

Pregled algoritama strojnog učenja u poljoprivredi i zaštiti okoliša

Bilić, Josip

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:

**Josip Juraj Strossmayer University of Osijek, Faculty of Agrobiotechnical Sciences Osijek /
Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet agrobiotehničkih znanosti Osijek**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:151:224576>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-07-18**



Sveučilište Josipa Jurja
Strossmayera u Osijeku

**Fakultet
agrobiotehničkih
znanosti Osijek**

Repository / Repozitorij:

[Repository of the Faculty of Agrobiotechnical
Sciences Osijek - Repository of the Faculty of
Agrobiotechnical Sciences Osijek](#)



SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Josip Bilić

Sveučilišni diplomski studij Mehanizacija

Smjer Mehanizacija

**Primjena algoritma strojnog i dubokog strojnog učenja u poljoprivredi i
zaštiti okoliša**

Diplomski rad

Osijek, 2021.

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Josip Bilić

Sveučilišni diplomski studij Mehanizacija

Smjer Mehanizacija

**Primjena algoritma strojnog i dubokog strojnog učenja u poljoprivredi i
zaštiti okoliša**

Diplomski rad

Osijek, 2021.

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Josip Bilić

Sveučilišni diplomski studij Mehanizacija

Smjer Mehanizacija

**Primjena algoritma strojnog i dubokog strojnog učenja u poljoprivredi i
zaštiti okoliša**

Diplomski rad

Povjerenstvo za ocjenu i obranu diplomskog rada:

1. izv. prof. dr. sc. Ivan Plaščak, predsjednik
2. prof. dr. sc. Mladen Jurišić, mentor
3. Dorijan Radočaj, mag. ing. geod. et geoinf., član

Osijek, 2021.

SADRŽAJ

1. UVOD	1
2. NAČIN RADA STROJNOG UČENJA	3
2.1. Nadzirano učenje	4
2.1.1. Metoda regresije.....	4
2.1.2. Metoda klasifikacije.....	4
2.2. Nenadzirano učenje	9
2.2.1. Duboko strojno učenje	10
2.3. Neuronska mreža	12
2.4. Umjetne neuronske mreže	13
2.4.1. Podjela umjetnih neuronskih mreža.....	15
2.5. Duboka neuronska mreža	16
2.6. Biološki neuron.....	17
3. PRIMJENA STROJNOG UČENJA U POLJOPRIVREDI.....	18
3.1. Predviđanje prinosa	18
3.2. Otkrivanje bolesti	18
3.3. Otkrivanje korova	19
3.4. Kvaliteta usjeva	20
3.5. Predviđanje svojstava tla	21
3.6. Integracija s 5G tehnologijom	21
3.7. Praćenje životinja na farmama	23
3.8. Smanjenje potrošnje vode pri navodnjavanju usjeva.....	23
3.9. Dron za prijevoz tereta	24
3.10. Roboti u poljoprivredi	24
4. PRIMJENA STROJNOG UČENJA U ZAŠTITI OKOLIŠA.....	33
5. ZAKLJUČAK.....	35
6. POPIS LITERATURE.....	36
7. SAŽETAK.....	40
8. SUMMARY.....	41
9. POPIS SLIKA.....	42

1. UVOD

Tehnologija je godinama redefinirala poljoprivredu, a tehnološki napredak utjecao je na poljoprivrednu industriju na više načina. Poljoprivreda je glavno zanimanje u mnogim zemljama svijeta, a s rastom stanovništva, koje će se prema projekcijama UN -a povećati sa 7,5 milijardi na 9,7 milijardi u 2050., bit će veći pritisak na poljoprivredu. Prema istraživanju, proizvodnja hrane morat će se povećati za 60% kako bi se prehranile dodatne dvije milijarde ljudi. Međutim, tradicionalne metode nisu dovoljne za podnošenje ove velike potražnje. To tjera poljoprivrednike i poljoprivredne tvrtke da pronađu nove načine za povećanje proizvodnje i smanjenje otpada. Kao rezultat toga, umjetna inteligencija stalno se pojavljuje kao dio tehnološke evolucije poljoprivredne industrije. Izazov je povećati globalnu proizvodnju hrane za 50% do 2050. kako bi se prehranile dodatne dvije milijarde ljudi. Rješenja pokrenuta umjetnom inteligencijom neće samo omogućiti poljoprivrednicima poboljšanje učinkovitosti, već će i poboljšati količinu, kvalitetu i brži izlazak na tržište, neke primjere modernizacije i robotizacije kao rješenje nabrojanih problema bit će opisane dalje u radu (Wipro, 2019.).

Sharma i sur. (2021) govori kako je John Deere-ovu tehnologiju uveo 1990. za sjetvu sjemena i apliciranja gnojiva pomoću traktora s globalnim sustavom pozicioniranja (GPS). Glavni fokus precizne poljoprivrede je smanjenje troškova proizvodnje i utjecaja na okoliš kako bi se povećala profitabilnost farme. Digitalne tehnologije kao što su IoT (engl. *Internet of things*), AI (engl. *artificial intelligence*, tj. ljudska inteligencija demonstrirana pomoću strojeva), analiza podataka igraju ključnu ulogu u preciznoj poljoprivredi. U preciznoj poljoprivredi, pametni senzori temeljeni na IoT-u raspoređeni su u poljoprivrednom zemljištu za prikupljanje podataka u vezi s hranjivim tvarima tla, gnojivima i potrebom vode, kao i za analizu rasta usjeva. Autonomni i poluautonomni uređaji poput bespilotne letjelice (UAV) i roboti koriste se za identifikaciju korova i bolesti u biljkama pomoću tehnika računalnog vida. Satelitski snimci također se koriste u preciznoj poljoprivredi za praćenje polja i identifikaciju bolesti u biljkama. Podaci dobiveni od postavljenih senzora obrađuju se i analiziraju pomoću algoritama kako bi se poljoprivredna praksa učinila kontroliranijom i optimiziranijom. Algoritmi se također koriste za predviđanje vremena i oborina na temelju podataka dobivenih sa senzora, klimatskih zapisa i satelitskih snimaka. To bi moglo spasiti živote tisuća poljoprivrednika. Pametno upravljanje životinjskim grlima važna je komponenta precizne poljoprivrede. Pomaže u praćenju zdravlja, dobrobiti, produktivnosti i reprodukcije životinja tijekom njihovog životnog ciklusa. Senzori i kamere nadziru zdravlje životinja, a tehnike računalnog vida pomažu u donošenju inteligentnih odluka, kao što je zaustavljanje zajedničkog širenja bolesti. Autonomni traktori i automatizirani

sustavi za navodnjavanje pružaju suvremena poljoprivredna rješenja poljoprivrednicima. Široko rasprostranjena uporaba preciznog poljodjelstva u svijetu posljedica je prisutnosti inovativnih strojnih i algoritama za duboko učenje, pristupa internetu velike brzine i učinkovitih računalnih uređaja.

Shafi i sur. (2021) govore kako poljoprivredni sektor ima iznimnu važnost u Pakistanu zbog unutarnje agrarne prirode gospodarstva. Pakistan ima BDP temeljen na poljoprivredi, međutim oslanja se na ručno praćenje usjeva, što je radno intenzivna i neučinkovita metoda. Nasuprot tome, u razvijenim se zemljama koristi nekoliko najnovijih tehnoloških rješenja za povećanje prinosa uz optimalnu uporabu resursa. U tu svrhu ponuđeni su im integrirani pristupi praćenja zdravlja usjeva korištenjem IoT-a, strojnog učenja i tehnologije dronova. U radu će biti opisana neka od ponuđenih rješenja. IoT senzori pružaju stanje parametara okoliša u stvarnom vremenu koji utječu na usjev, a platforma bespilotnih letjelica pruža multispektralne podatke koji se koriste za generiranje vegetacijskih indeksa (VI), kao što je indeks normirane razlike vegetacije (NDVI) za analizu zdravlja usjeva. NDVI pruža informacije o usjevima na temelju sadržaja klorofila, što nudi ograničene podatke o zdravlju usjeva. Kako bi se steklo bogato i detaljno znanje o zdravlju usjeva, podaci o vremenskim serijama promjenjive duljine IoT senzora i multispektralnih slika pretvoreni su u prikaz fiksne veličine za generiranje karata zdravlja usjeva. Na prikupljene podatke primijenjeni su brojni algoritmi strojnog i dubinskog učenja, pri čemu je duboka neuronska mreža s dva skrivena sloja najoptimalniji model među svim odabranim modelima, pružajući točnost od (98,4%).

Singha i sur. (2021.) prikazuju istraživanje o tehnikama klasifikacije različitih bolesti koje se koriste za otkrivanje bolesti biljnog lista i algoritam za tehniku segmentacije slike koja se može koristiti za automatsko otkrivanje, kao i za kasniju klasifikaciju bolesti biljnog lista. Uz vrlo malo računalnog obavljanja istraživanja postignuti su optimalni rezultati, što također pokazuje učinkovitost predloženog algoritma u prepoznavanju i klasifikaciji bolesti lista. Još jedna prednost korištenja ove metode je ta što se biljne bolesti mogu identificirati u ranoj fazi ili u početnoj fazi. Za poboljšanje stope prepoznavanja u procesu klasifikacije također se može koristiti umjetna neuronska mreža, Bayesov klasifikator i hibridni algoritmi.

U radu se opisuju tehnike i metode strojnog učenje kao moderan način za suočavanje s izazovima poljoprivredne proizvodnje u smislu produktivnosti, utjecaja na okoliš, sigurnosti hrane i održivosti. Također je analiziran način kako strojno učenje ima visoku točnost kada se koristi kao alat za donošenje bitnih odluka.

2. NAČIN RADA STROJNOG UČENJA

Pojam strojno učenje odnosi se na automatizirano otkrivanje značajnih obrazaca u podacima. U posljednjih nekoliko desetljeća postao je uobičajeni alat u gotovo svim zadacima koji zahtijevaju izdvajanje podataka iz velikih skupova podataka. Okruženi smo tehnologijom zasnovanom na strojnom učenju: tražilice uče kako nam donijeti najbolje rezultate (istovremeno postavljajući profitabilne oglase), softver protiv neželjene pošte uči filtrirati našu e-poštu, a transakcije s kreditnim karticama osigurane su softverom koji uči kako otkriti prijevare. Digitalni fotoaparati uče otkrivati lica, a inteligentne aplikacije za osobnu pomoć na pametnim telefonima uče prepoznavati glasovne naredbe. Automobili su opremljeni sustavima za prevenciju nesreća koji se grade pomoću algoritama strojnog učenja. Strojno učenje je također široko rasprostranjeno i koristi se u znanstvenim primjenama poput bioinformatike, medicine i astronomije.

Ono predstavlja temelj dubinske analize podataka, odnosno proces otkrivanja znanja u velikim skupovima podataka. Strojno učenje je uvelike primijenjeno u različitim vrstama znanosti. Zbog šireg područja koje strojno učenje obuhvaća to rezultira njegovu primjenu na rješavanje jako složenih problema na gotovo sva područja ljudske djelatnosti.

Neke od djelatnosti u kojima se primjenjuje strojno učenje su:

- Programske implementacije koje se ne mogu riješiti klasičnim programiranjem
- Programski sustavi koji su prilagodljivi
- Bio informatika
- Obrada prirodnog jezika
- Raspoznavanje govora
- Raspoznavanje uzoraka
- Inteligentno upravljanje
- Predviđanje trendova.

Kako tehnologija ide dalje, strojno učenje prati njen razvoj. Stoga se strojno učenje primjenjuje kod osobnih virtualnih pomoćnika kao što su Siri, Alexa, itd. Na temelju prethodnih istraživanja, strojno učenje prikuplja i pročišćava podatke. Uvelike se i primjenjuje prilikom GPS navigacije, gdje nam govori gdje su mogući zastoji u prometu na temelju svakodnevnog praćenja (Marjam De Marco, 2018.).

Prilikom upotrebe društvenih mreža, kao što je npr. *Facebook*, na fotografiji se pokreće umjetna inteligencija i raspoznaje lice na slici. Postoji nekoliko aplikacija koje otkrivaju razne predmete pa i životinje, poput mačaka, pasa, boca, automobila itd. Kada putujemo, koristimo *Google* upute da bismo saznali prometnu situacije u stvarnom vremenu i slijedili najbolji put koji je *Google* predložio u tom trenutku. Aplikacija „*Google translate*“ koju obično koristimo dok posjećujemo strane zemlje. Ta internetska prevoditeljska aplikacija na našem mobitelu pomaže nam u komunikaciji s lokalnim stanovništvom koje govori jezik koji nam je stran. Postoji nekoliko aplikacija umjetne inteligencije koje praktički danas koristimo. U stvari, svatko od nas koristi umjetnu inteligenciju u mnogim dijelovima svog života, čak i bez svog znanja. Današnja umjetna inteligencija može obavljati izuzetno složene poslove s velikom točnošću i brzinom (Machine learning, tutorials point, 2019.).

2.1. Nadzirano učenje

Učenje pod nadzorom lako ćemo opisati kao primjer učenja djeteta da prohoda. Držati ćemo dijete za ruku, pokazati mu kako da krene nogom naprijed, prošetati se za i tako dalje, sve dok dijete ne nauči samostalno hodati (Machine learning, tutorials point, 2019.).

2.1.1. Metoda regresije

Slično tome, u slučaju učenja pod nadzorom, računalu se zadaju konkretni poznati primjeri. Kažemo da je za zadanu vrijednost značajke x_1 izlaz y_1 , za x_2 y_2 , za x_3 y_3 itd. Na temelju tih podataka prepuštamo računalu da shvati empirijski odnos između x i y . Kad se stroj obuči na ovaj način s dovoljnim brojem podatkovnih točaka, tada tražimo da stroj predvidi Y za zadani X . Pod pretpostavkom da znamo stvarnu vrijednost od Y za ovaj dati X , moći ćemo zaključiti je li predviđanje stroja točno. Dakle, testirat ćemo je li stroj naučio koristeći poznate testne podatke. Jednom kada se uvjerimo da je stroj u stanju izvršiti predviđanja sa željenom razinom preciznosti (recimo 80 do 90%) možemo zaustaviti daljnju obuku stroja. Sada možemo sigurno koristiti stroj za predviđanje nepoznatih podatkovnih točaka ili zatražiti da stroj predvidi Y za zadani X za koji ne znamo stvarnu vrijednost Y (Machine learning, tutorials point, 2019.).

