculture using IoT data analytics and machine learning. *Journal of King Saud University - Computer and Information Sciences*. 2021;34(8):5602-5618. doi:<https://doi.org/10.1016/j.jksuci.2021.05.013>
4. Alpaydin, E. (2020). *Introduction to Machine Learning* (4th ed.). MIT Press.
5. Assouline, S., Russo, D., Silber, A., & Or, D. (2015). Balancing water scarcity and quality for sustainable irrigated agriculture. *Water Resources Research*, 51(5), 3419-3436. doi.org/10.1002/2015WR017071
6. Attri I.,Awasthi L. K., Sharma T. P., Rathee P. (2023). A review of deep learning techniques used in agriculture. *Ecological Informatics*, 77, 102217–102217. doi:10.1016/j.ecoinf.2023.102217
7. Barbedo, J. G. A. (2013). Digital image processing techniques for detecting, quantifying and classifying plant diseases. *SpringerPlus*, 2(1), 660. doi:10.1186/2193-1801-2-660
8. Basso, B., & Liu, L. (2019). The future of agriculture: Combining crop modeling and artificial intelligence. *European Journal of Agronomy*, 107, 82-90. doi:10.1016/j.eja.2019.05.015
9. Bechar, A., & Vigneault, C. (2017). Agricultural robots for field operations: Concepts and components. *Biosystems Engineering*, 149, 94-111. doi:10.1016/j.biosystemseng.2016.06.014

10. Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichhorn, K., & Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79-87. doi:10.1016/j.jag.2015.02.012
11. Blue River Technology. (2020). *See & Spray Technology*. <https://www.bluerivertechnology.com>
12. Boulent, J., Foucher, S., Théau, J., & St-Charles, P. L. (2019). Convolutional neural networks for the automatic identification of plant diseases. *Frontiers in Plant Science*, 10, 941. doi:10.3389/fpls.2019.00941
13. Brady, N. C., & Weil, R. R. (2016). *The Nature and Properties of Soils* (15th ed.). Pearson.
14. Cai Y, Zheng W, Zhang X, Zhangzhong L, Xue X (2019) Research on soil moisture prediction model based on deep learning. PLOS ONE 14(4): e0214508. <https://doi.org/10.1371/journal.pone.0214508>
15. Chlingaryan, A., Sukkarieh, S., & Whelan, B. (2018). Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Computers and Electronics in Agriculture*, 151, 61-69. doi:10.1016/j.compag.2018.05.012
16. Chung J., Lee Y., Kim J., Jung C. Kim S. (2022) Soil Moisture Content Estimation Based on Sentinel-1 SAR Imagery Using an Artificial Neural Network and Hydrological Components. *Remote Sensing*, 14(3), 465 doi:10.3390/rs14030465
17. Drusch, M., Bello, U. D., Carlier, S., Colin, O., Fernandez, V., Gascon, F., ... & Del Bello, U. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25-36. doi:10.1016/j.rse.2011.11.026
18. Eastwood, C., Klerkx, L., Ayre, M., & Dela Rue, B. (2019). Managing socio-technical innovation dilemmas in the digital age: Aligning smart farming and smallholder farmer inclusion. *NJAS - Wageningen Journal of Life Sciences*, 90-91, 100294. doi:10.1007/s10806-017-9704-5
19. Eli-Chukwu, N. C. (2019). Applications of artificial intelligence in agriculture: A review. *Engineering, Technology & Applied Science Research*, 9(4), 4377-4383. doi:10.48084/etasr.2756
20. EOS Data Analytics. (2021). *EOS Crop Monitoring*. <https://eos.com/products/crop-monitoring/>
21. FAO. (2017). *The future of food and agriculture: Trends and challenges*. Food and Agriculture Organization of the United Nations.
22. FarmShots. (2020). *Satellite Imagery for Precision Agriculture*. <https://www.farmshots.com>
23. Feng Q, Gong J, Liu J, Li Y. Monitoring Cropland Dynamics of the Yellow River Delta based on Multi-Temporal Landsat Imagery over 1986 to 2015. *Sustainability*. 2015; 7(11):14834-14858. <https://doi.org/10.3390/su71114834>
24. Feng, Q., Liu, J., & Gong, J. (2019). UAV remote sensing for urban vegetation mapping using random forest and texture analysis. *Remote Sensing*, 11(1), 14. doi:10.3390/rs70101074
25. Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318. doi:10.1016/j.compag.2018.01.009
26. Fleming A., Jakku E., Fielke S., Taylor B. M., Lacey J., Terhost A., Stitzlein C. (2021) Foresighting Australian digital agricultural futures: Applying responsible innovation

