



Projekat finansirali:



EU4Agri

Finansirano
Evropska unija



CZECH
AID

PAMETNI SISTEMI U POLJOPRIVREDI

ODGOVOR IZAZOVIMA 21. STOLJEĆA

PAMETNI SISTEMI U POLJOPRIVREDI – ODGOVOR IZAZOVIMA 21. STOLJEĆA

Izdavač: Univerzitet u Sarajevu - Poljoprivredno-prehrambeni fakultet

Autori: Hamdija Čivić
Sabrija Čadro
Mirha Đikić
Jasmin Grahić
Nermin Rakita
Teofil Gavrić
Alen Mujčinović
Osman Musić
Emina Sijahović
Arnela Okić
Zuhdija Omerović

Urednik: Hamdija Čivić

Recenzenti: Prof. dr. Zoran Jovović, redovni profesor, Biotehnički fakultet, Univerzitet Crne Gore
Prof. dr. Mihajlo Marković, redovni profesor, Poljoprivredni fakultet, Univerzitet u Banjoj Luci
Prof. dr. sc. Boris Lazarević, izvanredni profesor, Agronomski fakultet, Sveučilište u Zagrebu
Prof. dr. Selim Škaljić, redovni profesor u penziji, Poljoprivredno-prehrambeni fakultet,
Univerzitet u Sarajevu
Dr. sci. Martina Peršić, viši predavač, Veleučilište u Rijeci
Prof. dr. Emelj Tuna, redovni profesor, Fakultet poljoprivrednih nauka i prehrane Univerziteta
Sv. Ćirilo i Metodije, Skoplje
Prof. dr. Osman Mujezinović, redovni profesor, Šumarski fakultet, Univerzitet u Sarajevu

DTP: Mr. Sead Muhić, dipl. ing.

Štampa: OR PRINT STUDIO "Student Line"

Tiraž: 60

ISBN 978-9958-597-90-9

CIP zapis dostupan u COBISS sistemu Nacionalne i univerzitetske biblioteke BiH pod

ID brojem 67074566

PAMETNI SISTEMI U POLJOPRIVREDI – ODGOVOR IZAZOVIMA 21. STOLJEĆA

Sarajevo, 2025.

PREDGOVOR

Poljoprivredno-prehrambeni sektor suočava se sa brojnim dinamičnim promjenama i složenim izazovima - od klimatskih promjena, degradacije zemljišta i nedostatka prirodnih resursa, do potrebe za povećanjem produktivnosti i osiguranjem održivosti proizvodnih sistema, te osiguranje proizvodnje dovoljnih količina zdravstveno ispravne hrane. U takvom okruženju, razvoj i primjena pametnih sistema u poljoprivredi postaju ne samo poželjni, nego i nužni. Digitalizacija, precizna poljoprivreda i održivi modeli proizvodnje danas predstavljaju ključne alate kojima se gradi otpornija i konkurentnija poljoprivreda.

Knjiga „PAMETNI SISTEMI U POLJOPRIVREDI – ODGOVOR IZAZOVIMA 21. STOLJEĆA“ nastala je kao odgovor na gore navedene izazove i potrebe, te kao rezultat aktivnosti u okviru projekta EU4Agri. Ovaj projekat je usmjeren na jačanje poljoprivredne prakse u Bosni i Hercegovini kroz povezivanje proizvođača s naučnim i istraživačkim institucijama. Na ovaj način stvorena je čvrsta osnova za prenos znanja, implementaciju inovacija i unapređenje konkurentnosti poljoprivrede u našoj zemlji.

Sadržaj knjige strukturiran je u osam poglavlja, koja pokrivaju širok spektar tema od fundamentalne važnosti za savremenu poljoprivredu: od uloge digitalnih tehnologija i održivih strategija gnojidbe, preko pametnih sistema navodnjavanja i zaštite bilja, primjene inovativnih rješenja u voćarstvu, ratarstvu i poljoprivrednoj mehanizaciji, do koristi koje savremene tehnologije donose agrobiznisu i ruralnom razvoju u cjelini.

U knjizi je predstavljeno 20 tabela, 2 grafikona i 97 slika, uz bogat izbor relevantne literature, čime je osigurana kvalitetna naučno-stručna podloga. Djelo je namijenjeno studentima, istraživačima, stručnjacima i praktičarima u poljoprivredi, ali i donosiocima odluka, te svima koji žele bolje razumjeti značaj i mogućnosti primjene pametnih sistema u biljnoj proizvodnji uključujući i njihov širi agroekonomski kontekst.

Vjerujemo da će ova knjiga doprinijeti razvoju znanja, širenju inovacija i stvaranju novih perspektiva u poljoprivredi Bosne i Hercegovine, te poslužiti kao vodič i inspiracija za održive prakse koje odgovaraju izazovima 21. stoljeća. Također, smatramo da ona predstavlja sintezu naučno-istraživačkih dostignuća, aktuelnih trendova i praktičnih iskustava, nudeći smjernice za unapređenje poljoprivredne prakse u Bosni i Hercegovini.

Na kraju, želimo izraziti zahvalnost **uredu Razvojnog programa Ujedinjenih nacija u BiH (UNDP) i Češkoj razvojnoj agenciji (CzDA) koji su kroz projekt EU4Agri omogućili finansijsku podršku** u realizaciji ove publikacije.

SADRŽAJ

UVOD	9
Digitalizacija poljoprivrede	9
Digitalna poljoprivreda	10
Uloga digitalne poljoprivrede u održivom razvoju	10
SAVREMENE TEHNOLOGIJE KAO OSNOVA DIGITALNE POLJOPRIVREDE	13
Senzorski sistemi i senzorske mreže	13
Daljinsko istraživanje (remote sensing)	14
IoT (Internet of Things)	17
Automatizacija, robotika i AI	19
Robotika i AI	20
SAVREMENI SISTEMI U ISHRANI BILJAKA, ODRŽIVE STRATEGIJE	
GNOJIDBE, GNOJIVA I GNOJIDBA	27
Savremeni sistemi u ishrani biljaka i održive strategije gnojidbe	27
Fertirigacija	39
Vrste (metode) fertirigacije	41
Gnojiva i gnojidba	45
Kompatibilnost	47
Kiselost ili pH otopine rastvora gnojiva	47
Električna provodljivost (EC) i osmotski pritisak hranljive otopine	48
Kvalitet vode za navodnjavanje	51
Normiranje vode i gnojiva, zalivne norme	52
Normiranje hraniva-gnojiva za prihranu	55
Gnojidba jabuke	56
PAMETNI SISTEMI NAVODNJEVANJA BILJAKA U BILJNOJ PROIZVODNJI	61
Vodni bilans tla	62
Održiva poljoprivreda i tehnološki napredak	68
Pametno navodnjavanje	71
Upravljanje pametnim sistemom za navodnjavanje	76
Korištenje različitih senzora u pametnom navodnjavanju	81
Način postavljanja senzora za vlagu tla	88
Senzori za kišu	90
Bespilotne letjelice – dronovi i daljinsko istraživanje	91
Bespilotne letjelice – dronovi	94
SAVREMENI PRISTUPI U ZAŠTITI BILJAKA	103
PRIMJENA PAMETNIH SISTEMA U VOĆARTVU	111
Procjena početka kretanja vegetacije	113
Posmatranje fenofaza razvoja vegetativnih i generativnih organa	116
Određivanje optimalnog opterećenja voćaka	120
Primjer sistema podrške proizvođačima u procesu prorjeđivanja plodova jabuke	122