2.1.2. Metoda klasifikacije

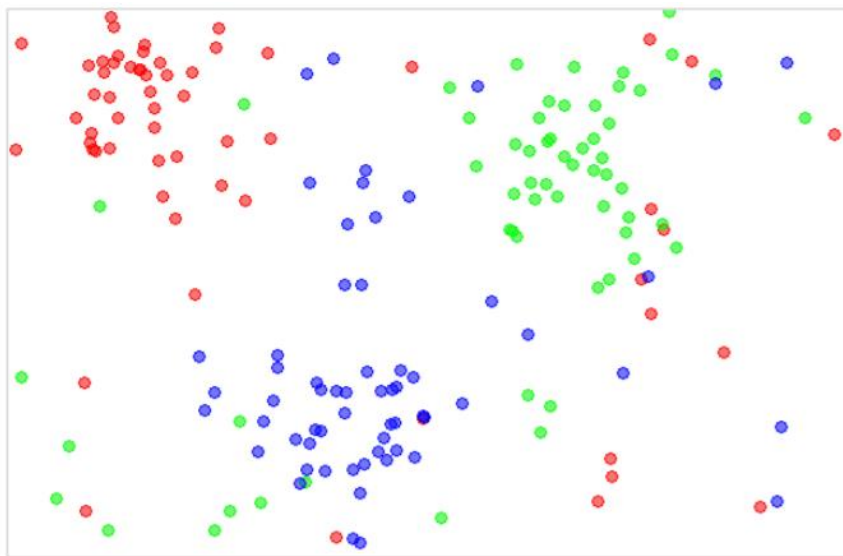
Također možemo koristiti tehnike strojnog učenja za probleme klasifikacije. U problemima klasifikacije razvrstavamo predmete slične prirode u jednu skupinu. Na primjer, u skupu od 100 učenika želimo ih podijeliti u tri skupine na temelju njihove visine (niski, srednja i visoki). Mjereći visinu svakog učenika, smjestit ćemo ih u odgovarajuću skupinu. Kada novi učenik dođe, stavit ćemo ga u odgovarajuću skupinu mjereći njegovu visinu. Slijedeći principe u regresijskom treningu, trenirat ćemo stroj da klasificira učenika na temelju njegove značajke

(visine). Kada stroj sazna kako se formiraju grupe, moći će ispravno klasificirati bilo kojeg nepoznatog novog učenika. Poželjno je upotrijebiti testne podatke kako bi provjerili je li stroj naučio tehniku klasifikacije prije puštanja razvijenog modela u proizvodnju. Nadzirano učenje je mjesto gdje je umjetna inteligencija započela svoje putovanje. Nekoliko algoritama je razvijeno za nadzirano učenje (Machine learning, tutorials point, 2019.).

Nekoliko je algoritama za učenje pod nadzorom. Neki od široko korištenih algoritama učenja pod nadzorom su:

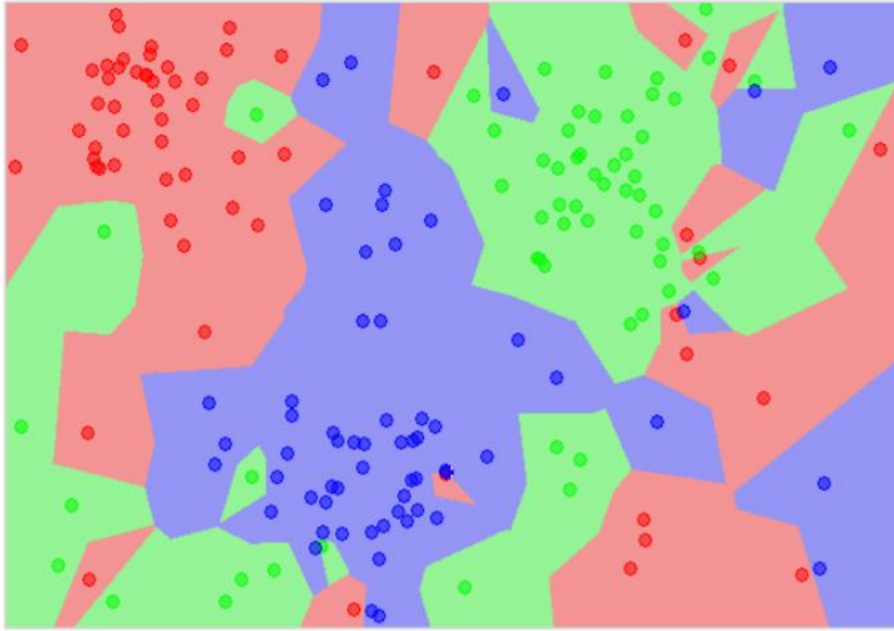
- K – najbliži susjedi
- Stablo odlučivanja
- Metoda Bayes
- Logistička regresija
- Podrška vektorskih strojeva

K – najbliži susjedi, koji se jednostavno nazivaju kNN, statistička je tehnika koja se može koristiti za rješavanje problema klasifikacije i regresije. Razmotrimo slučaj klasificiranja nepoznatog objekta pomoću kNN. Razmotrimo raspodjelu predmeta kao što je prikazano na slici 1.



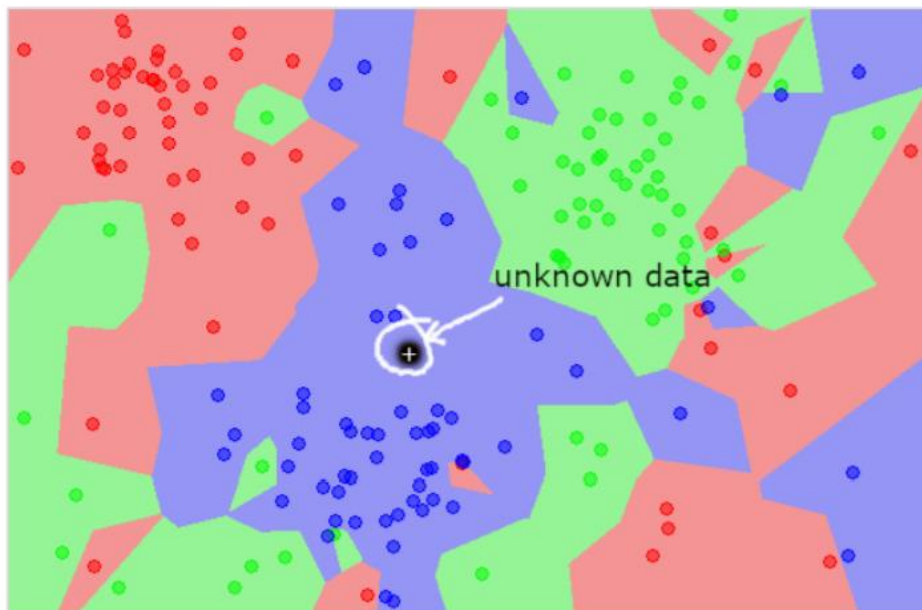
Slika 1. Klasificiranje nepoznatog objekta pomoću kNN metode (Izvor: Machine learning, tutorials point, 2019.)

Dijagram prikazuje tri vrste predmeta, označene crvenom, plavom i zelenom bojom. Kada pokrenemo kNN klasifikator na gore navedenom skupu podataka, granice za svaku vrstu objekta bit će označene kako je prikazano u nastavku na slici2.



Slika 2. Granice za svaku vrstu objekta (Izvor: Machine learning, tutorials point, 2019.)

Sada razmotrimo novi nepoznati objekt koji želimo klasificirati kao crvenu, zelenu ili plavu. To je prikazano na slici 3.



Slika 3. Nepoznata točka u klasi plavih predmeta (Izvor: Machine learning, tutorials point, 2019.)

Kao što vidimo vizualno, nepoznata točka podataka pripada klasi plavih predmeta. Matematički se to može zaključiti mjerenjem udaljenosti ove nepoznate točke sa svakom drugom točkom u skupu podataka. Kad to učinimo, znat ćemo da je većina njegovih susjeda plave boje. Prosječna

udaljenost do crvenih i zelenih predmeta bila bi definitivno veća od prosječne udaljenosti od plavih predmeta. Stoga se ovaj nepoznati objekt može klasificirati kao pripadnik plave klase. Algoritam kNN također se može koristiti za probleme regresije.

Stablo odlučivanja je nadzirana tehnika učenja koja se može koristiti i za klasifikacijske i za regresijske probleme, ali uglavnom je poželjna za rješavanje klasifikacijskih problema. To je klasifikator strukturiran stablom, gdje unutarnji čvorovi predstavljaju značajke skupa podataka, grane predstavljaju pravila odlučivanja, a svaki čvor lista predstavlja ishod.

U stablu odlučivanja postoje dva čvora, a to su čvor odlučivanja i čvor lista. Čvorovi odlučivanja koriste se za donošenje bilo koje odluke i imaju više grana, dok su čvorovi lista rezultat tih odluka i ne sadrže daljnje grane.

Odluke ili test izvode se na temelju značajki zadanog skupa podataka. To je grafički prikaz za dobivanje svih mogućih rješenja problema/odluke na temelju danih uvjeta. Zove se stablo odlučivanja jer, slično stablu, počinje s korijenskim čvorom, koji se proširuje na daljnje grane i konstruira strukturu nalik stablu. Da bismo izgradili stablo, koristimo algoritam CART, koji označava algoritam stabla klasifikacije i regresije. Stablo odluka jednostavno postavlja pitanje, a na temelju odgovora (da/ne) dalje je podijelio stablo na podstabla.

U stablu odlučivanja, za predviđanje klase danog skupa podataka, algoritam počinje od korijenskog čvora stabla. Ovaj algoritam uspoređuje vrijednosti atributa korijena s atributom zapisa (stvarni skup podataka) i, na temelju usporedbe, prati granu i prelazi na sljedeći čvor (Stabla odlučivanja, 2002.).

U strojnom učenju postoje različiti algoritmi, pa je odabir najboljeg algoritma za zadani skup podataka i problem glavna točka koju treba zapamtiti pri stvaranju modela strojnog učenja. Ispod su dva razloga za korištenje stabla odlučivanja:

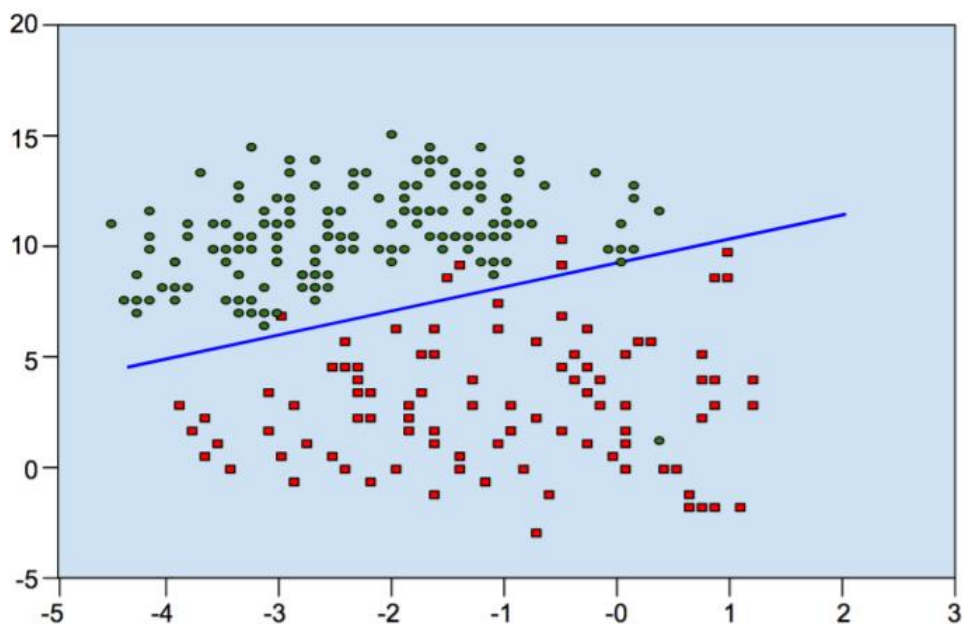
- Metoda stabla odlučivanja obično oponašaju ljudsko mišljenje dok donose odluke, pa ih je lako razumjeti.
- Logika iza stabla odlučivanja može se lako razumjeti jer prikazuje strukturu nalik stablu (Stabla odlučivanja, 2002.).

Jednostavno je razumjeti jer slijedi isti proces koji čovjek slijedi dok donosi bilo kakvu odluku u stvarnom životu. Može biti vrlo korisno za rješavanje problema povezanih s donošenjem odluka. Pomaže razmišljati o svim mogućim ishodima problema. Potrebe za čišćenjem podataka su manje u usporedbi s drugim algoritmima. Stablo odlučivanja sadrži mnogo slojeva,

što ga čini složenim. Možda ima problem s prekomjernim uklapanjem koji se može riješiti pomoću raznih algoritama (Stabla odlučivanja, 2002.).