- thinking to anticipate research and development impact under different scenarios. *Agricultural Systems Volume 190, 103120*. doi:10.1016/j.agsy.2021.103120
27. Foth, H. D., & Ellis, B. G. (1997). *Soil Fertility* (2nd ed.). CRC Press.
 28. Fountas, S., Carli, G., Sørensen, C. G., Tsiropoulos, Z., Cavalaris, C., Vatsanidou, A., ... & Vangeyte, J. (2020). Farm management information systems: Current situation and future perspectives. *Computers and Electronics in Agriculture, 170*, 105248. <https://doi.org/10.1016/j.compag.2015.05.011>
 29. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
 30. Google Earth Engine. (2021). *Google Earth Engine and DeepMind - Predicting Soil Moisture*. <https://earthengine.google.com/>
 31. Guerri M. F., Distante C., Spagnolo P., Bougourzi F., Taleb-Ahmed, Abdelmalik (2024) Deep learning techniques for hyperspectral image analysis in agriculture: A review. *ISPRS Open Journal of Photogrammetry and Remote Sensing Volume 12, 100062*. doi:10.1016/j.ojphoto.2024.100062
 32. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.
 33. Hengl, T., Heuvelink, G. B. M., & Kempen, B. (2017). SoilGrids250m: Global gridded soil information based on machine learning. *PLoS ONE, 12*(2), e0169748. doi:10.1371/journal.pone.0169748
 34. Henrietta H. M., Artificial intelligence in agriculture: a review of current applications and future trends, *Futuristic Trends in Agriculture Engineering & Food Sciences Volume 3 Book 11, IIP Series, Volume 3, May, 2024, Page no.1-6, e-ISBN: 978-93-5747-553-2, doi:10.58532/V3BCAG11P1CH1*
 35. Hillel, D. (2008). *Soil in the Environment: Crucible of Terrestrial Life*. Academic Press.
 36. <https://www.fao.org/policy-support/tools-and-publications/resources-details/en/c/472484/>
 37. Hughes, D. P., & Salathé, M. (2015). An open access repository of images on plant health to enable the development of mobile disease diagnostics through machine learning and crowdsourcing. *Plant Pathology, 64*(1), 154-162. doi:10.1111/ppa.12344
 38. IBM. (2021). *IBM Watson Decision Platform for Agriculture*. <https://www.ibm.com/watson/agriculture>
 39. iUNU. (2021). *LUNA: Artificial Intelligence for Horticulture*. <https://www.iunu.com>
 40. Jahromi M. N., Zand-Parsa S., Razzghi S., Jamshidi S., Didari S., Doosthosseini A., Pourhghasemi H. R., Developing machine learning models for wheat yield prediction using ground-based data, satellite-based actual evapotranspiration and vegetation indices. *European Journal of Agronomy Volume 146, May 2023, 126820*, doi:10.1016/j.eja.2023.126820
 41. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning*. Springer.
 42. Jiménez A., Cárdenas P., Jiménez F., (2022) Intelligent IoT-multiagent precision irrigation approach for improving water use efficiency in irrigation systems at farm and district scales
 43. John Deere. (2020). *Autonomous Tractors and AI Solutions*. <https://www.deere.com/en/technology-products/precision-ag-technology/autonomous-tractors/>

44. Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260. doi:10.1126/science.aaa8415
45. Kamal KC, Zhendong Y, Mingyang Wu, Zhilu Wu, (2019) Depthwise separable convolution architectures for plant disease classification. *Computer and Electronics in Agriculture, Volume 165, 104948*. doi:10.1016/j.compag.2019.104948
46. Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90. doi:10.1016/j.compag.2018.02.016
47. Kamilaris, A., Kartakoullis, A., & Prenafeta-Boldú, F. X. (2019). A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture*, 162, 128-139. doi:10.1016/j.compag.2017.09.037
48. Kasera R.K., Gour S., Acharjee T. (2024) A comprehensive survey on IoT and AI based applications in different pre-harvest, during-harvest and post-harvest activities of smart agriculture *Computers and Electronics in Agriculture, Volume 216, 2024, 108522, ISSN 0168-1699*, doi:10.1016/j.compag.2023.108522
49. Klerkx, L., Jakku, E., & Labarthe, P. (2019). A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. *NJAS - Wageningen Journal of Life Sciences*, 90-91, 100315. doi:10.1016/j.njas.2019.100315
50. Klompenburg T. Kassahun A., Catal C., (2020) Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agronomy Volume 177, 105709*. doi:10.1016/j.compag.2020.105709
51. Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782. doi:10.1109/LGRS.2017.2681128
52. Lal, R. (2004). Soil carbon sequestration to mitigate climate change. *Geoderma*, 123(1-2), 1-22. doi:10.1016/j.geoderma.2004.01.032
53. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. doi:10.1038/nature14539
54. Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674. doi:10.3390/s18082674
55. Ma L., Liu Y., Zhang X., Ye Y., Yin G., Johnson B. A., (2019) Deep learning in remote sensing applications: A meta-analysis and review *ISPRS Journal of Photogrammetry and Remote Sensing, Volume 152, June 2019, Pages 166-177* doi:10.1016/j.isprsjprs.2019.04.015.
56. Maggiori, E., Charpiat, G., Tarabalka, Y., & Alliez, P. (2016). Recurrent Neural Networks to Correct Satellite Image Classification Maps. *IEEE Transactions on Geoscience and Remote Sensing*, 55, 4962-4971.
57. Malik I, Ahmed M, Gulzar Y, et al. Estimation of the Extent of the Vulnerability of Agriculture to Climate Change Using Analytical and Deep-Learning Methods: A Case Study in Jammu, Kashmir, and Ladakh. *Sustainability*. 2023;15(14):11465. doi:https://doi.org/10.3390/su151411465
58. Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419. doi:10.3389/fpls.2016.01419
59. Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. MIT Press.
60. Netafim. (2021). *Precision Irrigation for Agriculture*. <https://www.netafim.com>