Procjena prinosa upotrebom vještačke inteligencije	127
Procjena prinosa ML tehnikom	127
Procjena prinosa DL tehnikom	128
Pametna procjene prinosa voćaka	130
Praćenje rasta ploda	134
PRIMJENA PAMETNIH SISTEMA U RATARSTVU	143
Sistemi za mjerenje otpora vuče	144
Priprema tla u sistemu precizne poljoprivrede	144
Alati za određivanje optimalnih rokova sjetve	147
Primjena sistema precizne poljoprivrede u sjetvi	148
Bespilotne letjelice ili dronovi	149
Biorazgradivi malč	149
Senzorsko mjerenje osobina usjeva	151
SAT TS-Monitorng	151
Zaoravanje žetvenih ostataka	151
Optimiziranje plodoreda povećava ugljik u tlu i smanjuje emisije stakleničkih plinova bez žrtvovanja prinosa	152
Autonomni roboti u suzbijanju korova	152
Brza procjena parametara kvaliteta žita	155
Korištenje umjetne inteligencije u određivanju kvalitete sjemena	157
Solarne sušnice	157
NAPREDNE TEHNIKE POLJOPRIVREDNE MEHANIZACIJE ZA ODRŽIVE SISTEME BILJNE PROIZVODNJE	163
Tehnike precizne poljoprivrede	164
Primjena GPS i GIS tehnologija	164
Navođenje traktora GPS-om	164
Korištenje senzora za monitoring usjeva	166
Tipovi i princip rada senzora	167
Pametni senzori za ispitivanje svojstava tla	168
Automatizacija u oranju, sjetvi, gnojidbi i navodnjavanju	169
Oranje	169
Sjetva	170
Gnojidba	171
Automatsko navodnjavanje	172
Mehanizacija u pametnoj zaštiti bilja	172
Autonomni sistemi i robotika	174
Internet stvari i umjetna inteligencija	174
Održiva i energetski efikasna mehanizacija	175
KORISTI OD PRIMJENE SAVREMENIH TEHNOLOGIJA U AGROBIZNISU	177
Uloga poljoprivredno-prehrambenog lanca snabdijevanja	178
Prednosti i izazovi primjene digitalnih tehnologija u poljoprivredi	184

UVOD

Jasmin Grahić

Digitalizacija poljoprivrede

Poljoprivreda je, još od svog početka, predstavljala evolutivni proces u kojem su ljudi postepeno usvajali različite pristupe u biljnoj proizvodnji i uzgoju životinja. Napuštanje nomadskog načina života, još prije 12.000 godina, kada je neolitski čovjek prepoznao važnost kultiviranja biljaka i pripitomljavanja životinja (neolitska revolucija), predstavlja začetak poljoprivrede. Kroz historiju, kreirano je i usvajano mnogo organizovanih i sistematičnih načina za povećanje poljoprivrednih prinosa, što je bilo ključno za zadovoljenje prehrambenih potreba rastuće ljudske populacije. Transformacije poljoprivrednih sistema, od tradicionalnih metoda do savremenih rješenja, mogu se pratiti kroz pet razvojnih faza poznatih kao Poljoprivreda 1.0 do Poljoprivreda 5.0 (Zambon *et al.*, 2019; Liu *et al.*, 2020a; Liu *et al.*, 2020b; Ragazou *et al.*, 2022; Baryshnikova *et al.*, 2022):

- Poljoprivreda 1.0 - Poljoprivreda 1.0 se oslanjala na tradicionalne metode uzgoja uz korištenje jednostavnih alata. Ovu fazu karakteriše proizvodnja koja je bila lokalna, mala, koja je zahtijevala značajnu količinu radne snage, pri čemu su korištene i radne životinje (poput konja i volova). Zbog tehnoloških ograničenja, prinosi su bili skromni, a poljoprivreda je bila fokusirana na zadovoljenje osnovnih prehrambenih potreba zajednice;
- Poljoprivreda 2.0 - Poljoprivreda 2.0 predstavlja period u kojem su farmeri prepoznali prednosti Industrijske revolucije (Industrija 1.0 od 1780-ih do 1870-ih) i počeli koristiti mašine u poljoprivredi, što je omogućilo povećanje poljoprivredne produktivnosti uz smanjen intenzitet ljudskog rada. Ovo razdoblje je poznato i kao era industrijske poljoprivrede;
- Poljoprivreda 3.0 - Poljoprivreda 3.0 predstavlja korištenje tehnoloških dostignuća i inovacija proizašlih iz Industrije 2.0 i Industrije 3.0. Inovacije iz Industrije 2.0, poput elektrifikacije i automatizacije (montažne linije), zajedno sa motorima sa unutrašnjim sagorijevanjem, omogućile su i razvoj povezanih tržišta, kao i efikasniji transport poljoprivrednih proizvoda na velike udaljenosti. Sa napretkom u elektronici, računarstvu i informacijskim tehnologijama (napredni softverski modeli, dostupnost globalnog navigacionog sistema, nove tehnologije upravljanja podacima, najsavremenije bežične komunikacijske tehnologije), uz korištenje obnovljivih izvora energije (hidroenergija, energija vjetera, fotonaponska energija), povećani su proizvodni kapaciteti poljoprivrednih sistema. Dakle, svim pomenutim su stvoreni uslovi da se mali poljoprivredni sistemi zamijene velikim, te da se introdukira precizna poljoprivreda;
- Poljoprivreda 4.0 - Poljoprivreda 4.0 je era pametne poljoprivrede koja se oslanja na informatičke i komunikacijske tehnologije (IKT) nastale tokom Industrijske revolucije 4.0, poput jeftinih senzora i mikoprosesora, žičanih/bežičnih komunikacijskih i mrežnih sistema velike brzine, mogućnosti skladištenja podataka u oblaku (*cloud storage*), mogućnosti analize velikih skupova podataka (*BigData analytics*), obrade slika, umjetne inteligencije (AI), dronova i satelita. Ove tehnologije pomažu u prikupljanju, prijenosu, skladištenju i automatizovanoj analizi podataka povezanih sa poljoprivredom;
- Poljoprivreda 5.0 - Poljoprivreda 5.0 (Digitalna poljoprivreda) ima za cilj primjenu informatičkih i komunikacijskih tehnologija (IKT) uvedenih u Poljoprivredi 4.0 na način koji smanjuje negativne utjecaje poljoprivrede na okoliš, rješavajući uz to i socijalne i političke

probleme u poljoprivrednim sistemima. Ovdje se posebno ističe kombinovanje zelenih, obnovljivih izvora energije sa IKT tehnologijama, pri čemu se pomjera fokus sa visoke produktivnosti poljoprivrednih sistema na ekološku i društvenu dobrobit.