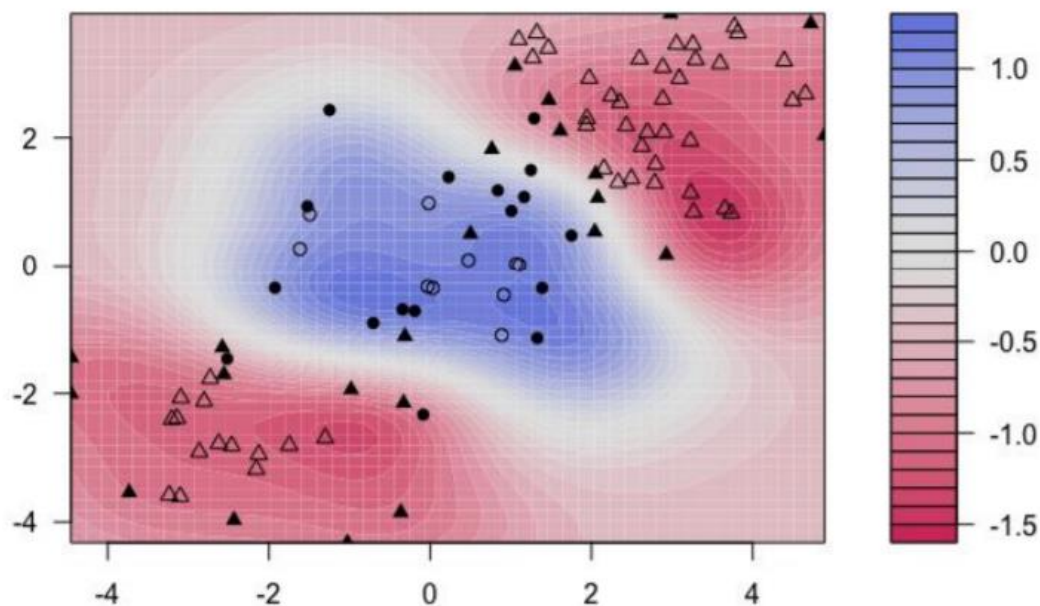
Metoda Bayes koristi se za izradu klasifikatora. Dobar primjer možemo vidjeti iz slijedeće rečenice. Želimo sortirati (klasificirati) voće raznih vrsta iz velike košarice s voćem. Možemo koristiti značajke poput boje, veličine i oblika ploda. Na primjer, bilo koje voće crvene boje, okruglog je oblika i promjera oko 10 cm može se smatrati jabukom. Dakle, da bismo trenirali metodu, koristili bismo ove značajke i testirali vjerojatnost da određena značajka odgovara željenim ograničenjima. Tada se kombiniraju vjerojatnosti različitih značajki da bi se došlo do vjerojatnosti da je određeno voće Jabuka. Metoda Bayes općenito zahtijeva mali broj podataka o obuci za klasifikaciju (Machine learning, tutorials point, 2019.).

Iz dijagrama možemo vizualno pregledati odvajanje crvenih točaka od zelenih. Definira se granična crta kako bi razdvojili ove točke. Sada, da bi smo klasificirali novu podatkovnu točku, samo ćemo morati odrediti na kojoj se strani crte nalazi točka, kao što je prikazano na slici 4.



Slika 4. prikazuje dijagram raspodjele podatkovnih točaka u XY ravnini (Izvor: Machine learning, tutorials point, 2019.)

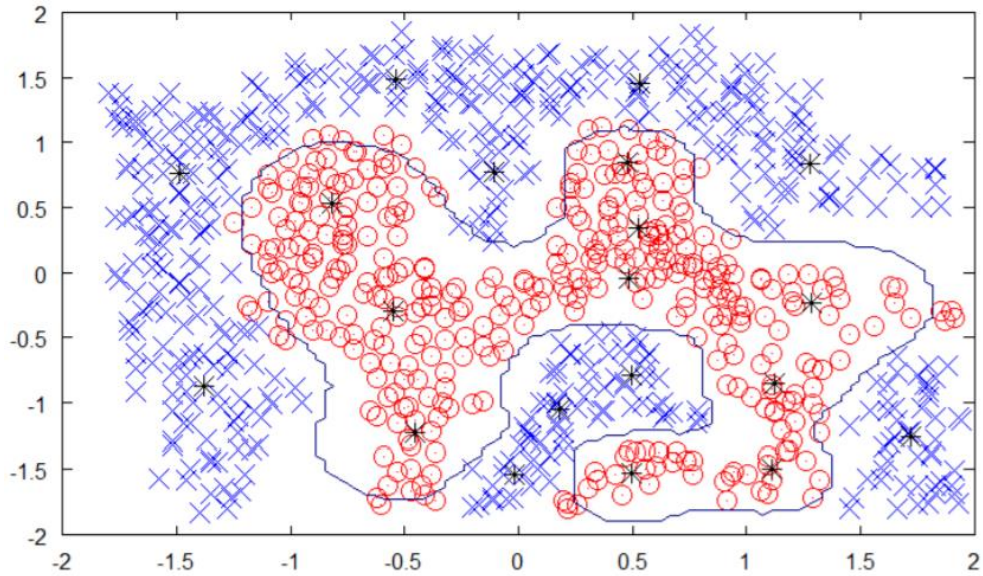
Ovdje se tri klase podataka ne mogu linearno razdvojiti. Granične krivulje su nelinearne. U takvom slučaju pronalazak jednadžbe krivulje postaje složen posao. Podrška vektorskih strojeva pomaže u određivanju granica razdvajanja u takvim situacijama, takvu krivulju možemo vidjeti na slici 5.



Slika 5. Primjer nelinearne granične krivulje (Izvor: Machine learning, tutorials point, 2019.)

2.2. Nenadzirano učenje

U ne nadziranom učenju ne određujemo ciljanu varijablu stroja, već pitamo stroj "Što mi možete reći o X ?". Točnije, možemo postaviti pitanja poput davanja velikog skupa podataka X , "Kojih je pet najboljih skupina koje možemo napraviti od X -a?" ili "Koje se značajke najčešće pojavljuju zajedno u X -u?". Da bismo došli do odgovora na takva pitanja, možemo shvatiti da bi broj podatkovnih točaka koje bi stroj trebao za utvrđivanje strategije bio vrlo velik. U slučaju učenja pod nadzorom, stroj se može obučiti s čak nekoliko tisuća podataka. Međutim, u slučaju učenja bez nadzora, broj podataka koji su razumno prihvaćeni za učenje započinje s nekoliko milijuna. Graničnu crtu možemo vidjeti na slici 6. koja predstavlja granicu između žutih i crvenih točaka kako je utvrđeno strojnim učenjem bez nadzora. Jasno se vidi da stroj s prilično dobrom točnošću odredi klasa svake crne točke.



Slika 6. Granica utvrđena strojnim učenjem bez nadzora (Izvor: Machine learning, tutorials point, 2019.).

Nenadzirano učenje pokazalo je velik uspjeh u mnogim modernim aplikacijama, kao što su otkrivanje lica, otkrivanje predmeta i tako dalje.

Dobar primjer ovog učenja možemo povezati s dresiranjem kućnog psa, mi treniramo svog ljubimca da nam donese loptu. Bacimo loptu na određenoj udaljenosti i tražimo od njega da nam je vrati. Svaki put kad pas to učini ispravno, mi ga nagradimo. Pas polako saznaje da mu uspješno obavljanje posla daje nagradu i tada svaki put u budućnosti počne raditi posao na pravi način. Upravo se ovaj koncept primjenjuje u tipu učenja s podrškom. Tehnika je u početku razvijena za strojeve za igranje igara. Stroj dobiva algoritam za analizu svih mogućih poteza u svakoj fazi igre. Stroj može slučajno odabrati jedan od poteza. Ako je potez ispravan, stroj se nagrađuje, u protivnom može biti sankcioniran. Polako će stroj početi razlikovati ispravne i pogrešne poteze i nakon nekoliko ponavljanja naučit će rješavati zagonetku igre s boljom preciznošću. Točnost pobjede u igri poboljšavala se kako stroj igra sve više i više igara. Ova tehnika strojnog učenja razlikuje se od nadziranog učenja po tome što se moraju dostaviti označene ulazne i izlazne parove. Fokus je na pronalaženju ravnoteže između istraživanja novih rješenja i iskorištavanja naučenih rješenja (Machine learning, tutorials point, 2019.).

2.2.1. Duboko strojno učenje

Duboko učenje model je koji se temelji na umjetnim neuronskim mrežama, točnije Konvolucijskim neuronskim mrežama (CNN). Postoji nekoliko arhitektura koje se koriste u dubokom učenju, poput dubokih neuronskih mreža, mreže dubokih vjerovanja, ponavljajućih

neuronskih mreža i konvolucijske neuronske mreže. Te su mreže uspješno primijenjene u rješavanju problema računalnog vida, prepoznavanje govora, obrada prirodnog jezika, bioinformatika, dizajn lijekova, analiza medicinske slike i igara. Postoji nekoliko drugih područja u kojima se duboko učenje proaktivno primjenjuje. Dubinsko učenje zahtijeva ogromnu procesorsku snagu i ogromne podatke, koji su danas općenito lako dostupni (Machine learning, tutorials point, 2019.).

Duboko strojno učenje s podrškom (DRL) kombinira tehnike dubokog učenja i učenja s podrškom. Algoritmi učenja s podrškom sada se kombiniraju s dubokim učenjem kako bi se stvorio moćan model. Tehnika je bila vrlo uspješna na polju robotike, videoigara, financija i zdravstva. Mnogi se nerješivi problemi sada rješavaju stvaranjem ovog modela. U ovom se području odvijaju mnoga istraživanja i industrije ih vrlo aktivno prate (Machine learning, tutorials point, 2019.).

Ovu metodu objasniti ćemo pomoću utrke za predsjedničke izbore, npr., rezultati izbora bili su jako bliski. Jedan kandidat imao je 50,7% glasova, a drugi 47,9%. Da je postotak glasača promijenio stranu, ishod izbora bio bi drugačiji. Postoje male skupine birača koje će, kada se na njih pravilno apelira, prijeći na stranu. Te skupine možda nisu velike, ali u tako bliskim utrkama mogu biti dovoljno velike da promijene rezultate izbora. Stoga postavljamo si pitanje, kako pronaći ove skupine ljudi? Kako im se obratiti? Odgovor je klasterizacija. Postupak kako se to radi:

- Prvo, prikupljati informacije o ljudima sa ili bez njihovog znanja o tome: bilo kakve informacije koje bi mogle dati neke naznake o tome što im je važno i što će utjecati na njihov glas.
- Zatim te podatke stavite u neku vrstu algoritma klasteriranja.
- Dalje, za svaki klaster (bilo bi pametno prvo odabrati najveći) izradite poruku koja će se svidjeti tim glasačima.

Na kraju organizirat kampanju i promatrati kako bismo vidjeli djeluje li (Machine learning, tutorials point, 2019.).

Klasteriranje je vrsta učenja bez nadzora koje automatski formira skupine sličnih stvari. To je poput automatske klasifikacije. Možete grupirati gotovo sve, a što su stavke sličnije u klasteru, to su klasteri bolji. U ovom ćemo poglavlju proučavati jednu vrstu algoritma klasterizacije nazvanu k-sredina. Naziva se „k“ jer pronalazi jedinstvene klastere „k“, a središte svakog

klastera je srednja vrijednost vrijednosti u tom klasteru (Machine learning, tutorials point, 2019.).

Identifikacija klastera govori algoritmu: „Evo nekih podataka. Sad grupirajte slične stvari i recite mi o tim skupinama“. Ključna razlika od klasifikacije je ta što u klasifikaciji znate što tražite. Iako to nije slučaj u grupiranju. Grupiranje se ponekad naziva klasifikacija bez nadzora jer daje isti rezultat kao klasifikacija, ali bez unaprijed definiranih klasa (Machine learning, tutorials point, 2019.).

2.3. Neuronska mreža

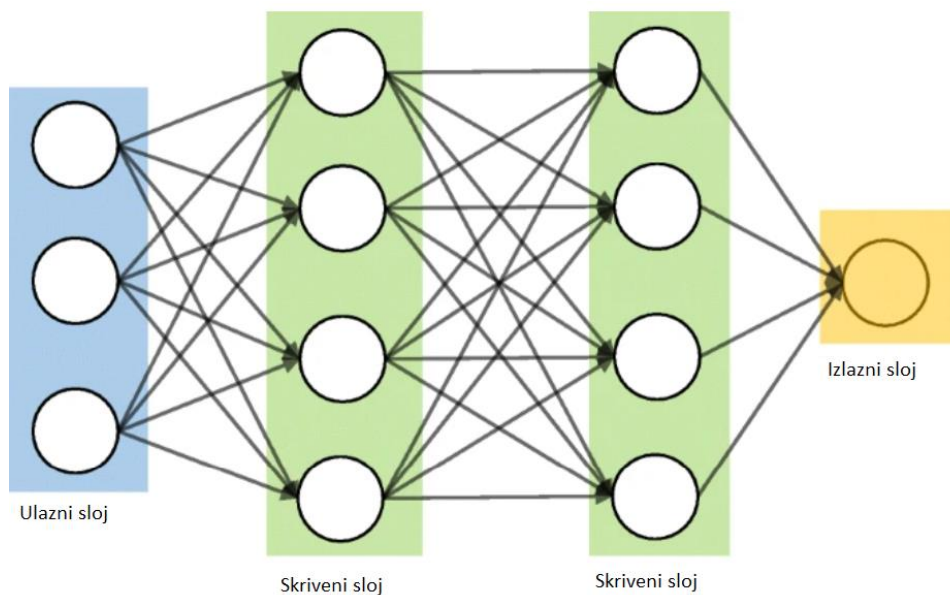
Neuronske mreže, poznate i kao umjetne neuronske mreže (ANN) ili simulirane neuronske mreže (SNN), podskup su strojnog učenja i u srcu su algoritama dubokog učenja. Njihovo ime i struktura inspirirani su ljudskim mozgom, oponašajući način na koji biološki neuroni međusobno signaliziraju. Neuronske mreže oslanjaju se na podatke o obuci kako bi s vremenom naučile i poboljšale svoju točnost. Međutim, nakon što su ti algoritmi učenja precizno podešeni za točnost, oni su moćni alati u računalnoj znanosti i umjetnoj inteligenciji, dopuštajući nam da klasificiramo i grupiramo podatke velikom brzinom. Zadaci u prepoznavanju govora ili prepoznavanju slike mogu potrajati nekoliko minuta u odnosu na sate u usporedbi s ručnom identifikacijom od strane ljudskih stručnjaka. Jedna od najpoznatijih neuronskih mreža je Googleov algoritam pretraživanja. Između 50 i 150 milijardi neurona nalazi se u ljudskome mozgu gdje nisu svi iste vrste (Neuronske mreže predavanje, 2015.).