61. Ojha, T., Misra, S., & Raghuwanshi, N. S. (2015). Wireless sensor networks for precision agriculture: A comprehensive review. *Computers and Electronics in Agriculture*, 118, 66-84. doi:10.1016/j.compag.2015.08.0111
62. Park SH, Lee BY, Kim MJ, et al. Development of a Soil Moisture Prediction Model Based on Recurrent Neural Network Long Short-Term Memory (RNN-LSTM) in Soybean Cultivation. *Sensors*. 2023;23(4):1976. doi:https://doi.org/10.3390/s23041976
63. Phang S. K. , Chiang T. H. A. , Happonen A., Chang M. M. L. , From Satellite to UAV-Based Remote Sensing: A Review on Precision Agriculture, *IEEE Access*, vol. 11, pp. 127057-127076, 2023, doi: 10.1109/ACCESS.2023.3330886.
64. Phiri D, Simwanda M, Salekin S, Nyirenda VR, Murayama Y, Ranagalage M. Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*. 2020; 12(14):2291. <https://doi.org/10.3390/rs12142291>
65. Poonia R. C., Gao X., Raja L. (2018). *Smart Farming Technologies for Sustainable Agricultural Development.*, Engineering Science Reference, ISBN-10-152588167
66. Prospera Technologies. (2021). *AI-powered solutions for precision agriculture.* <https://www.prospera.ag>
67. Rahman S. A. Z., Mitra K. C. and Islam S. M. M., Soil Classification Using Machine Learning Methods and Crop Suggestion Based on Soil Series 2018 21st International Conference of Computer and Information Technology (ICCIIT), Dhaka, Bangladesh, 2018, pp. 1-4, doi: 10.1109/ICCITECHN.2018.8631943.
68. Resson. (2021). *Predictive analytics for agriculture.* <https://www.resson.com>
69. Rijswijk K, Laurens Klerkx, Bacco M, et al. Digital transformation of agriculture and rural areas: A socio-cyber-physical system framework to support responsabilisation. *Journal of Rural Studies*. 2021;85:79-90. doi:https://doi.org/10.1016/j.jrurstud.2021.05.003
70. Rose, D. C., Wheeler, R., Winter, M., Lobley, M., & Chivers, C. A. (2018). Agriculture 4.0: Making it work for people, production, and the planet. *Land Use Policy*, 81, 718-730. doi:10.1016/j.landusepol.2020.104933
71. Saiz-Rubio, V., & Rovira-Más, F. (2020). From smart farming towards agriculture 5.0: A review on crop data management. *Agronomy*, 10(2), 207. doi:10.3390/agronomy10020207
72. Schimmelpfennig, D. (2016). Precision Agriculture in the Digital Era: Recent Adoption on U.S. Farms. *United States Department of Agriculture Economic Research Service*, EIB-153. <https://www.ers.usda.gov/publications/pub-details/?pubid=83077>, doi:10.22004/ag.econ.333550
73. Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117. doi:10.1016/j.neunet.2014.09.003
74. Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction* (2nd ed.). MIT Press.
75. Tangesalu D, Tieknik R.T. E., Tooy D., Judijanto L. (2023) Precision Agriculture: Integrating Technology for Enhanced Efficiency and Sustainability in Crop Management, *Global International Journal of Innovative Research* 1(3):213-219 doi: 10.59613/global.v1i3.37
76. Teshome F.T., Bayabil H.K., Schaffer B., Yiannis Ampatzidis, Hoogenboom G. Improving soil moisture prediction with deep learning and machine learning models. *Computers and Electronics in Agriculture*. 2024;226:109414-109414. doi:10.1016/j.compag.2024.109414

77. Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A review on UAV-based applications for precision agriculture. *Information*, 10(11), 349. doi:10.3390/info10110349
78. Vincent, J. (2018). How Resson is helping potato farmers use AI to stop their crops dying. *The Verge*. <https://www.theverge.com>
79. Wageningen University & Microsoft. (2020). *Collaboration for AI in Agriculture*. <https://www.wur.nl/en/Research-Results/Research-Institutes/Environmental-Research/Projects/Collaboration-with-Microsoft.htm>
80. Wageningen University. (2021). *Digital Farming Research*. <https://www.wur.nl>
81. Weltzien, C. (2016). Digital agriculture – or why agriculture 4.0 still offers only modest returns. *Landtechnik*, 71(2), 66-68. doi:10.1515/lt.2016.3135
82. Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. J. (2017). Big Data in Smart Farming – A review. *Agricultural Systems*, 153, 69-80. doi:10.1016/j.agsy.2017.01.023
83. Zhang X., Xue J., Chen S., Wang N., Shi Z., Huang Y., Zhuo Z. (2022) Digital Mapping of Soil Organic Carbon with Machine Learning in Dryland of Northeast and North Plain China. *Remote Sensing* 14(10), 2504 . doi:10.3390/rs14102504

Dr. sc. Domagoj K. Hackenberger,

Dr. Sc. Tamara Đerđ,

Prof. dr. sc. Branimir K. Hackenberger