Digitalna poljoprivreda

Koncept digitalne poljoprivrede temelji se na razvoju automatizovanih, integriranih poljoprivrednih sistema, koji se bave prikupljanjem, prijenosom i obradom podataka, kao i digitalizacijom kontrole poljoprivredne mehanizacije kroz informatičke, komunikacijske i mrežne tehnologije sa ciljem praćenja svih poljoprivrednih aktivnosti (Tang *et al.*, 2002). Pored samog sakupljanja podataka, digitalna poljoprivreda u fokus stavlja i korištenje novih, savremenih alata za stvaranje dodane vrijednosti iz dostupnih informacija.

Dakle, digitalizacija poljoprivrede predstavlja sveobuhvatan proces transformacije tradicionalnih poljoprivrednih praksi kroz integraciju modernih tehnologija i informacijsko-komunikacijskih sistema. Ovaj koncept obuhvata korištenje digitalnih alata za prikupljanje, analizu i distribuciju podataka, čime se poljoprivrednicima omogućava donošenje informisanih odluka koje povećavaju efikasnost, produktivnost i održivost poljoprivrednih proizvodnih sistema.

Uloga digitalne poljoprivrede u održivom razvoju

Digitalna poljoprivreda automatizuje sve aspekte i faze poljoprivredne proizvodnje, uključujući samo planiranje proizvodnje, odabir sortimenta ili pasmina, pripremu zemljišta i/ili objekata, sadnju i uzgoj, kao i kontinuirano praćenje cjelokupnog digitalnog agro-ekosistema. Radi boljeg razumijevanje samog pojma digitalni agro-ekosistem, nužno je definirati određene pojmove, odnosno napraviti jasno distinkciju između ekosistema, poljoprivrednog ekosistema (agro-ekosistema), digitalnog ekosistema i digitalnog agro-ekosistema:

- ekosistem - Ekosistem je kompleksan sistem unutar specifičnog okruženja u kojem se odvijaju interakcije između živih organizama (kao što su biljke, životinje i mikrobi) i nežive prirode (poput klime, tla, vode i pejzaža). U jednom takvom sistemu svi organizmi međusobno zavise i doprinose očuvanju života;
- agro-ekosistem - Poljoprivredni ekosistem predstavlja vještački ekosistem koji je kreiran, kojim upravlja i koji kontroliše čovjek (Guidotti, 2015). Ovaj ekosistem je konstruisan tako da bude podrška poljoprivrednim aktivnostima. Dakle, čovjek igra ključnu ulogu u oblikovanju i održavanju ovih ekosistema, pri čemu je primarni cilj optimizacija proizvodnih uslova, odnosno optimizacija procesa proizvodnje hrane i drugih poljoprivrednih proizvoda;
- digitalni ekosistem - Prema definiciji, digitalni ekosistem je adaptivni, skalabilni i održivi sistem koji se sastoji od međusobno povezanih digitalnih resursa, stvarajući jedinstveno informatičko okruženje koje podstiče interakciju među članovima, čak i kada ne postoje čvrste funkcionalne veze između njih (Barykin *et al.*, 2020). Drugim riječima, digitalni ekosistem obuhvata mrežu sistema i relevantnih aktera koji koriste digitalne tehnologije za međusobnu interakciju u cilju ostvarivanja zajedničkih ekonomskih prilika;
- digitalni agro-ekosistem - Digitalni poljoprivredni ekosistem je adaptivan, skalabilan i održiv sistem koji se sastoji od međusobno povezanih digitalnih resursa. Ovaj ekosistem pruža informatičko okruženje koje pomaže u automatizaciji poljoprivrednih operacija i

podstiče interakciju među akterima u poljoprivredi, čak i kada ne postoje čvrste saradničke ili funkcionalne veze između njih (Kuldeep Singh, 2024). Glavni cilj digitalnog poljoprivrednog ekosistema je povećanje obima i kvalitete poljoprivredne proizvodnje kroz usvajanje digitalnih tehnologija na održiv način. Dakle, uz smanjenje troškova rada i povećanje prihoda, digitalni poljoprivredni ekosistemi osnažuju farmere i poljoprivredne zajednice da donose efikasne odluke koje vode ka unapređenju količine i kvaliteta njihovih poljoprivrednih proizvoda. Četiri su glavne komponente digitalnog poljoprivrednog ekosistema: akteri u poljoprivredi (proizvođači, savjetodavci, distributeri, trgovci itd.), poljoprivredna mehanizacija, poljoprivredne operacije i digitalne tehnologije.

Za optimizaciju produktivnosti i upravljanja svim proizvodnim procesima, podaci, odnosno informacije predstavljaju ključni faktor digitalne poljoprivrede, jer svi akteri u poljoprivrednoj industriji zahtijevaju potpune, tačne i pravovremene informacije za donošenje optimizovanih odluka. Te informacije trebaju biti lako dostupne, pristupačne i dobro zaštićene, njihovo korištenje isplativo, i prilagođene specifičnim potrebama korisnika (Mahant *et al.*, 2012). U suštini, digitalna poljoprivreda pruža rješenja za povećanje proizvodnje poljoprivrednih proizvoda tako što poljoprivredne prakse čini kontrolisanim, preciznijim i tačnijim, koristeći napredne IKT tehnologije koje pomažu u smanjenju troškova proizvodnje i negativnog utjecaja na okoliš.

Poljoprivreda 21. stoljeća se suočava sa tri glavna izazova: ekstremnim vremenskim uslovima, rapidnim porastom svjetske populacije i smanjenjem obradivih površina uslijed urbanizacije (Huang *et al.*, 2020). Prema izvještaju Ujedinjenih nacija (UN), očekuje se da će svjetska populacija dostići 9,7 milijardi do 2050. godine, a 11,2 milijardi do 2100. godine (Cohen, 2003; Gu *et al.*, 2021). Pored navedenih, postoji i niz drugih faktora koji predstavljaju važan motiv za upotrebu digitalnih tehnologija u poljoprivredi, poput potreba za: daljinskim nadzorom i upravljanjem, povećanjem produktivnosti, smanjenjem proizvodnih troškova i minimizacijom negativnog utjecaja na životnu sredinu.