Umjetne neuronske mreže budu točnije od statističkih tehnika, najviše kada je problem ili zadatak slabo definiran ili nerazumljiv, te ne zahtijevaju znanje o određenom procesu. Neuronska razvija vlastiti plan temeljen na odnosu između varijabli te to se posebno odnosi na nelinearne sustave. Postupak neuronske mreže vrlo fleksibilan i snažan alat jer uči složene odnose i mogućnost uključivanja kvalitativnih i kvantitativnih podataka.

Nedostatci neuronskih mreža mogu su poteškoće u njihovom korištenju, a to je potrebno vrijeme treniranja i determinaciju djelo tvorne mrežne strukture, nasuprot jednostavnijim metodama. Neuronske mreže ne nude kao konačni model podataka razumljiv odnos važnih varijabli. Odnosi između varijabli skriveni su u mrežnoj strukturi i težinskim faktorima veza neuronske mreže. Neuronska mreža ne daje suvisle odgovore izvan raspona vrijednosti primjera iz kojih je učila, a postupak generalizacije naučenih primjera uspješan je samo kod pojava koje su relativno neprekidne. Da bi učenje bilo uspješno, ono zahtijeva veliki broj podataka, a to predstavlja problem (D. Klobučar, 2009)..

2.4. Umjetne neuronske mreže

Umjetne neuronske mreže skup su algoritama strojnog učenja koji su nadahnuti funkcioniranjem neuronskih mreža ljudskog mozga. Prvo su ih predložili McCulloch i Pitts, a kasnije su ih popularizirali. U biološkom su mozgu neuroni povezani jedni s drugima kroz više aksonskih spojeva tvoreći graf poput arhitekture. Te se međusobne veze mogu ponovno povezati što pomaže prilagoditi, obraditi i pohraniti informacije. Jednako tako, umjetna neuronska mreža i njeni algoritmi mogu se predstaviti kao međusobno povezani čvorovi. Izlaz jednog čvora ide kao ulaz u drugi čvor za naknadnu obradu u skladu s međusobnom vezom. Čvorovi su obično grupirani u matricu koja se naziva sloj, ovisno o transformaciji koju izvode. Osim ulaznog i izlaznog sloja, u umjetnoj neuronskoj mreži u okviru može biti jedan ili više skrivenih slojeva. Čvorovi i rubovi imaju težine koje omogućuju podešavanje jačine signala komunikacije koja se može pojačati ili oslabiti ponovljenim treningom. Na temelju treninga i naknadne prilagodbe matrica, težina čvorova i rubova, umjetna neuronska mreža može napraviti predviđanje za testne podatke. Slika 7. prikazuje ilustraciju umjetne neuronske mreže s dva skrivena sloja i s njegovom međusobno povezanom grupom čvorova, strelice povezuju izlaz čvorova iz jednog sloja s ulazom čvorova drugog sloja.

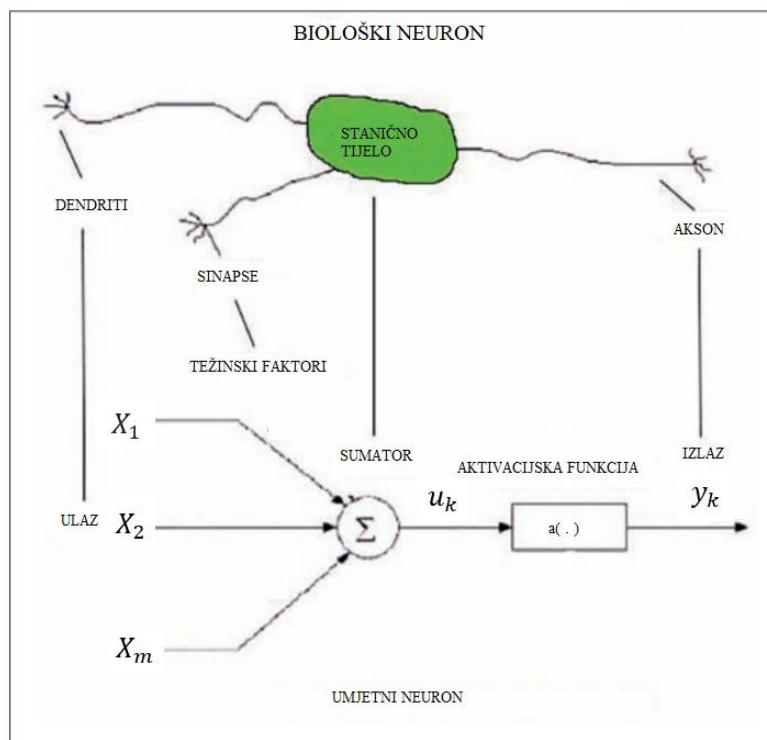


Slika 7. Umjetna neuronska mreža

(<https://bmcmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-019-1004-8>).

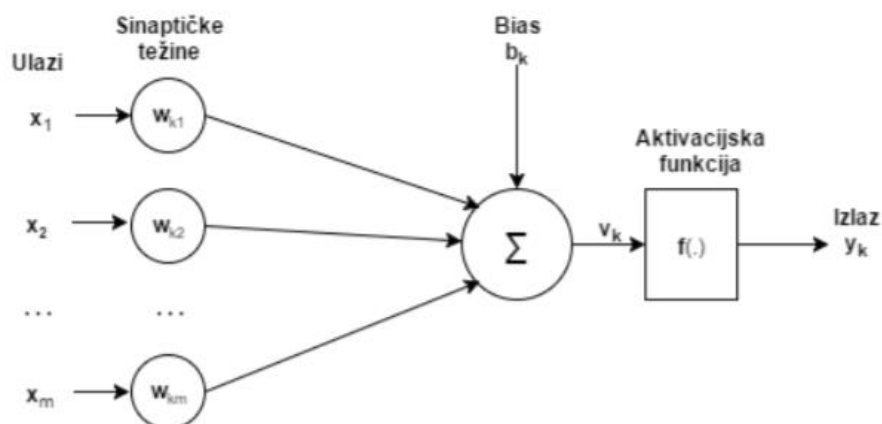
U "klasičnoj" neuronskoj mreži informacije se prenose u jednom smjeru mrežom, gdje je svaki sloj u potpunosti povezan sa svojim susjedima, od ulaznog do izlaznog sloja. Međutim, postoje dvije druge vrste neuronskih mreža koje su posebno prikladne za određene probleme:

konvolucijske neuronske mreže (CNN) i rekurentne neuronske mreže (RNN). Odnosi glavnih komponenti biološkog i umjetnog neurona prikazana su na slici 8.



Slika 8. Komponente biološkog i umjetnog neurona (Izvor: D. Klobučar, 2009.)

Umjetni neuron (prikazan na slici 9.) koji čini gradivnu jedinicu umjetne mreže neurona. Tri su elementa koja ga čine: skup sinapsi, procesna jedinica i aktivacijska funkcija. Kanali su ulazne veze u kojima ulazni signal dolazi do procesne jedinice neurona. Sinaptička težina umjetnog neurona može sadržavati pozitivnu i negativnu vrijednost, za razliku od sinaptičke težine prirodnog neurona koja ne može posjedovati ovu negativnu vrijednost.



Slika 9. Umjetni neuron (Izvor: Ćorić, 2017.)

Procesna jedinica ima zadatak zbrajanja ulaznih signala multiplicirane vrijednošću pripadajuće sinaptičke težine i generira ulaz u aktivacijsku funkciju neurona. Aktivacijska funkcija ima zadatak transformiranja dobivenog ulaza u izlazni signal neurona.

Ovisno o problemu koji se modelira, koristi se mnogo vrsta aktivacijskih funkcija, ali najbitniji osnovni tipovi su: funkcija praga, linearna funkcija po odsječcima i sigmoidna funkcija (Ćorić, 2017.).

2.4.1. Podjela umjetnih neuronskih mreža

Feedforward neuronska mreža ili duboka *feedforward* mreža jedna je od najjednostavnijih vrsta umjetnih neuronskih mreža. U ovom ANN -u podaci prolaze kroz nekoliko ulaznih čvorova (računske jedinice poznate i kao umjetni neuroni) sve dok ne stignu do izlaznog čvora. Jednostavno rečeno, informacije prolaze u jednom smjeru od ulazne točke ili ulaznog čvora do izlazne točke ili izlaznog čvora. Razlikuje se od drugih složenijih tipova ANN -a po tome što nema povratne veze gdje se izlaz iz svakog sloja neurona vraća na učenje. Unaprijed usmjerena neuronska mreža ne čini ciklus ili petlju koja omogućuje programu učenje. Ove neuronske mreže koriste se u računalnom vidu i aplikacijama za prepoznavanje lica.

Neuronska mreža radijalne osnove ima samo tri sloja - ulazni sloj, skriveni sloj i izlazni sloj. Ograničeno je na jedan skriveni sloj u usporedbi s drugim vrstama. Skriveni sloj je u osnovi skriven između ulaznih i izlaznih slojeva te smanjuje višak podataka. U usporedbi s drugim vrstama koje mogu imati nekoliko skrivenih slojeva, učenje je brže u ovoj mreži. Da bismo dodatno razumjeli čemu služe različiti slojevi, zamislimo da želimo obavijestiti svoje računalo da raspozna automobil na slici. Da bi računalo razumjelo, potrebni su mu zasebni alati (ili slojevi). Tako naš detektor automobila može imati detektor kotača pa može reći da nešto ima kotače. Trebao bi imati detektor karoserije vozila koji bi mu mogao omogućiti razlikovanje automobila od kamiona i detektor veličine kako bi mogao učiniti isto. Ovo su samo neki elementi koji čine skrivene slojeve u umjetnim neuronskim mrežama. Ne predstavljaju cijelu sliku, već su njeni dijelovi. Neuronska mreža radijalne osnove se mogu koristiti u složenim sustavima za obnovu energije. U slučaju nestanka struje, mogu se koristiti za vraćanje električne energije u normalne uvjete uz minimalne gubitke i manji utjecaj na društvo. Također se mogu opsežno primijeniti za predviđanje vremenskih uvjeta. Primjer bi bio trgovanje dionicama, gdje računala predviđaju koje će dionice vjerojatno povećati ili smanjiti vrijednost, dopuštajući korisnicima pametno ulaganje.

Ponavljajuća neuronska mreža slična je prethodnoj neuronskoj mreži, ali sprema izlaz određenog sloja i vraća ga kao ulaz. Kao rezultat toga, može pomoći u predviđanju nekoliko mogućih ishoda iz bilo kojeg sloja. Ako prvi sloj primi izlaz i pošalje ga natrag kao ulaz, sljedeći slojevi će pokrenuti ponavljajući proces neuronske mreže. Svaki čvor zadržava memoriju iz prethodnog koraka. Dakle, sustav pamti pogrešna predviđanja i uči od njih kako bi poboljšao svoja sljedeća. Ukratko, ova neuronska mreža može naučiti iz svakog koraka predvidjeti ishod u sljedećem koraku. Koriste u aplikacijama pretvaranja teksta u govor koje predviđaju što bi korisnici dalje htjeli reći, ovisno o kontekstu njihovog početnog unosa.

Višeslojna *Perceptron* mreža ima tri ili više slojeva koji klasificiraju podatke koji se ne mogu linearno odvojiti. Dakle, potpuno je povezan, što znači da je svaki čvor unutar sloja povezan sa sljedećim čvorom u sljedećem sloju. Ova mreža koristi se u prepoznavanju govora i tehnologijama strojnog prevođenja.

Konvolucijska neuronska mreža primjenjuje različitu verziju prethodne mreže tako što ima nekoliko slojeva koji se mogu potpuno međusobno povezati. Primarna svrha joj je dešifriranje specifičnih značajki date slike, poput lica. Oni identificiraju značajke na temelju toga koliko je svaki piksel (koji čini svaku crtu lica) blizu ili daleko od referentne točke. Ova mreža široko se koristi za precizno otkrivanje lica čak i ako je ulazna slika niske rezolucije. Oni su također osobito korisni za poboljšanje procjene o polju vožnje kod autopilota u automobilu, budući da su vrlo dobri u određivanju udaljenosti. Druge primjene uključuju obradu prirodnog jezika, detekciju parafraza i klasifikaciju slika (Artificial Neural Networks: Types and Applications, 2021.).

2.5. Duboka neuronska mreža

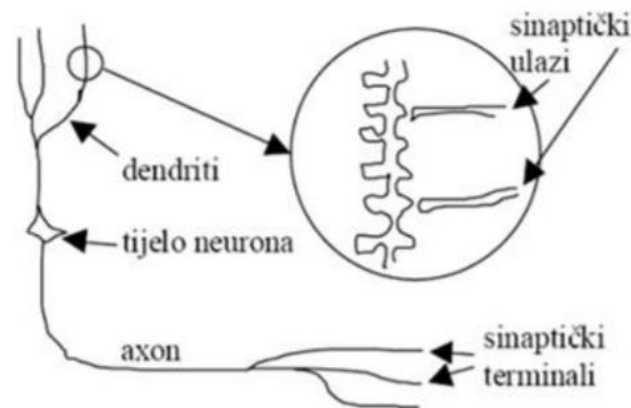
Neuronske mreže mogu se stvoriti iz najmanje tri sloja neurona: ulaznog sloja, skrivenih slojeva i izlaznog sloja. Između skrivenog sloja nalaze se mnogi neuroni, s vezama između slojeva. Kako neuronska mreža "uči" podatke, težina ili snaga veza između tih neurona su "fino podešene", što omogućava mreži da iznese točna predviđanja.

Algoritmi strojnog učenja neuronske mreže modeliraju se na način na koji mozak radi, konkretno na način na koji predstavlja informacije. Kada neuronska mreža ima mnogo slojeva, to se naziva dubokom neuronskom mrežom, a proces treninga i korištenja dubokih neuronskih mreža naziva se dubokim učenjem. Duboke neuronske mreže uglavnom se odnose na posebno složene neuronske mreže. Oni imaju više slojeva (čak 1.000) i obično više neurona po sloju. S

više slojeva i više neurona, mreže se mogu nositi sa sve složenijim zadacima; ali to znači da im treba više vremena za trening (Artificial Neural Networks: Types and Applications, 2021.).