U savremenoj eri, poljoprivredni sektor, zajedno sa svim svojim granama i povezanim disciplinama, pokazuje veliku sklonost ka adaptaciji digitalne poljoprivrede kroz primjenu naprednih informatičkih i komunikacijskih tehnologija, posebno onih koje su dio tehnološkog sklopa Interneta stvari (*Internet of things* - IoT). IoT obuhvata senzore, komunikacijske protokole, skladištenje podataka u oblaku, alate za analizu podataka i akuatorske sisteme. Njegova svrha je da optimalno iskoristi dostupne informacije, znanja i vještine, u cilju unapređenja automatizacije i potpomaganja održivih praksi u poljoprivredi (Brewster *et al.*, 2017).

Jasmin Grahic

Senzorski sistemi i senzorske mreže

Senzorika se odnosi na proces prikupljanja podataka pomoću senzora. Senzor predstavlja jednu od osnovnih komponenti pametnih uređaja, koji tim uređajima omogućava da detektuju promjene u okolini. Pojam „senzor“ se može definirati na nekoliko načina:

- opća definicija - senzor je uređaj koji može primiti i reagovati na stimulus /podražaj (na primjer, varijacije u okolišnim mikroklimatskim uslovima, kao što su temperatura, pritisak i vlažnost, ili pak varijacije kada su u pitanju kretanje, pomjeranje, zvuk, sila, protok, svjetlost, prisustvo hemikalija itd.);
- operativna definicija - senzor je uređaj koji prevodi primljeni podražaj u električni signal;
- tehnička definicija - senzor je elektronski uređaj odgovoran za proizvodnju električnih, optičkih ili digitalnih podataka izvedenih iz fizičke okoline, koji se dodatno elektronski transformišu u korisne informacije.

Na osnovu ovih definicija, može se zaključiti da je ulaz senzora neka vrsta opažanja (neelektrični fenomen) u vezi sa promjenom fizičkih osobina, dok je izlaz električni signal u vidu varijacija u naboju, naponu ili struji. Senzorski izlaz treba biti kompatibilan s elektronskim sklopovima. U praktičnom smislu to znači da senzori omogućavaju mjerenje temperature i pritiska konvertovanjem toplote i atmosferskog pritiska u električne signale. Ovaj koncept senzorske tehnologije predstavlja ključni aspekt modernih poljoprivrednih praksi, omogućavajući precizno praćenje i upravljanje agro-ekosistemima putem automatizacije i digitalizacije. Dakle, senzori u savremenoj poljoprivrednoj proizvodnji omogućavaju precizno upravljanje resursima i bolju kontrolu uzgojnih uslova. Tako se, na primjer, senzori vlažnosti tla koriste za optimizaciju navodnjavanja i očuvanje vodnih resursa, dok elektromagnetni senzori (EMI i EC) omogućavaju analizu provodljivosti tla i sadržaja hranjivih materija. Temperaturni senzori i higrometri nadziru mikroklimu i vlažnost zraka, što je ključno za rast biljaka i prevenciju bolesti, posebno u zaštićenim prostorima. Senzori protoka vode omogućavaju kontrolisanu distribuciju vode, a pH senzori mjere kiselost tla i otopina, što pomaže u pravilnoj primjeni đubriva. Optički senzori detektuju promjene u boji i stanju biljaka, omogućavajući ranu identifikaciju stresa ili bolesti. Gasni senzori prate prisustvo štetnih plinova poput amonijaka i CO₂, posebno u zatvorenim prostorima poput staklenika. Na kraju, senzori opterećenja omogućavaju precizno mjerenje prinosa i efikasno doziranje sjemena i gnojiva. Ovi senzori predstavljaju temelj digitalne poljoprivrede usmjerene ka većoj efikasnosti i održivosti.

Radi boljeg razumijevanja, veoma je važno objasniti i pojam „senzorske mreže“. Senzorske mreže se sastoje od niza malih, bežično povezanih senzora, raspoređenih *ad hoc* u određenom okruženju. Ovi senzorski čvorovi rade zajedno kako bi mjerili i prenosili određene fizičke fenomene (putem *sink* čvorova) na udaljene baze podataka ili u oblak, gdje se prikupljeni podaci analiziraju. Savremeni senzori su opremljeni različitim tehnologijama bežične komunikacije i mrežnog povezivanja, što omogućava efikasan prijenos prikupljenih podataka. Bežični komunikacijski moduli u kombinaciji sa sensorima omogućavaju prijenos raznovrsnih podataka, dok mrežna rješenja omogućavaju međusobnu povezanost uređaja, što je ključno za efikasan prijenos informacija. U realnim uslovima, podaci često prolaze kroz više mreža prije nego što stignu do ciljne platforme.

Senzorske mreže se u poljoprivredi koriste za različite namjene (Ojha *et al.*, 2015), kao što su:

- mjerenje mikrometeoroloških podataka;
- praćenje prve pojave i brojnosti štetočina;
- praćenje nivoa hranjiva u zemljištu;
- kretanje životinja na pašnjacima;
- mjerenje emisije gasova;
- praćanje pozicije poljoprivrednih i drugih mašina i opreme;
- praćenje količine dostupne vode za biljke.

U poljoprivredi se koriste dva glavna tipa senzorskih mreža: terestričke senzorske mreže (TSM) i podzemne senzorske mreže (PSM). U TSM-u, mali senzorski čvorovi, koji se obično oslanjaju na tehnologiju mikroelektromehaničkih sistema (MEMS), postavljaju se iznad površine tla kako bi prikupili tačne podatke iz okruženja. Ovi senzori formiraju *ad hoc* mrežu koja obavlja specifične zadatke. U slučaju podzemnih senzorskih mreža (PSM), bežični senzorski čvorovi se postavljaju unutar tla. Ovi senzori, smješteni u subpovršinskom sloju, igraju ključnu ulogu u mjerenju različitih hemijskih i fizičkih svojstava tla, kao što su pH, salinitet, sadržaj vode u tlu, koncentracija toksičnih materija. Dakle, TSM i PSM pružaju real-time podatke koji pomažu u donošenju informisanih odluka o navodnjavanju, đubrenju i zaštiti biljaka, čime se povećava efikasnost i održivost poljoprivredne proizvodnje. Na primjer, potpuna automatizacija sistema za navodnjavanje u preciznoj poljoprivredi zahtijeva postavljanje senzora po cijelom polju, što uključuje oba tipa senzorskih mreža, kako bi se pratili mikrometeorološki parametri, vlažnost tla, te donijele odluke o rasporedu i količini navodnjavanja.

Daljinsko istraživanje (*remote sensing*)

Daljinsko istraživanje (eng. *remote sensing*) se u osnovi odnosi na prikupljanje informacija na daljinu, bez potrebe za fizičkim kontaktom. U okviru digitalne poljoprivrede, primjenjuju se statičke i mobilne metode daljinskog istraživanja za prikupljanje podataka o poljoprivrednim sistemima.

Statične metode daljinskog istraživanja obuhvataju upotrebu video kamera i mikrofona. Video kamere se koriste za praćenje stanja usjeva, životinja i poljoprivredne opreme, dok mikrofoni omogućavaju snimanje zvukova sa farmi, uključujući zvukove štetočina, rad mašina, kao i promjene u vokalizaciji/oglašavanju životinja, koje mogu ukazivati na stres ili bolest.

Mobilne tehnologije daljinskog istraživanja obuhvataju tri tipa sistema (Matese *et al.*, 2015; Shafi *et al.*, 2019):

- satelitske sisteme;
- avionske sisteme;
- sisteme bespilotnih letjelica.

Uporedne karakteristike svih mobilnih tehnologija daljinskog istraživanja prikazane su u sljedećoj tabeli (Tabela 1).

Tabela 1. Komparacija ključnih karakteristika različitih sistema mobilnih tehnologija daljinskog istraživanja

Tehnologija daljinskog istraživanja	Opservaciono područje	Pokrivenost	Učestalost opservacije	Prikaz terena	Prostorna rezolucija	Troškovi
satelitski sistemi	globalno	10 km	dnevno	uzak	5 m/piksel	visoki troškovi
avionski sistemi	regionalno	1 km	svakih nekoliko sati	širok	0,5 m/piksel	visoki troškovi
sistemi bespilotnih letjelica	lokalno	100 m	svakih nekoliko minuta	širok	0,05 m/piksel	ekonomično

Važno je naglasiti da odabir senzora koji će biti korišteni na sistemima daljinskog istraživanja (statičnim - video kamera ili mobilnim) preventivno zavisi od specifičnih ciljeva koji se planiraju ostvariti. Ključne karakteristike senzora na koje treba obratiti pažnju su:

- prostorna rezolucija – odnosi se na najmanju veličinu elementa na fotografiji, odnosno na najmanji objekt koji se može identifikovati;
- radiometrijska rezolucija – odnosi se na sposobnost senzora da detektuje najmanje promjene u intenzitetu svjetlosti. U praksi, visoka radiometrijska rezolucija omogućava bolje prepoznavanje nijansi i varijacija u boji, što je ključno za analizu i tumačenje podataka prikupljenih daljinskim istraživanjem;
- spektralna rezolucija - odnosi se na broj spektralnih opsega (specifične talasne dužine svjetlosti koje senzor može mjeriti) i širinu spektralnog opsega svakog od njih. Senzor koji ima veći broj spektralnih opsega s užim talasnim dužinama može preciznije razlikovati boje i nijanse. Visoka spektralna rezolucija omogućava dublje analize, što je, u praktičnom smislu, korisno za prepoznavanje različitih vrsta biljaka, ili pak procjenu zdravstvenog stanja biljaka;
- temporalna rezolucija – definira koliko često senzor može prikupljati podatke o istom cilju.

Naravno, i odabir samog sistema mobilnog istraživanja zavisiće od specifičnih potreba. Satelitski sistemi, na primjer, imaju potencijal da prikupe informacije o velikim površinama, ali obično gube prostornu i vremensku rezoluciju. Osim toga, prikupljeni podaci su pod utjecajem atmosferskih uslova. Avionski sistemi, također, mogu prikupljati podatke sa velikih površina, ali se, zahvaljujući boljoj prostornoj i vremenskoj rezoluciji u poređenju sa satelitskim sistemima, najčešće koriste za praćenja na nivou polja. S druge strane, sistemi bespilotnih letjelica se uglavnom koriste na lokalnom nivou, često na specifičnim tačkama, što zahtijeva dodatne napore za prikupljanje spektralnih podataka.

U daljinskom istraživanju, elektromagnetna radijacija (EMR) koja se reflektuje sa površina analiziranih tijela / objekata prikuplja se pomoću optičkih senzora. Ovi senzori mogu biti pasivni, tj. senzori koji koriste sunčevu svjetlost kao izvor, ili aktivni, oni koji koriste umjetne izvore svjetlosti. Dakle, daljinsko istraživanje predstavlja sofisticiranu tehniku koja koristi pomenute senzore za prikupljanje informacija bez fizičkog kontakta s objektom od interesa, oslanjajući se na reflektovanu i/ili emitovanu elektromagnetnu radijaciju (EMR). Važno je napomenuti da sva tijela čija je temperatura iznad apsolutne nule ($0\text{ K} = -273\text{ °C}$) emituju elektromagnetnu energiju. Senzori,

koji se koriste za prikupljanje elektromagnetne energije sa zadanih ciljeva, mogu se podijeliti u dvije kategorije: one koje generiraju sliku kao krajnji proizvod (kamere i skeneri) i one koji pružaju podatke u grafičkom ili numeričkom formatu, kao što su radiometri i spektrofotometri (Formaggio i Sanches, 2017).

Elektromagnetna radijacija (EMR) obuhvata različite raspone elektromagnetnog spektra, koji se može definirati kao skup svih postojećih elektromagnetnih talasa. U kontekstu daljinskog istraživanja, dostupni su razni uređaji i oprema koja omogućava istraživanje spektralnog raspona od ultraljubičastog zračenja (talasna dužina od 0,3 do 0,4 μm) do mikrovalova i radio talasa (iznad 27.000 μm , što odgovara 2,70 cm). Vidljivi spektar (0,4–0,7 μm) je raspon koji ljudsko oko može da detektuje, pri čemu svaka talasna dužina daje različitu percepciju boje, od ljubičaste do crvene. Vidljivi spektar se često dijeli na tri raspona talasnih dužina: plavi (0,4–0,5 μm), zeleni (0,5–0,6 μm) i crveni (0,6–0,7 μm), poznate kao RGB (crvena, zelena, plava). Infracrveni spektar (0,7–15,0 μm) dijeli se na bliski infracrveni (0,7–1,3 μm), srednji infracrveni (1,3–5,6 μm) i daleki infracrveni (5,6–15,0 μm). Također, uobičajeno je da se infracrveni spektar dijeli na reflektovani infracrveni (0,7–3 μm) i termalni ili emitovani infracrveni (3–15,0 μm). Ova klasifikacija elektromagnetnog spektra je ključna za razumijevanje različitih metoda daljinskog istraživanja, jer omogućava identifikaciju i analizu različitih tipova informacija koje se mogu prikupiti iz okruženja.

Kada elektromagnetna radijacija dođe u kontakt sa nekom površinom, može se apsorbovati, prenijeti ili reflektovati. Spektralna refleksija se definiše kao odnos između količine radijacije koja pada na površinu i one koja se od nje odbija. Bitno je napomenuti da refleksija svjetlosti na prirodnim objektima na zemlji nije jednaka za svaku talasnu dužinu. Ova specifična osobina svakog objekta naziva se spektralni potpis i predstavlja grafički prikaz refleksije svjetlosti na različitim talasnim dužinama unutar elektromagnetnog spektra.