2.6. Biološki neuron

Ćorić, 2017. navodi kako je to sustav koji predstavlja mrežu specijaliziranih stanica koje prenose, šalju ili primaju informacije iz biološke okoline ili iz samog organizma. Živčani sustav upravlja njegovim ponašanjem. Ovakav raspored učinio je polazište za produciranje sustava koji oponašaju procese rezoniranja svojstvene čovjeku. Središte živčanog sustava je mozak. Ljudski mozak je nelinearno računalo sa sposobnošću paralelnog procesiranja velikog broja informacija. Osnovna građa stanica živčanog sustava je neuron. Neuron je ćelija koja propagira elektrokemijske signale, a slika 10. prikazuje dijelove biološkog neurona.



Slika 10. Struktura biološkog neurona (Izvor: Ćorić, 2017.)

Od djelotvornosti sinapsi ovisi jačina signala koju prima neuron. Svaka sinapsa je sastavljena od prostora koji je ispunjen neurotransmiterima koji prenose signal. Mozak na temelju rada jako velikog broja relativno jednostavnih procesnih jedinica uspijeva upravljati ekstremno kompleksnim procesima. Svaki od ovih neurona prima i zbraja niz ulaznih signala te ako njihova veličina prelazi određenu razinu, generira slijedeći signal i prosljeđuje ga slijedećoj procesnoj jedinici (Ćorić, 2017.).

3. PRIMJENA STROJNOG UČENJA U POLJOPRIVREDI

Poljoprivredna tehnologija i precizna poljoprivreda, koja se danas naziva i digitalna poljoprivreda, nastala su kao nova znanstvena područja koja koriste podatkovno intenzivne pristupe za vođenje poljoprivredne produktivnosti uz minimalan utjecaj na okoliš. Podaci generirani u suvremenim poljoprivrednim radnjama pružaju se nizom različitih senzora koji omogućuju bolje razumijevanje operativnog okruženja i samog postupka, što dovodi do preciznijeg i bržeg donošenja odluka (Rsip vision, 2020.).

3.1. Predviđanje prinosa

Predviđanje prinosa usjeva u preciznoj poljoprivredi odnosi se na procjenu sezonskog prinosa prije žetve, na temelju senzornih i satelitskih snimaka, poput stanja tla, razine dušika, vlage, sezonskog vremena i povijesnih podataka o prinosu. Do danas se sezonski planovi upravljanja za predviđanje prinosa u velikoj mjeri oslanjaju na podatke o oborinama. Međutim, kiše ostaju nepredvidljiv čimbenik, pa se na njih ne može računati kao na pouzdana predviđanja prinosa usjeva tijekom cijele sezone. U posljednja dva desetljeća bilježi se sve veći trend uključivanja senzornih podataka u plan upravljanja, bilo da se radi o kombiniranim, stacionarnim sensorima (npr. LiDAR), bespilotnim letjelicama (npr. multispektralno snimanje) ili satelitom te je to je rezultiralo bogatstvom dostupnih podataka, takav primjer snimanja tla možemo vidjeti na donjoj slici (Rsip vision, 2021.).


Dobar primjer strojnog učenja u poljoprivredi je aplikacija koja automatski broji plodove na grani. Metoda razvrstava plodove u tri kategorije, da li je plod za berbu ili ne i plodovi koji su u fazi sazrijevanja. Uz to metoda procjenjuje težinu i postotak sazrijevanja plodova. Cilj ovoga je pružiti informacije proizvođačima kako bi optimizirali ekonomske koristi i planirali svoj poljoprivredni rad. Glavni cilj je smanjiti potrebe za radnom snagom u operacijama ručne berbe i rukovanja (Rsip vision, 2021.).

3.2. Otkrivanje bolesti


Poljoprivredna produktivnost je nešto o čemu gospodarstvo uvelike ovisi. To je jedan od razloga zašto otkrivanje bolesti u biljkama ima važnu ulogu u poljoprivredi, jer su bolesti u biljkama sasvim prirodne. Ako se o tome ne vodi odgovarajuća briga, to uzrokuje ozbiljne učinke na biljke i zbog kojih to utječe na kvalitetu, količinu ili produktivnost proizvoda. Otkrivanje biljnih bolesti pomoću neke automatizirane tehnike korisno je jer smanjuje velik opseg posla praćenja na velikim farmama usjeva, a u vrlo ranoj fazi otkriva simptome bolesti. Kao primjer navodim algoritam za tehniku segmentacije slike koji se koristi za automatsko

otkrivanje i klasifikaciju bolesti lišća biljaka. Segmentacija slike, koja je važan aspekt za otkrivanje bolesti kod bolesti biljnih listova, vrši se pomoću genetskog algoritma.

Digitalni fotoaparati ili slični uređaji koriste se za snimanje lišća različitih vrsta, a zatim se koriste za prepoznavanje pogođenog područja u listovima, kao što je prikazano na slici 11. i 12. Tada se na njih primjenjuju različite vrste tehnika obrade slika, za obradu tih slika kako bi se dobile različite i korisne značajke potrebne za svrhu kasnije analize. Automatsko otkrivanje bolesti lista se obavlja pomoću algoritma za tehniku segmentacije slika koji nadalje služi i kao kasnija klasifikacija biljnih listova. Još jedna prednost korištenja ove metode je u tome što se biljne bolesti mogu prepoznati u ranoj fazi ili u početnoj fazi. Na donjoj slici prikazan je primjer poboljšavanja stope prepoznavanja u procesu klasifikacije gdje se također može koristiti umjetna neuronska mreža (Electronics-Digital Systems, 2021.).



Slika 11. Dijagnosticiranje simptoma na listu (Izvor: Electronics-Digital Systems)




Slika 12. Različiti efekti koji upućuju na određenu bolest lišća (Electronics-Digital Systems)

3.3. Otkrivanje korova

Otkrivanje i upravljanje korovom još je jedan važan problem u poljoprivredi. Mnogi proizvođači navode korov kao najvažniju prijetnju za biljnu proizvodnju. Točno otkrivanje korova od velike je važnosti za održivu poljoprivredu, jer je korov teško otkriti i razlikovati usjeve. Algoritmi u strojnom učenju zajedno sa sensorima mogu dovesti do preciznog otkrivanja i uništavanja korova s niskim troškovima i bez ekoloških problema i nuspojava.

Strojno učenje za otkrivanje omogućilo je razvoj alata i robota za uništavanje korova, što smanjuje potrebu za herbicidima. Pomoću multispektralnih slika snimljenim bespilotnim zrakoplovnim sustavima omogućeno je identificirati korove koje je teško iskorijeniti i koji uzrokuju velike gubitke na prinosu usjeva, primjere takvih slika vidimo na slici 13.



Slika 13. Detekcija korova u programu MATLAB (Izvor: El Weed Detection in Agriculture Using Image Processing)

3.4. Kvaliteta usjeva

IoT kamere, roboti za raspršivanje, roboti za podrezivanje, pametni telefoni, sve to igra ulogu u kvaliteti usjeva. Uređaji fotografiraju usjeve i prenosi ih poslužitelju u različite svrhe. Na primjer, kamere IoT-a i mobilne kamere koriste se za prikupljanje podataka o cijelom poljoprivrednom zemljištu kako bi se pratio detaljan status uzgoja određenih usjeva. IoT kamere prikupljaju fotografije procesa rasta određene kulture u stakleniku, gdje bilježe rast usjeva u različito vrijeme. Fotografije snimljene mobilnom kamerom sadrže status rasta raznih usjeva, a fotografije se rade kao testni set. Prikupljeni podaci dostavljaju se računalima na platformi i kombiniraju s pravilima i propisima o uzgoju biljaka kako bi se odredile mjere upravljanja. Poljoprivredni strojevi i roboti neovisno prikupljaju slike usjeva i odmah ih pretvaraju u mjere upravljanja, omogućujući visoku razinu prostorne i sezonske dinamike. Ti zadaci terenskog održavanja jako ovise o izvedbi mrežnih algoritama za donošenje odluka u

stvarnom vremenu i pohranjeni su na platformi (Machine Learning in Agriculture: A Review, 2021.).

3.5. Predviđanje svojstava tla

Strojno učenje se primjenjuje na identifikaciju i predviđanja poljoprivrednih svojstava tla, poput procjene sušenja tla, stanja, temperature i sadržaja vlage. Tlo je heterogen prirodni resurs, sa složenim procesima i mehanizmima koje je teško razumjeti. Svojstva tla omogućavaju istraživačima da razumiju dinamiku ekosustava i utjecaj na poljoprivredu. Točna procjena stanja tla može dovesti do poboljšanog gospodarenjem tla. Samo temperatura tla igra značajnu ulogu za preciznu analizu učinaka klimatskih promjena u regiji i ekoloških uvjeta. To je značajan meteorološki parametar koji kontrolira interaktivne procese između tla i atmosfere. Uz to, vlaga tla ima važnu ulogu za promjenljivost prinosa usjeva. Međutim, mjerenja tla obično su dugotrajna i skupa, pa se pomoću računalne analize temeljene na strojnom učenju može postići jeftino i pouzdano rješenje za točnu procjenu tla. Metoda precizno procjenjuje sušenje tla, s podacima o evapotranspiraciji i oborinama za željenu regiju (Machine Learning in Agriculture: A Review).

3.6. Integracija s 5G tehnologijom

Kako bi precizna poljoprivreda zaista porasla, potrebna je poljoprivredna mehanizacija povezana s 5G mrežom. Masivno povećanje računalne snage i prikupljanja podataka pokretačke su snage porasta umjetne inteligencije. „5G na poljoprivrednim strojevima i sensorima uvelike će povećati količinu dostupnih podataka, što znači da umjetna inteligencija može pravilno funkcionirati“, navodi Paul Beastall, direktor tehnološke strategije u Cambridge Consultants. „Farme se obično vode mješavinom iskustva i specijaliziranog znanja, a centralizirana umjetna inteligencija već uočava obrasce koji omogućuju poboljšanje prinosa, npr., davanjem upozorenja na bolesti u staklenicima“ (Dione project, 2020.).

Koristeći 5G, poljoprivrednici mogu pratiti poljske uvjete i biti obaviješteni kada usjevi trebaju vode, pesticide ili gnojiva. Druge uporabe 5G-a u poljoprivredi susrećemo u uzgoju stoke, upravljanjem poljoprivrednih dronova, automatizacija upravljanja traktora, itd. Rezultat za poljoprivredu je bolji prinos usjeva, bolja kvaliteta proizvodnje i veći profit. 5G podržava pametni uzgoj koji zahtijeva precizne tretmane usjeva. Umjesto da tretiraju cijelo polje na isti način, poljoprivrednici mogu svakome redu biljaka dati upravo ono što mu je potrebno. 5G je ključan za to jer podržava komunikaciju između strojeva. Također ubrzava cijeli prostor, omogućujući centralno upravljanje strojevima i slanje podataka u stvarnome vremenu. U bliskoj budućnosti bespilotne letjelice s omogućenim 5G-om izrađivat će kartu korova ili

štetnika kako bi omogućio tretmane specifične za određena mjesta. To bi uvelike smanjilo potrebnu količinu sredstava za zaštitu bilja jer se ne bi proširila na cijeli usjev, već na određene ciljane biljke. Za takve zadatke potrebne su visoke rezolucijske slike. 5G otvara mogućnost stvaranja učinkovitog tijeka rada. Slike se izravno prenose s parcele na poslužitelja gdje se slike obrađuju i rezultat se vraća u poljoprivredni stož koji tretira određenu parcelu. Takav tijek rada ima veliku korist jer je produktivnost poljoprivrednika vrlo velika jer ne mora premještati ili obrađivati podatke (Dione project, 2020.).

5G nudi veliki potencijal za poljoprivredu. Mnoge farme, čiji je pristup optičkim uređajima preskup, imat će širokopojasni pristup internetu putem 5G. Strojevi i oprema u stajama i poljima na bilo kojem mjestu mogu se uključiti u mrežu farmi. Razvija se širok raspon novih tehnologija, poput kontrole navodnjavanja, suzbijanja korova, senzora za krave i autonomnih vozila, a sve to ima koristi od brzog prijenosa podataka. Ove će tehnologije nesumnjivo biti važne kako bi poljoprivredna proizvodnja bila učinkovitija i održivija kako bi se odgovorilo na glavne aktualne izazove (Dione project, 2020.).

Opremljeni su sa skenerom za korov i raspršivačem usjeva, skeniraju usjeve pomoću umjetne inteligencije za identifikaciju korova zatim primjenjuju pesticide samo tamo gdje je to potrebno. Nakon otprilike 30 minuta vraćaju se na graničnu stanicu, napune spremnik i napune bateriju. Ručni rad i dalje će imati mjesto u tretiranju, ali kombiniranjem pametnih tehnologija sa snagom 5G -a, poljoprivrednici će moći učinkovitije rasporediti svoje vrijeme na područja koja su doista važna. Slika 14. prikazuje daljinski navođeni dron od strane čovjeka (Pinduoduo global, 2020.).



Slika 14. Tretiranje zemljišta pomoću drona (<https://www.indiamart.com/proddetail/agribot-agricultural-pesticide-spraying-drone-21773981997.html>)

U suvremenoj tehnologiji postoje kamere koje mogu razlikovati usjeve i korov. Dobar je primjer sustav „Vodafone 5G system“ iz „Blue Rivera“, koji je sada u vlasništvu poljoprivrednog diva John Deere. Tehnologija "See & Spray" koristi kamere visoke rezolucije koje snimaju 20 slika u sekundi, a na slike se primjenjuje umjetna inteligencija kako bi sustav prepoznao razliku između uzgojenih biljaka i korova. Umjesto velike količine tretiranja, smanjuje upotrebe pesticida. Drugi primjer je „Fafaza“, koja čini nešto slično otkrivajući razlike u boji i teksturi lista kako bi izolirala biljke. Dizajniran je za rad autonomno, bez zajamčene mrežne veze, a sva potrebna obrada instalirana je na platformi (Pinduoduo global, 2020.).