Na primjer, kada sunčeva svjetlost dođe do površine biljke, svjetlost može biti apsorbovana, prenesena ili reflektovana. Dakle, kada svjetlost padne na list, dio te svjetlosti se apsorbuje, što biljci pomaže da obavlja fotosintezu, dok se dio svjetlosti odbija. Spektralna refleksija se odnosi na odnos između količine svjetlosti koja padne na list i one koja se od njega odbija. Na primjer, ako na list padne 100 jedinica svjetlosti, a 30 jedinica se reflektuje, tada je spektralna refleksija 30%. Međutim, važno je napomenuti da refleksija svjetlosti varira ovisno o talasnoj dužini. Na primjer, listovi biljaka reflektuju više svjetlosti u bliskom infracrvenom spektru nego u vidljivom spektru. Biljke obično reflektuju više radijacije u bliskom infracrvenom području (0,7–1,3 μm) zbog strukture svojih listova. U ovom opsegu, vegetacija praktično ne apsorbuje energiju, a ono što se ne reflektuje se prenosi. Nasuprot tome, biljke apsorbuju većinu radijacije u vidljivom spektru (0,4–0,7 μm), posebno crvene i plave talasne dužine, jer su te radijacije povezane sa pigmentima u listovima koji igraju ključnu ulogu u procesu fotosinteze. Hlorofili su pigmenti odgovorni za zelenu boju biljaka, budući da imaju vrhove apsorpcije zračenja u plavom i crvenom spektru. Ostali fotosintetski pigmenti apsorbuju svjetlost samo u plavom spektru. Ova osobina čini crveni dio spektra najčešće korištenim u daljinskom istraživanju, posebno kada se koristi u formulama za vegetacijske indekse.

Vegetacijski indeksi su važni alati koji omogućavaju efikasnije praćenje stanja vegetacije u poljoprivredi. Korištenjem ovih indeksa, smanjuje se utjecaj faktora koji mogu zakomplikovati analizu, kao što su pozadinska refleksija i atmosferski uslovi. Oni, u suštini, predstavljaju kombinacije refleksija svjetlosti na specifičnim talasnim dužinama, čime se omogućava preciznija procjena zdravlja biljaka i efekata poljoprivredne proizvodnje. Jedan od najpoznatijih vegetacijskih indeksa je vegetacijski indeks normalizirane razlike (NDVI), koji su razvili Rouse i saradnici 1973.

godine (Rouse *et al.*, 1973). Ovaj indeks je široko korišten zbog svoje sposobnosti da pruži jasne informacije o stanju biljaka, pomažući poljoprivrednicima u donošenju informiranih odluka.

Vrijednosti NDVI-a se kreću u granicama od -1 do 1, pri čemu vrijednosti bliže 1 ukazuju na visoku fotosintetsku aktivnost biljaka. Nasuprot tome, negativne vrijednosti NDVI-a ili vrijednosti bliske nuli ukazuju na to da se radi o područjima kao što su vodena tijela, objekti ili mjesta sa ograničenim biljnim pokrivačem, tj. da je aktivnost klorofila u tim oblastima niska. Ovaj indeks funkcionira na osnovu principa da aktivnija vegetacija bolje apsorbira svjetlost u crvenom spektru, dok reflektuje više svjetlosti u bliskom infracrvenom spektru. Naravno, navedeno se dešava zbog samog procesa fotosinteze i jedinstvene strukture listova. Promjene u vrijednostima NDVI-a tokom vegetacijske sezone mogu biti rezultat prirodnih promjena (prolazak pojedinih faza rasta i razvoja) ili problema izazvanih biotskim ili abiotskim faktorima.

Dakle, na osnovu promjena vrijednosti NDVI-a, moguće je, relativno precizno, procijeniti prinos, zdravstveno stanje biljaka, te identificirati nedostatke u opskrbi hranjivim tvarima i vodom, što je ključno za provođenje uspješnog monitoringa u digitalnim agro-ekosistemima.

IoT (*Internet of Things*)

Pojam "Internet stvari" (IoT) je prvi put spomenut 1999. godine, a izvorno se odnosio na korištenje RFID uređaja (*Radio-frequency identification* - bežična i beskontaktna tehnologija koja koristi radio frekvenciju kako bi se razmjenjivale informacije između prijenosnih uređaja / memorija i računara) u svrhu praćenja specifičnih proizvoda u proizvodnom procesu, da bi 2015. godine, IoT bio definisan kao «domen aplikacija koji integriše različita tehnološka i društvena polja» (Minerva *et al.*, 2015). Iako generička, ova definicija jasno daje do znanja da se IoT odnosi na uređaje povezane na internet koji prikupljaju i pohranjuju podatke iz okruženja s ciljem automatizacije različitih zadataka. Iot predstavlja inteligentnu globalnu mrežu koja omogućava:

- interakciju uređaja - dati uređaji mogu prikupljati podatke, obraditi ih, i povezati se na internet;
- obradu podataka i razmjenu informacija - uređaji, data centri i korisnici mogu međusobno razmjenjivati informacije;
- kreiranje inteligentnih sistema - na osnovu prikupljenih i analiziranih podataka, mogu se formirati razni inteligentni sistemi koji optimiziraju procese i funkcije.

Prema izvještaju kompanije CISCO (Pepper, 2019), procjenjuje se da će do 2030. godine oko 500 milijardi različitih senzorskih uređaja biti povezano na internet. Pomenuti uređaji će moći slati podatke koristeći IoT mreže, a preneseni podaci će biti evidentirani, evaluirani i distribuirani za obradu putem IoT usluga i aplikacija.

IoT mreža podržava raznovrsne formate podataka i različite protokole, te se kontinuirano razvija kako bi se prilagodila potrebama svakodnevnice. Iot je implementiran u brojnim sektorima, uključujući:

- pametne gradove - optimizacija funkcionalnosti infrastrukture i korištenja resursa za poboljšanje kvalitete života;
- transport - praćenje i upravljanje saobraćajem i vozilima kako bi se povećali efikasnost i sigurnost;
- poljoprivreda - povećanje efikasnosti u proizvodnji hrane i drugih poljoprivrednih proizvoda;
- energetska sektor - efikasno korištenje i distribucija energije;

- industrija - povećanje produktivnost i smanjenje troškova kroz automatizaciju proizvodnih procesa;
- zdravstvo - monitoring i upravljanje zdravstvenim podacima pacijenata radi poboljšanja kvalitete zdravstvene usluge.

Kada je u pitanju poljoprivredni sektor, IoT uređaji se mogu koristiti za olakšavanje usvajanja naprednih tehnologija. Naime, digitalna poljoprivreda koristi razna IoT rješenja za prikupljanje i analiziranje podataka u realnom vremenu, što, između ostalog, omogućava farmerima da prate proizvodne uslove i donose informisane odluke, čime se doprinosi održivijem i efikasnijem poljoprivrednom poslovanju.

U IoT-baziranom agro-ekosistemu, svi faktori i resursi neophodni za uspješno funkcionisanje sistema mogu se prikazati kao strukturu koja se sastoji od pet slojeva (petoslojna arhitektura):

- sloj percepcije - sloj percepcije obuhvata različite uređaje, kao što su RFID tagovi, senzori, RGB i multispektralne kamere, te GPS (globalni pozicioni sistem). Ovaj sloj je zadužen za prikupljanje specifičnih podataka (npr, podataka o mikroklimatskim uslovima). Prikupljeni podaci se obično šalju mikrokontrolerima ili mikroprocesorima, koji te podatke prosljeđuju dalje, u oblak, radi skladištenja;
- mrežni sloj - mrežni sloj uključuje različite komunikacijske tehnologije, kao što su ZigBee, Bluetooth, WiFi, LoRa, 4G/5G i širokopojasne mreže. Njegova glavna funkcija je prijenos prikupljenih podataka od sloja percepcije do sloja skladištenja. Ove žičane i bežične jedinice obično su ugrađene u mikrokontrolere i mikroprocesore, što olakšava slanje podataka ka resursima oblaka;
- sloj skladištenja - sloj skladištenja podataka, poznat i kao *cloud* sloj, zadužen je za čuvanje velikih količina prikupljenih podataka. Ovi podaci se mogu klasifikovati u tri glavne kategorije: strukturirani, polustrukturirani i nestrukturirani. Strukturirani podaci su podaci koji imaju standardizovani format, obično organizovani u tabelama sa redovima i kolonama, što olakšava njihovu obradu i analizu. Primjeri strukturiranih podataka uključuju informacije pohranjene u relacijskim bazama podataka, *Excel* datotekama i web formama. Polustrukturirani podaci nemaju potpunu strukturu, budući da im nedostaju određene informacije, i ne prate klasičnu tabelarnu strukturu. Setovi polustrukturiranih podataka uglavnom sadrže i metapodatke. Metapodaci (tip senzora, jedinica mjere, datum i vrijeme mjerenja, lokacija senzora, status senzora itd.) ključni su za razumijevanje i efikasnu obradu polustrukturiranih podataka, jer pružaju dodatni kontekst koji omogućava njihovu pravilnu analizu i korištenje. Primjeri polustrukturiranih podataka obuhvataju e-poštu, kompresovane datoteke, kao i formate poput JSON (*JavaScript Object Notation*) i CSV (*Comma-Separated Values*). Nestrukturirani podaci su podaci koji imaju unutrašnju strukturu, ali ne prate unaprijed definisan format ili šemu. Ovi podaci uključuju audio i video datoteke, fotografije i tekstualne (.txt) datoteke;
- sloj analize - sloj analize podataka, poznat i kao sloj obrade, igra ključnu ulogu u IoT-baziranim agro-ekosistemima. Njegova glavna funkcija je procjena i interpretacija podataka pohranjenih u oblaku. Sloj analize podataka obuhvata dva ključna segmenta: preprocesuiranje podataka i samu analizu podataka. Preprocesuiranje je proces koji podrazumijeva čišćenje i pripremu podataka kako bi se otkrile greške, neslaganja ili nekompletni podaci. Ovaj korak je od suštinskog značaja, jer osigurava da podaci budu tačni i dosljedni prije nego što se pristupi njihovoj detaljnoj analizi. U suštini, preprocesuiranje podataka čini osnovu na kojoj se može graditi pouzdana analiza. Glavni cilj analize jeste identifikacija ponavljajućih obrazaca

i određenih trendova koji se mogu uočiti unutar skupova prikupljenih podataka. U ovom procesu se koriste različite metode, uključujući statističke analize, mašinsko učenje i obradu prirodnog jezika (engl. *natural language processing* – NLP). Ove tehnike omogućavaju analitičarima da dobiju ključne uvide koji mogu značajno utjecati na način provođenja određenih aktivnosti (agrotehničkih mjera), a, u konačnici, i na same efekte proizvodnje. Na primjer, kroz analizu podataka mogu se identifikovati najučinkovitiji pristupi navodnjavanju, optimalne strategije korištenja đubriva ili prepoznati potencijalni problemi kada je u pitanju zdravlje biljaka.

- aplikacijski sloj - aplikacijski sloj korisnicima pruža jednostavne interfejsse koji omogućavaju lako praćenje i prikazivanje rezultata analize podataka. U ovom sloju, tehnike vizualizacije, poput interaktivnih grafikona, ključne su za bolje razumijevanje rezultata analize, što korisnicima pomaže da donesu informisane odluke i unaprijede efikasnost svojih poljoprivrednih sistema. Aplikativni sloj predstavlja ključnu vezu između analize podataka i njihove primjene u poljoprivrednoj praksi.

Dakle, svaki sloj igra specifičnu ulogu u procesu obrade podataka, a njihova međusobna povezanost omogućava efikasno upravljanje poljoprivrednim operacijama. Razumijevanje ovih veza je ključno za optimizaciju proizvodnje u digitalnim agro-ekološkim sistemima.

Automatizacija, robotika i AI

Automatizacija

Usvajanje digitalnih tehnologija, kao što su senzorske tehnologije, komunikacione i mrežne tehnologije, globalni pozicioni sistem (GPS), dronovi i vještačka inteligencija, značajno doprinosi razvoju automatizovanih sistema upravljanja farmama. Automatizacija u poljoprivredi obuhvata različite aktivnosti koje se provode kako bi se poboljšala efikasnost i produktivnost. Neke od tih aktivnosti podrazumijevaju:

- automatizovanu sjetvu;
- automatizovani nadzor usjeva i zasada;
- automatizovano upravljanje sistemom za navodnjavanje;
- automatizovanu zaštitu usjeva od štetočina;
- automatizovanu detekciju i prevenciju biljnih bolesti;
- automatizovano đubrenje;
- automatizovanu primjenu fitofarmaceutskih sredstava;
- automatizovanu berbu;
- automatizovano praćenje ponašanja životinja.

Ponavljamo, osnovni razlog automatizacije pojedinih procesa unutar digitalnih agro-ekosistema jeste upravo optimizacija cjelokupne poljoprivredne proizvodnje. U ovom kontekstu, tj. u okviru pomenutih, automatizovanih sistema, aktuatori igraju ključnu ulogu, budući da su sastavni dio gotovo svih mašina koje se koriste u digitalnoj poljoprivredi. Njihova osnovna funkcija je da pretvaraju jedan oblik energije u drugi. Kada je u pitanju poljoprivredna mehanizacija, ulazna energija može biti električna, hidraulična ili pneumatska, dok je izlazna energija obično mehanička (koja generiše pokret ili silu). Bez obzira na vrstu ulazne energije, generisani pokret može biti linearni ili rotacioni. Važno je pomenuti da postoje dvije osnovne kategorije aktuatora, i to:

- električni aktuatori - među električnim aktuatorima, najčešće korišteni u tehnologijama vezanim uz digitalnu poljoprivredu su električni motori i solenoidni ventili (ili električni ventili). Električni motori, koji mogu biti motori za izmjeničnu i motori za istosmjernu struju, koriste se za pokretanje mehanizama koji za svoj rad zahtijevaju rotacionu mehaničku energiju. S druge strane, solenoidni ventili regulišu protok tečnosti, kao što je protok vode u automatizovanim sistemima za navodnjavanje;
- hidraulični i pneumatski aktuatori - hidraulični i pneumatski aktuatori koriste hidraulična ulja, odnosno zrak. Aktuatori koji proizvode rotacione pokrete nazivaju se motorima (hidrauličnim ili pneumatskim), dok se oni koji generišu linearne pokrete nazivaju cilindrima (hidrauličnim ili pneumatskim). Hidraulični aktuatori se odlikuju visokom snagom i obrtnim momentom, ali rade na nižim brzinama. Za razliku od njih, pneumatski aktuatori omogućavaju brže pokrete, ali su im snaga i obrtni moment manji.