3.7. Praćenje životinja na farmama

Sposobnost lociranja i praćenja stoke osobito u brdskim područjima i na rančevima, ključna je za poljoprivrednike. Ako se zdravlje krava, unos hrane, pa čak i njihova plodnost mogu prenijeti poljoprivrednicima, oni mogu odlučiti kada će intervenirati. 5G će omogućiti usluge povezivanja i geolokacije, što bi moglo smanjiti troškove i povećati performanse rješenja za nadzor stoke koja trenutačno ovise o vlasničkim radijskim rješenjima, međutim, to će ovisiti o dostupnosti pokrivenosti 5G mrežom, a rana implementacija usmjerena je na urbana središta (Pinduoduo global, 2020.).

Poznavanje fizičkog položaja krave i stada može biti od kritičnog značaja za poljoprivrednike, a još više kada je sezona teljenja. „Moocall“ senzor, Vodafone-ov senzor montiran na repu krave koji upozorava poljoprivrednike kada se tele treba roditi. Od lansiranja 2017. godine više od 250.000 teladi rođeno je sigurno pomoću „Moocall“ senzora. Ovo je umjetna inteligencija, i iako ne zahtijeva posebno 5G, nema sumnje da će 5G uskoro s ovom tehnologijom ići ruku pod ruku (Pinduoduo global, 2020.).

3.8. Smanjenje potrošnje vode pri navodnjavanju usjeva

U suhim, sušnim i udaljenim područjima ključna je ušteda čak i kapi vode. U probnom partnerstvu s alžirskim operatorom mobilne mreže Djezzy, Nokia je stvorila svjetsku mrežu internetskih mreža (WING) za opremanje alžirskih uzgajivača breskvi s praktičnim podacima koji će im pomoći u postizanju boljih prinosa. Sonde za tlo zakopane 120 cm ispod linije za navodnjavanje prikupljaju i šalju podatke o tlu koji poljoprivrednicima omogućuju praćenje vlažnosti tla, uzoraka vode i slanosti. Očitavanja se analiziraju kako bi poljoprivrednik mogao točno upravljati ciklusima navodnjavanja i ishranom tla. Nakon mjesec dana poljoprivrednik je smanjio potrošnju vode za 40% na jednoj liniji za navodnjavanje za jedan hektar i povećao

prihod do 5% po hektaru. *WING* radi na svim mobilnim mrežama, ali takva će se ispitivanja poboljšati samo s 5G -om (Pinduoduo, 2020.).

3.9. Dron za prijevoz tereta

Još jedan primjer bespilotnih letjelica u poljoprivredi je *Volocopter*-ov novi *VoloDrone* koji, bespilotna letjelica razvijena s John Deere-om. Bespilotni, potpuno električni, letjelica za teške terete sposobna nositi nosivost do 200 kg, *VoloDrone* može transportirati kutije, tekućine i opremu bilo gdje na farmi ili čak prolaziti zemljištem kako bi zastrašio ptice. Potpuno električan, ima promjer 9,2 m i pokreće se s 18 rotora, takav primjer prikazan je slici 15. (Research gate, 2020.).



Slika 15. VoloDrone za prijevoz manjeg tereta
(<https://www.volocopter.com/solutions/volodrone/>)

3.10. Roboti u poljoprivredi

Nakon godina iščekivanja, robotika je napokon ušla u svijet poljoprivrede kako bi napravila razliku u ovom ključnom području. Samo po sebi, tržište robotike već neko vrijeme cvjeta, s procijenjenom vrijednošću od 23,67 milijardi USD u 2020. Očekuje se da će to doseći nevjerojatnih 74 milijarde USD do 2026. godine, a respektabilan dio ovog rasta bit će posvećen poljoprivrednoj robotizaciji (Research gate, 2020.).

Poljoprivredni roboti specijalizirani su tehnološki napredci koji mogu pomoći poljoprivrednicima u širokom rasponu operacija. Imaju sposobnost analiziranja, razmišljanja i

izvršavanja mnoštva funkcija, a mogu se programirati za rast i razvoj kako bi odgovarali potrebama različitih zadataka (Research gate, 2020.).

Poljoprivredni roboti mogu se koristiti za nevjerojatan broj zadataka kako bi se olakšalo poljoprivrednicima. Njihova je primarna uloga rješavanje radno intenzivnih, ponavljajućih i fizički zahtjevnih zadataka. Posljednjih godina roboti se koriste i za razne specijalizirane poslove kojima su se prethodno bavili samo iskusni poljoprivrednici. To uključuje mogućnost selekcije osjetljivog voća i povrća, poput salate i jagoda (Research gate, 2020.).

U svijetu postoje brojne korporacije i sveučilišta koja su duboko uložena u poljoprivrednu robotiku. Događaji i iskoraci u ovom segmentu događaju se brzo i brzo, pa zato u nastavku dolje navodimo neke od najvećih otkrića.

Fizikalnost povezana sa žetvom usjeva uvijek je bila težak poduhvat za poljoprivrednike diljem svijeta, pa se zato robotika koristi za smanjenje zahtjeva ovog zadatka. Ova naporna i ponavljajuća poljoprivredna djelatnost također je neizbježna, ali priroda posla čini da roboti uđu i preuzmu odgovornost. Jedini pravi problem ovdje se odnosio na ručnu spretnost potrebnu za branje raznog voća i povrća. Svaka vrsta proizvoda ima svoje jedinstvene zahtjeve i to zahtijeva ogromnu količinu istraživanja i mehaničke stručnosti. Posebno je poznato da se voće izuzetno lako brzo kvari (modri, mijenja boju), dok je lisnato povrće podložno suzama. Rješavanje ovog problema zahtijeva ogromnu količinu preciznosti koju je potrebno programirati u robote koji će biti postavljeni na ovaj zadatak. Srećom, nekoliko velikih imena već se uključuje kako bi popunilo ovu ogromnu prazninu u agrotehnici (Research gate, 2020.). Jedno od najvećih imena koja se bave ovim segmentom robotike u poljoprivredi je Sveučilište Cambridge. Oni su stvorili jedinstvenog robota poznatog kao *Vegebot* (prikazan na slici 16.), a ovo je prototip koji se oslanja na računalni vid kako bi postigao nevjerojatnu točnost prilikom žetve usjeva.



Slika 16. *Vegebot* u radu (<https://www.agri-tech-e.co.uk/robot-uses-machine-learning-to-harvest-lettuce%E2%80%A8/>)

Sveučilište Cambridge posebno je dizajniralo ovog robota da može brati biljke salate, zadatak koji se ne tako davno smatrao gotovo nemogućim za strojeve. *Vegebot* ima dvije glavne komponente: sustav računalnog vida i sustav rezanja. Gornja kamera na *Vegebotu* snima sliku polja salate i prvo identificira sve salate na slici. Zatim za svaku salatu robot klasificira treba li je ubrati ili ne. Salata se može odbiti jer još nije zrela ili bi mogla imati bolest koja bi se u berbi mogla proširiti i na drugu salatu. Znanstvenici su razvili i obučili algoritam strojnog učenja na primjerima slika zelene salate. Nakon što je *Vegebot* mogao prepoznati zdravu salatu u laboratoriju, tim ju je zatim istrenirao na terenu, u različitim vremenskim uvjetima, na tisućama pravih glavica salate. Kamera na *Vegebotu* omogućuje skeniranje salate i otkrivanje je li određena biljka zrela za berbu ili nije. Nakon što robot odluči da je biljka spremna za branje, koristi drugu kameru postavljenu blizu oštrice robota kako bi vodila njegove radnje i izvršila je do savršenstva. Druga kamera na *Vegebotu* postavljena je u blizini noža za rezanje i pomaže u osiguravanju glatkog rezanja. Istraživači su također uspjeli podesiti tlak u ruci za hvatanje robota tako da je držala salatu dovoljno čvrsto da je ne ispusti, ali ne toliko da je zdrobi. Sila hvata može se prilagoditi za druge usjeve. *Vegebot* prvo identificira "ciljani" usjev u svom vidnom polju, zatim utvrđuje je li određena salata zdrava i spremna za berbu. Konačno, reže salatu s ostatka biljke, a da je ne smrvi, tako da je "spremna za supermarket". Za čovjeka cijeli proces traje nekoliko sekundi, ali to je doista izazov za robota. Algoritam strojnog učenja

također je korišten u softveru *Vegebota* kako bi mu pomogao u otkrivanju zrele salate koja je idealna za branje (Food ingredients first, 2020.).

Iako se *Vegebot* u sadašnjoj fazi ne može natjecati s brzinom ljudskih ruku, poljoprivrednoj zajednici dobro predstavlja to što je ova tehnologija u tako kratkom vremenu postigla tako brze korake. Ako robot može pomoći u berbi osjetljivog usjeva poput salate, to može biti dvostruko korisno za tvrde proizvode koji nisu skloni brzom kvarenju (Automated harvesting, 2021.)

Harvest Croo je još jedan veliki brand koji posluje u SAD -u i koji je duboko povezan sa stvaranjem robota za žetvu i berbu. Trenutno su specijalizirani za branje jagoda jer je to voće poznato po sklonostima oštećenja tijekom sezone berbe.

Njihov robot se zove *Berry 5* i vrhunac je različitih komponenti umjesto pojedinačnih ruku koje se tradicionalno koriste u robotima u poljoprivredi. Ove komponente mogu pomoći *Berry*-u 5 u izvršavanju složenih zadataka, poput hvatanja lista grma jagoda, nježnog ubiranja jagode i sigurnog pakiranja.

Slično kao i robot razvijen na Sveučilištu Cambridge, *Berry 5* također se oslanja na računalni vid kako bi mu pomogao razlikovati zrele i sirove plodove. Za razliku od *Vegebota*, *Berry 5* iznimno je brz u izvođenju. Sposoban je ubrati grm jagode za osam sekundi, a može se premjestiti na sljedeći grm za dodatnih 1,5 sekundi. Na slici 17. možemo vidjeti primjer *Berry 5* koji se koristi na poljima Floride i uskoro bi trebao biti potpuno komercijaliziran.



Slika 17. *Berry 5* robot u radu (<https://www.growingproduce.com/fruits/get-in-gear-now-for-agricultures-robotic-revolution/>)

Video procesori koji se koriste u ovom robotu mogu analizirati 30 gigabajta podataka u sekundi, što je nevjerojatno. To mu omogućuje snimanje slika visoke rezolucije za identifikaciju zrelih

bobica na biljci u vrlo kratkom vremenu. Srce stroja je njegov kotač za odabir. Svaki kotač opremljen je stereo kamerom za vid i daje svakoj bobici na biljci vrijednost zrelosti kako bi se utvrdilo je li spremna za branje. Ako je zrelo, mehanička stezaljka će ubrati bobicu i baciti je u šalicu prije nego što je premjesti na razinu platforme. Robot će također izbušiti rupe prije sadnje. To se radi pomoću GPS preciznosti. Kad kotači za berbu prođu kasnije u sezoni za berbu, GPS će omogućiti stroju da otkrije gdje se točno nalaze središta biljaka. Svaki stroj bit će opremljen sa 16 kotača za berbu na platformi s autonomnim pogonom koja će se protezati kroz četiri reda jagoda. Kad je u potpunosti operativan, cilj je da svaki stroj može ubrati 8 hektara dnevno, pokrivajući 25 hektara u trodnevnom ciklusu. "Da uzgajivač ima veće polje, poput 25 hektara, mogao bi razmisliti o postavljanju tri stroja na polje i brati ga tijekom jednog dana, a ne tri dana", navodi Wishnatzki, osnivač kompanije *Harvest Croo*. "Postoji mnogo različitih razmatranja koja razmatramo u razvoju sustava. No, naš cilj je da jedan stroj zamijeni potrebu za oko 25 do 30 radnika." Wishnatzki voli koristiti analogiju mobitela kako bi objasnio budućnost robotike i drugih tehnologija. "Kad me ljudi pitaju gdje smo s ovom tehnologijom, kažem im da razmisle o najranijim mobitelima", navodi Wishnatzki. "Tu smo danas sa svojom robotskom tehnologijom, na samom početku onoga što ćemo moći učiniti." Dodaje da su ljudi samo htjeli telefonirati s ranim mobitelima i nisu mogli ni zamisliti sve što se može učiniti s današnjim pametnim telefonima. Vjeruje da će to biti slučaj sa strojem *Harvest CROO* (The guardian, 2021.)

Primarni proizvod tvrtke Roomb naziva se robot *HV-100*, a njegova je funkcija usmjerena na razmak između različitih vrsta biljaka i usjeva tijekom sezone žetve.

Ova je tehnika osobito korisna za staklenike jer biljke u ovom ekosustavu moraju biti ravnomjerno raspoređene kako bi se spriječilo preklapanje rasta i izgradila otpornost.

Posebnost ovog robota je to što može raditi u nepovoljnim uvjetima i rasadnicima. U početku su posude zbijene, ali se uskoro moraju razdvojiti ili razmaknuti kako bi biljke mogle nastaviti rasti bez isprepletanja i međusobnog oštećenja. Iako je malo poznat izvan industrije, razmak je kritična operacija u životu gotovo svake hortikulturene biljke. Razmak možemo vidjeti na slici 18., što je jedna od nekoliko operacija koje *HV-100* roboti izvode.



Slika 18. Jednak razmak između sadnica

(<https://www.roboticstomorrow.com/article/2013/07/case-study-harvest-automation-hv-100-robots-are-the-key-that-unlock-production-efficiencies/177/>)

Veliki problem uzgajivača u Americi je taj što je briga o razmaku jedan od najmanje poželjnih poslova na farmi. Zadatak uključuje saginjanje, podizanje jednog ili više spremnika u svaku ruku (težina spremnika do 22 kilograma po komadu), hodanje nekoliko koraka, a zatim ponovno saginjanje kako biste ih pažljivo postavili u određeni, unaprijed definirani uzorak. Radnici obavljaju ovaj zadatak svakodnevno tijekom vegetacije u uvjetima koji se penju do visokih temperatura pa do hladne kiše. Rad je sezonski, ozljede su česte, a plaće niske. Problemi s zainteresiranom radnom snagom su stalni. Nepoželjna vrsta ovoga posla, rada na razmaku, rezultira velikim problemom za uzgajivače, teško je predvidjeti koliko će se radnika pojaviti na određeni dan. Kada je premalo radnika na raspolaganju, uzgajivači obavljaju samo najhitnije poslove, a zanemaruju druge. Takvi kompromisi mogu utjecati na prinos i kvalitetu biljaka te na isplativost poslovanja. Zbog ovakvih problema, uzgajivačima dolazi ideja za usvajanje robota. Zapravo, u Americi, ova kompanija praktički nije naišla na uzgajivače koji nisu bili voljni razmotriti korištenje robota. Industrija nudi bogate mogućnosti za robote: samo u SAD - u sektor rasadnika i staklenika proizvodi biljke u vrijednosti od oko 17 milijardi dolara godišnje. Procjenjuje se da se svake godine proda jedna do dvije milijarde biljaka iz kontejnera, a svaka se biljka obično pokupi i preseli nekoliko puta tijekom svog života na farmi (Robotics tomorrow, 2021.). HV-100 robot sastoji se od složenih dijelova, a neke od njih možemo vidjeti na slijedećoj slici 19.



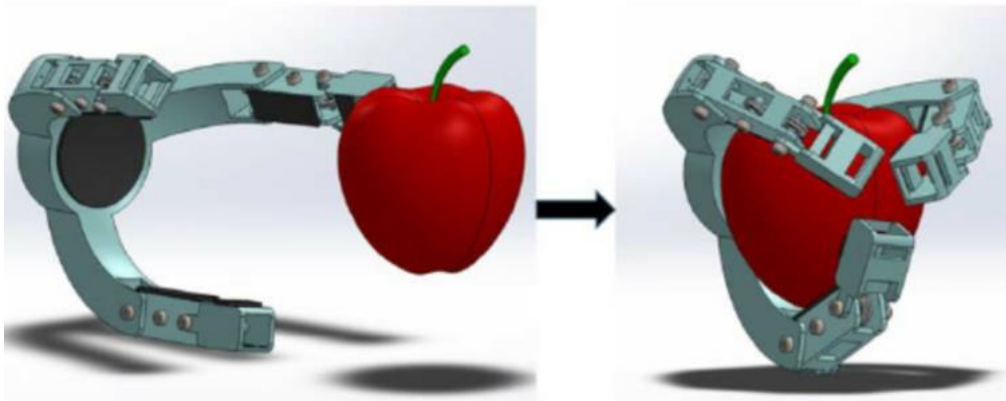
Slika 19. Dijelovi *HV-100* robota (<http://shvachko.net/wp-content/uploads/2013/11/HV-100.png>)

A - Laserski senzor dometa, B - Granični senzori, C - Hvatalka, D - Zastava (kada se povuče dolazi do zaustavljanja robota), E - Elektronička kutija s korisničkim sučeljem, F - Prednji valjak za ravnotežu (<https://www.roboticstomorrow.com/article/2013/07/case-study-harvest-automation-hv-100-robots-are-the-key-that-unlock-production-efficiencies/177/>).

Inženjeri s Australskog odjela za strojarstvo i svemirsko inženjerstvo Sveučilišta Monash usmjerili su svoju pozornost na jabuke. Njihov robot pod imenom robot *Harvester 3* koristi mješavinu kamera i algoritama za dubinsko učenje kako bi skenirao stabla voćnjaka i otkrio dijelove voća, što od njega zahtijeva da obrađuje informacije o njihovom obliku, orijentaciji i položaju zgloba stabljika grana kako bi sveo oštećenja proizvoda i okolnog lišća na minimum. „Robot hvata jabuke s posebno dizajniranim, mekanom hvataljkom s pneumatskim pogonom i četiri neovisno prsta te usisnim sustavom koji učinkovito hvata i vadi jabuke, dok minimizira oštećenja ploda i samog stabla“, objašnjava dr. Chao Chen, koji je vodio istraživanje. "Osim toga, usisni sustav izvlači jabuku iz krošnje u hvataljku, smanjujući potrebu hvataljke da uđe u krošnju i potencijalno oštećuje sve oko ploda. Hvatalka može izvući više od 85 posto svih jabuka iz krošnje koje su bile planirane za berbu.”

Robot može identificirati više od 90 posto jabuka unutar pogleda svoje kamere i udaljenosti od oko 1,2 m. Dr. Chao Chen navodi kako stroj može raditi u svim svjetlosnim i vremenskim uvjetima te mu je potrebno manje od 200 milisekundi za obradu slike jabuke.

Dr. Chao i njegov tim su ove godine provodili terenska ispitivanja svog robota za berbu jabuka i izvijestili su da je robot ošteti manje od 6 posto svojeg ubranog ploda ne namjernim uklanjanjem stabljika. Pokretanjem stroja na pola brzine vidjelo se da je identificiralo, ubralo i položilo jabuku svakih 12,6 sekundi, dok je pojednostavljenjem procesa odabira smanjeno na oko 9 sekundi. U konačnici, pokretanje robota punim kapacitetom skratilo je ovo vrijeme berbe na 7 sekundi po jabuci (Conceptual design, 2021.). Izgled hvataljke za vrijeme obavljanja berbe možemo vidjeti na slici 20.



Slika 20. Shematski prikaz hvatanja ploda (https://www.researchgate.net/figure/End-Effector-Grasping-an-Apple_fig4_288840721)

Izgled *Harvester 3* robota i njegovu hvataljku možemo vidjeti na slici 21.



Slika 21. *Harvester 3* robot u radu (<https://newatlas.com/robotics/apple-harvesting-robot-fresh-seven-seconds/>)

Prednosti kod upotrebe robota u poljoprivredi je ta da se koriste kako bi se poljoprivrednicima pomoglo i oslobodilo ih se fizičkih zahtjevnih i dugotrajnih poslova te im tako omogućili da s slobodnim vremenom preuzmu druge važne uloge. To uključuje korištenje strojnog učenja i njegovog algoritma i bespilotnih letjelica za nadgledanje farmi, donošenje ključnih odluka na temelju novih podataka, pa čak i za korak ispred budućih problema.

Nedostatak upotrebe robota u poljoprivredi je ta što je ova tehnologija još u razvoju te je skupa za sve poljoprivrednike. Stoga je većina robotike potrebno temeljito testirati, pa čak i reproducirati u velikom opsegu prije nego što postane pristupačna poljoprivrednicima u zemljama u razvoju i nerazvijenim zemljama. Osim toga, robotika je također prijetnja velikom broju radnika koji žive od poslova koje obavljaju na poljoprivrednim zemljištima. Ako robotika zamijeni ovu industriju, to može dovesti i do krize nezaposlenosti.

Cijela svrha robotike je olakšati fizičko opterećenje ljudskih bića kako bi nam omogućili korištenje naših intelektualnih sposobnosti i maksimiziranje naših sposobnosti. Roboti u poljoprivredi mogu postići upravo to na farmama, čime se omogućuje poljoprivrednicima da bolje rasporede svoj prostor i na kraju smanje krizu nestašice hrane za globalno stanovništvo (The guardian, 2021.).

4. PRIMJENA STROJNOG UČENJA U ZAŠTITI OKOLIŠA

Umjetna inteligencija je proizvod čovjeka i kao subjekt koji mu je podređen i ograničen njegovom voljom, ima velik potencijal da inteligentno pojednostavi svoj život, pa čak i pomogne u rješavanju problema koje je izuzetno teško ili nemoguće riješiti samo za nas. Strojno učenje nam može pomoći u suočavanju s ključnim prijetnjama okoliša s kojima se suočavamo u 21. stoljeću, a to su klimatske promjene i gubitak biološke raznolikosti.

Klimatske promjene imaju mnogo izvora, ali uvijek se svode na industrijske aktivnosti. Razne grane gospodarstva odgovorne su za emisije stakleničkih plinova, nažalost, procjena i predviđanje podataka nisu uvijek točne i mogu biti pogrešne. Prikupljanje podataka (npr. onečišćenju zraka) i predviđanje prijetnji na temelju njih mogu dobiti potpuno novo značenje ako u ovu vrstu prakse uključimo strojno učenje. Umjetna inteligencija koristi se takvim učenjem, između ostalog, IoT. Za objašnjenje IoT se odnosi na uređaje povezane na internet koji „međusobno komuniciraju“.

Podaci prikupljeni od senzora međusobno povezanih na ovaj način, mjereći osnovne onečišćujuće tvari u zraku kao što su, ugljični monoksid, sumporov dioksid i dušikov dioksid, kolektivno analizira strojno učenje, koji na njihovoj osnovi uči predvidjeti opasnosti i utvrditi ih. To je posebno važno na mjestima na kojima je teško procijeniti zagađenje i definirati njegove izvore. Strojno učenje također omogućuje predviđanje ekstremnih vremenskih pojava s velikom preciznošću (koje će s vremenom postati češće u uvjetima klimatskih promjena). Takvo rješenje na nacionalnoj razini provodi, na primjer, američka Nacionalna uprava za oceane i atmosferu. Također omogućuje optimizaciju potrošnje energije u zgradama, smanjujući na taj način povezane emisije. Umjetna inteligencija može pridonijeti stvaranju novih materijala s niskom emisijom, razvoju zelenijeg prometa i boljem praćenju krčenja šuma. Gubitak biološke raznolikosti i izumiranje vrsta također predstavlja svjetski problem. Krčenje šuma izravni je uzrok oduzimanja životnog prostora organizmima, ali nije jedini aspekt ljudske aktivnosti koji moramo uravnotežiti.

Ogromnu štetu prirodnim ekosustavima uzrokuje i pojačana poljoprivreda. Korištenjem umjetne inteligencije, strojnog učenja i IoT-a za održivost poljoprivredne proizvodnje uključuje praćenje usjeva i stanja tla, kao i zahvaljujući prikupljenim i analiziranim podacima, omogućujući maksimiziranje ratarske proizvodnje s najmanjim mogućim utjecajem na okoliš. Inteligentni uređaji za nadzor i senzori mogu se povezati s biljkama kako bi u stvarnom vremenu neprestano nadzirali parametre poput hidratacije, prehrane biljaka i bolesti. To

zauzvrat može smanjiti potrebu za pesticidima koji imaju štetan utjecaj na okoliš. Takva se rješenja već uspješno koriste.

Umjetna inteligencija može ne samo smanjiti negativni utjecaj ljudskih aktivnosti na prirodu, već i pratiti učinke zaštite vrsta. Strojno učenje i umjetna inteligencija se koriste, npr., za provođenje neinvazivnog proučavanja obrazaca ponašanja životinja, kao što su migracija, parenje i prehrambene navike. Zanimljiv alat za prikupljanje podataka o ugroženim životinjskim vrstama je, npr., Tehnika identifikacije otiska (*FIT*). Riječ je o softveru koji je kreirala tvrtka *WildTrack*, a koji prikuplja podatke o otiscima stopala na životinjama na razini pojedinca, dobi i spola bez ikakvih smetnji povezanih s hvatanjem i obilježavanjem životinja (Erocreator, 2020.).

5. ZAKLJUČAK

Ovakva vrsta tehnologije je stvorena za unapređenje poljoprivredne proizvodnje. Ona mijenja način na koji ljudi upravljaju strojevima, štedi vrijeme i gorivo, smanjuje umor poljoprivrednika i donosi brojne uštede. Kako bi se prehranila ova svjetska rastuća populacija te očuvao se okoliš morat ćemo prihvatiti „pametniji“ način poljoprivredne proizvodnje, koristeći suvremenu poljoprivrednu tehnologiju. Umjetna inteligencija u poljoprivredi ne samo da pomaže poljoprivrednicima u automatizaciji poljoprivrede, nego i radi većeg prinosa usjeva i bolje kvalitete uz manje korištenje resursa. Tvrtke uključene u razvijanje i poboljšanje strojnog učenja u ovom sektoru u budućnosti će dobiti tehnološki napredak, pružat će sve više korisnih aplikacija i tehnologije u rješavanju velikog svjetskog problema, a to je povećanje proizvodnje hrane kako bi ona bila dostupna i u dijelovima gdje je nema dovoljno ni za osnovni život. Tradicionalni poljoprivredni sustavi više se ne mogu osloniti uz sve veću globalnu potražnju za hranom. Postoji stalna potreba za razvojem poboljšanih tehnologija i tehnika bez nužnoga povećanja cijena ili pogoršanja prirodnih resursa i okoliša. Umjetna inteligencija ima vitalnu ulogu u budućnosti čovječanstva. To uključuje i poljoprivrednu industriju. Potencijal strojnog učenja i stalno poboljšavanje umjetne inteligencije znači da je gornja granica rasta u poljoprivrednom sektoru ogromna. Pametna implementacija umjetne inteligencije u poljoprivredu pomogla bi osigurati održivost industrije u budućnosti.

6. POPIS LITERATURE

1. Wipro. Towards Future Farming: How Artificial Intelligence is transforming the Agriculture industry 12.8.2019. <https://www.wipro.com/holmes/towards-future-farming-how-artificial-intelligence-is-transforming-the-agriculture-industry/> 22.5.2021.
2. Sharma, A., Jain, A., Gupta, P., Chowdary, V. (2020): Machine learning applications for precision agriculture: A comprehensive review. IEEE Access. <https://ieeexplore.ieee.org/abstract/document/9311735>.
3. Shafi, U., Mumtaz, R., Iqbal, N., Zaidi, S. M. H., Zaidi, S. A. R., Hussain, I., Mahmood, Z. (2020): A Multi-Modal Approach for Crop Health Mapping Using Low Altitude Remote Sensing, Internet of Things (IoT) and Machine Learning. IEEE Access, 8, 112708-112724. <https://ieeexplore.ieee.org/abstract/document/9119071>.
4. Singh, V., Misra, A. K. (2017): Detection of plant leaf diseases using image segmentation and soft computing techniques. Information processing in Agriculture, 4(1), 41-49. <https://www.sciencedirect.com/science/article/pii/S2214317316300154>.
5. Pcchip. Strojno učenje vs duboko učenje 29.7.2022. <https://pcchip.hr/ostalo/tech/strojno-ucenje-vs-duboko-ucenje/> 22.5.2021.
6. M. De Marco (2018.): Primjena metoda strojnog učenja u proizvodnim sustavima, Diplomski rad, Sveučilište u Zagrebu. http://repositorij.fsb.hr/8941/3/De_Marco_2018_diplomski.pdf 22.5.2021.
7. Čorić (2017.): Metode strojnog učenja u predviđanju profitabilnosti kupaca, Doktoratski rad, Sveučilište u Mostaru. <https://repositorij.efst.unist.hr/islandora/object/efst%3A1783/datastream/PDF/view> 25.5.2021.
8. Tutorials point. Machine learning, tutorials point, Simply easy learning 2.7.2019. https://www.tutorialspoint.com/machine_learning/machine_learning_tutorial.pdf 25.5.2021
9. Neuronske mreže predavanje 15.2.2018. <https://eris.foi.hr/11neuronske/nn-predavanje1.html> 27.5.2021.
10. Klobučar, D., Pernar, R. (2009). Umjetne neuronske mreže u procjeni sastojinskih obrasta s cikličkih snimaka. Šumarski list, 133(3-4), 145-155.
11. Sainte-anastasié. Hebbov zakon je neuropsihološka osnova učenja 28.8.2017. <https://hr.sainte-anastasié.org/articles/neurociencias/ley-de-hebb-la-base-neuropsicolgica-del-aprendizaje.html> 27.5.2021.

12. Lončarić, S. Neuronske mreže: Proces učenja, Fakultet elektrotehnike i računarstva 3.5.2019. https://www.fer.unizg.hr/_download/repository/02-ProcesUcenja.pdf 27.5.2021.
13. Skladištenje. Stabla odlučivanja 2.22018. <http://www.skladistenje.com/stabla-odlucivanja/> 27.5.2021.
14. Biomedcentral. Comparing different supervised machine learning algorithms for disease prediction 25.2.2019. <https://bmcmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-019-1004-8> 27.5.2021.
15. Banjanović-Mehmedović, L. Izabrana poglavlja inteligentnih sistema: Metode klasifikacije 26.3.2013. http://lejla-bm.com.ba/IPIS/IPIS_2_Metode_klasifikacije.pdf 27.5.2021.
16. Jagtap, S. B., Hambarde, M. S. M. (2014): Agricultural plant leaf disease detection and diagnosis using image processing based on morphological feature extraction. IOSR J Sig Proc, 4(5), 24-30. <https://www.iosrjournals.org/iosr-jvlsi/papers/vol4-issue5/Version-1/E04512430.pdf>.
17. Ayswarya, R., Balaji, B., Balaji, R., Arun, S., Ramya, R. (2017): Weed detection in agriculture using image processing. International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, 6(3), 1698-1703. <https://www.sciencedirect.com/science/article/abs/pii/S0168169915003981>.
18. CropDeep. The Crop Vision Dataset for Deep-Learning-Based Classification and Detection in Precision Agriculture 22.6.2019. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6427818/> 10.6.2021.
19. Artificial Neural Networks. Types and Applications 5.3.2017. <https://www.techslang.com/artificial-neural-networks-types-and-applications/> 10.6.2021.
20. Rsip vision. Agricultural yield prediction using Deep Learning 5.5.2020. <https://rsipvision.com/agricultural-yield-prediction-using-deep-learning/> 10.6.2021.
21. Jagtap, S. B., Hambarde, M. S. M. (2014): Agricultural plant leaf disease detection and diagnosis using image processing based on morphological feature extraction. IOSR J VLSI Sig Proc, 4(5), 24-30. <https://arxiv.org/ftp/arxiv/papers/2106/2106.10698.pdf>.
22. Liakos, K. G., Busato, P., Moshou, D., Pearson, S., Bochtis, D. (2018): Machine learning in agriculture: A review. Sensors, 18(8), 2674. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6111295/>.

23. Ecoreactor. Artificial intelligence in environmental protection 23.2.2020.
<https://ecoreactor.org/en/artificia-intelligence-environmental-protection/> 11.6.2021.
24. Mind tree. Artificial Intelligence in Agriculture 1.6.2020.
<https://www.mindtree.com/insights/resources/artificial-intelligence-agriculture>
11.6.2021.
25. Dione project. 5G network is coming to Agriculture 6.1.2021. <https://dione-project.eu/5g-network-is-coming-to-agriculture/> 13.6.2021.
26. Farming paradise. The Impact of 5G on the Future of Farming 2.4.2021.
<https://farmingparadise.com/5g-future-farming/> 13.6.2021.
27. Pinduoduo global. Agricultural Robots: Robots in Agriculture and Farming 6.8.2020.
<https://stories.pinduoduo-global.com/agritech-hub/robots-in-agriculture-and-farming>
14.6.2021.
28. Newatlas. Volocopter builds a giant crop-spraying drone for John Deere 25.2.2021.
<https://newatlas.com/aircraft/volocopter-crop-spraying-drone-john-deere/> 15.6.2021.
29. Volocopter. VOLODRONE The heavy-lift drone 5.8.2020.
<https://www.volocopter.com/solutions/volodrone/> 15.6.2021.
30. Newatlas. Volocopter builds a giant crop-spraying drone for John Deere 5.5.2020.
<https://newatlas.com/aircraft/volocopter-crop-spraying-drone-john-deere/> 15.6.2021.
31. Food ingredients first. Automated harvesting: “Vegebot” designed to streamline farming and cut labor costs 25.2020.
<https://www.foodingredientsfirst.com/news/automated-harvesting-vegebot-designed-to-streamline-farming-and-cut-labor-costs.html> 15.6.2021.
32. Growing produce. Get in Gear Now for Agriculture’s Robotic Revolution 2.5.2021.
<https://www.growingproduce.com/fruits/get-in-gear-now-for-agricultures-robotic-revolution/> 17.6.2021.
33. The guardian. Robocrop: world's first raspberry-picking robot set to work 13.5.2020.
<https://www.theguardian.com/technology/2019/may/26/world-first-fruit-picking-robot-set-to-work-artificial-intelligence-farming> 17.6.2021.
34. Robotics tomorrow. Case study: Harvest Automation HV-100 Robots Are The Key That Unlock Production Efficiencies 1.2.2021.
<https://www.roboticstomorrow.com/article/2013/07/case-study-harvest-automation-hv-100-robots-are-the-key-that-unlock-production-efficiencies/177/> 18.7.2021.
35. Davidson, J. R., Mo, C: (2014). Conceptual Design of an End-Effector for an Apple Harvesting Robot. In Conference on Automation Technology for Off-Road Equipment

(ATOE), Beijing, China. https://www.researchgate.net/figure/End-Effector-Grasping-an-Apple_fig4_288840721 18.7.2021.

36. Newatlas. Apple harvesting robot plucks a piece of fruit every 7 seconds 2.6.2020. <https://newatlas.com/robotics/apple-harvesting-robot-fresh-seven-seconds/> 18.7.2021.

7. SAŽETAK

U radu su prikazane metode te načini strojnog i dubokog strojnog učenja i njegova implementacija u poljoprivredi i zaštiti okoliša. U prvom dijelu rada opisano je kako strojno učenje može biti nadzirano ili nenadzirano. Također se opisuju neuronske mreže koje su mozak algoritama dubokog strojnog učenja. U drugom dijelu rada opisana je primjena strojnog učenja u poljoprivredi te kako ona utječe na očuvanje okoliša. Govori se kako bez 5G integracije precizna poljoprivreda zapravo ne bi ni postojala. Opisane su suvremene kamere koje otkrivaju bolesti i korove. Navedeni su bespilotni zrakoplovi koji imaju ulogu snimanja i tretiranja zemljišta iz zraka pa čak i za prijevoz tereta. Spomenuta je tehnologija i roboti koji se koriste u razvijenijim dijelovima svijeta. Navedeni roboti još su u fazi razvijanja i na dobrom su putu za probijanje na svjetsko tržište poljoprivredne suvremene tehnologije.

Ključne riječi: neuron, algoritam, strojno učenje, robot, senzor, GPS, precizna poljoprivreda

8. SUMMARY

The paper presents the methods and ways of machine and deep machine learning and its implementation in agriculture and environmental protection. The first part of the paper describes how machine learning can be supervised or unsupervised. Neural networks that are the brain of deep machine learning algorithms are also described. The second part of the paper describes the application of machine learning in agriculture as it affects the preservation of the environment. It is said that without 5G integration, precision agriculture would not even exist. Modern cameras that detect diseases and weeds are described. Drones are listed that have the role of filming and treating land from the air and even for transporting cargo. Technology and robots used in more developed parts of the world are mentioned. These robots are still in the development phase and on a good way to break into the world market of modern agricultural technologies.

Keywords: neuron, algorithm, machine learning, robot, sensor, GPS, precision agriculture

9. POPIS SLIKA

Slika 1. Klasificiranje nepoznatog objekta pomoću kNN metode	5
Slika 2. Granice za svaku vrstu objekta	6
Slika 3. Nepoznata točka u klasi plavih predmeta	6
Slika 4. prikazuje dijagram raspodjele podatkovnih točaka u XY ravni.....	8
Slika 5. Primjer nelinearne granične krivulje.....	9
Slika 6. Granica utvrđena strojnim učenjem bez nadzora	10
Slika 7. Umjetna neuronska mreža.....	13
Slika 8. Komponente biološkog i umjetnog neurona	14
Slika 9. Umjetni neuron	14
Slika 10. Struktura biološkog neurona	17
Slika 11. Dijagnosticiranje simptoma na listu.....	19
Slika 12. Različiti efekti koji upućuju na određenu bolest lišća	19
Slika 13. Detekcija korova u programu.....	20
Slika 14. Tretiranje zemljišta pomoću drona	22
Slika 15. VoloDrone za prijevoz manjeg tereta	24
Slika 16. <i>Vegebot</i> u radu	26
Slika 17. <i>Berry 5</i> robot u radu	27
Slika 18. Jednak razmak između sadnica	29
Slika 19. Dijelovi <i>HV-100</i> robota.....	30
Slika 20. Shematski prikaz hvatanja ploda.....	31
Slika 21. <i>Harvester 3</i> robot u radu	32

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku

Diplomski rad

Fakultet agrobiotehničkih znanosti Osijek

Sveučilišni diplomski studij, Mehanizacija

Primjena algoritma strojnog i dubokog strojnog učenja u poljoprivredi i zaštiti okoliša

Josip Bilić

Sažetak:

U radu su prikazane metode te načini strojnog i dubokog strojnog učenja i njegova implementacija u poljoprivredi i zaštiti okoliša. U prvom dijelu rada opisano je kako strojno učenje može biti nadzirano ili nenadzirano. Također se opisuju neuronske mreže koje su mozak algoritama dubokog strojnog učenja. U drugom dijelu rada opisana je primjena strojnog učenja u poljoprivredi te kako ona utječe na očuvanje okoliša. Govori se kako bez 5G integracije precizna poljoprivreda zapravo ne bi ni postojala. Opisane su suvremene kamere koje otkrivaju bolesti i korove. Navedeni su bespilotni zrakoplovi koji imaju ulogu snimanja i tretiranja zemljišta iz zraka pa čak i za prijevoz tereta. Spomenuta je tehnologija i roboti koji se koriste u razvijenijim dijelovima svijeta. Navedeni roboti još su u fazi razvijanja i na dobrom su putu za probijanje na svjetsko tržište poljoprivredne suvremene tehnologije.

Rad je izrađen pri: Fakultet agrobiotehničkih znanosti Osijek

Mentor: prof. dr. sc. Mladen Jurišić

Broj stranica: 44

Broj grafikona i slika: 21

Broj tablica: 0

Broj literaturnih navoda: 36

Broj priloga: 0

Jezik izvornika: hrvatski

Ključne riječi: neuron, algoritam, strojno učenje, robot, senzor, GPS, precizna poljoprivreda

Datum obrane: 23.9.2021.

Stručno povjerenstvo za obranu:

1. izv. prof. dr. sc. Ivan Plaščak, predsjednik
2. prof. dr. sc. Mladen Jurišić, mentor
3. Dorijan Radočaj, mag. ing. geod. et geoinf., član

Rad je pohranjen u: Knjižnica Fakulteta agrobiotehničkih znanosti Osijek, Sveučilišta Josipa Jurja Strossmayera u Osijeku, Vladimira Preloga 1

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek

Graduate thesis

Faculty of agrobiotechnical sciences Osijek

University Graduate Studies, Mechanization, course Mechanization

Application of machine and deep machine learning algorithm in agriculture and environmental protection

Josip Bilić

Abstract:

The paper presents the methods and ways of machine and deep machine learning and its implementation in agriculture and environmental protection. The first part of the paper describes how machine learning can be supervised or unsupervised. Neural networks that are the brain of deep machine learning algorithms are also described. The second part of the paper describes the application of machine learning in agriculture as it affects the preservation of the environment. It is said that without 5G integration, precision agriculture would not even exist. Modern cameras that detect diseases and weeds are described. Drones are listed that have the role of filming and treating land from the air and even for transporting cargo. Technology and robots used in more developed parts of the world are mentioned. These robots are still in the development phase and on a good way to break into the world market of modern agricultural technologies.

Thesis performed at: Faculty of agrobiotechnical sciences Osijek

Mentor: Prof. Dr. Mladen Jurišić

Number of pages: 44

Number of figures: 21

Number of tables: 0

Number of references: 36

Number of appendices: 0

Original in: Croatian

Keywords: neuron, algorithm, machine learning, robot, sensor, GPS, precision agriculture

Thesis defended on date: 23.9.2021.

Reviewers:

1. Assoc. Prof. Ivan Plaščak, chairman
2. Prof. Dr. Mladen Jurišić, mentor
3. MSc Dorijan Radočaj, member

Thesis deposited at: Library Faculty of Agrobiotechnical Sciences Osijek, Josip Juraj Strossmayer University of Osijek, Vladimira Preloga 1