U savremenim poljoprivrednim mašinama i robotima, sve je prisutniji trend korištenja električnih aktuatora, koji omogućavaju direktnu integraciju sa elektronskim kontrolnim sistemom. Direktna integracija aktuatora u elektronske kontrolne sisteme poboljšava preciznost, smanjuje oscilacije i skraćuje vrijeme odziva. Pored toga, električni aktuatori ne zahtijevaju složene hidraulične ili pneumatske sisteme, koji su obično teži i sadrže veliki broj komponenti. Ove prednosti čine električne aktuatorske sisteme sve poželjnijim u modernoj poljoprivredi, jer značajno doprinose efikasnosti i preciznosti upravljanja poljoprivrednim operacijama.

Robotika i AI

Posljednjih godina, robotika i vještačka inteligencija (AI) postale su veoma popularne tehnologije koje su se našle u fokusu pažnje široke javnosti, industrije i istraživačke zajednice, zahvaljujući njihovom potencijalu da revolucioniraju načine na koje radimo, živimo i komuniciramo. Definicije robotike i vještačke inteligencije variraju i evoluiraju, što otežava formulisanje jedinstvenog i sveobuhvatnog okvira za razumijevanje ovih tehnologija. Prvi robotski likovi su se pojavili u naučnoj fantastici, u dramama, filmovima i književnim djelima, pri čemu su posjedovali ljudske osobine. Na primjer, mogli su hodati, razgovarati ili obavljati zadatke koje nijedna druga mašina nije mogla izvršiti. Od tada su mašine značajno napredovale, a sami roboti su razvijeni tako da se mogu efikasno prilagoditi različitim okruženjima. Granica između mašine i robota je vrlo tanka i često subjektivna. Važno je istaknuti i to da se pojmovi robotika i vještačka inteligencija često koriste kao sinonimi, što izaziva zabunu u vezi sa njihovim tačnim značenjem i primjenom.

Riječ „robot“ potiče od češke riječi „*robota*“, koja znači „prisilni rad“. Ova etimologija je imala svoje značenje u prošlosti, s obzirom na to da su roboti prvobitno konstruisani za obavljanje ponavljajućih i opasnih zadataka. Kako su roboti evoluirali, tako je i definicija robotike postala kontekstualno zavisna. Prema oksfordskom rječniku engleskog jezika, robot se definiše kao „mašina koju je moguće programirati pomoću računara, i koja može automatski da izvršava složene nizove radnji“. Međutim, ovom se definicijom ne kreira jasna razlika između robota i drugih mašina koje ne posjeduju autonomiju ili sposobnost da uče i da se prilagođavaju.

Druga definicija opisuje robote kao mašine koje mogu oponašati ljudske ili životinjske pokrete kako bi izvršile zadatak na način sličan ljudima. „Shakey“ je bio prvi mobilni robot opće namjene, napravljen krajem 1960-ih. Ovaj robot je bio u mogućnosti da obavlja zadatke sa jasnom svrhom, umjesto da se samo pridržava unaprijed definisanih instrukcija.

Vozila za istraživanje svemira, kao što su roveri, humanoidi i roboti sa nogama, nesumnjivo se klasifikuju kao roboti jer mogu obavljati zadatke poput ljudi i kretati se u područjima koja su ljudima nedostupna. Ovi roboti su u početku bili potpuno daljinski kontrolisani, ali su postepeno unaprijeđivani različitim nivoima autonomije kako bi efikasnije obavljali zadatke uz olakšanu kontrolu i smanjenu potrebu za ljudskom intervencijom. Međutim, ni ova definicija ne obuhvata sve vrste robota, s obzirom na to da postoje autonomne mašine koje mogu izvršavati zadatke koje ljudi ne mogu, ili koje obavljaju iste zadatke brže i efikasnije od ljudi.

Iako ne postoji jedinstveni konsenzus o tome koje mašine se mogu klasifikovati kao roboti, elektronsko programiranje, sposobnost percepcije okruženja, obrada podataka i fizičkih informacija, autonomno djelovanje do određenog stepena, kretanje, samostalno upravljanje fizičkim komponentama ili procesima, manipulaciju okruženjem i sposobnost donošenja inteligentnih odluka, funkcionalnosti su koje se mogu naći kod robotskih sistema.

Roboti mogu biti potpuno autonomni ili imati različit stepen autonomije, zbog čega se mogu koristiti na različite načine - od ručno vođenih ili daljinski upravljanih sistema do potpuno autonomnih, koji ne zahtijevaju ljudsku intervenciju. Jedna od ključnih razlika između mašine i robota je ta što su mašine elektro-mehanički uređaji sa unaprijed programiranim softverom, dok roboti imaju senzore koji im omogućavaju da percipiraju i komuniciraju sa svojim okruženjem. Na osnovu ove definicije, roboti se mogu klasifikovati u dvije osnovne kategorije, ili kombinaciju njih: (i) robotske manipulatore i (ii) mobilne robote (Trevelyan, 1999). Mobilni roboti se dalje dijele na tri glavne tipa, zavisno od okruženja u kojem se kreću: (i) kopnena vozila, koja mogu imati točkove, gusjenice ili noge; (ii) bespilotne letjelice (UAV), uključujući dronove i bespilotne avione; i (iii) podvodna vozila, poput autonomnih podmornica.

Razvoj robota, svih kategorija, sa različitim nivoima autonomije, predstavlja značajan korak ka unaprijeđenju efikasnosti i produktivnosti u različitim industrijama, uključujući poljoprivredu.

Naredna tehnologija koja će biti objašnjena jeste “umjetna inteligencija” (AI – eng. *artificial intelligence*). Pojam “umjetna inteligencija” prvi put je upotrijebio američki matematičar i informatičar John McCarthy 1955. godine. Umjetna inteligencija se odnosi na sposobnost mašine ili računara da donosi odluke na temelju podataka. Trenutno se većina aplikacija umjetne inteligencije oslanja na primjenu mašinskog učenja (ML – eng. *machine learning*). Mašinsko učenje je oblast računarstva koja se bavi razvojem algoritama koji omogućavaju računarima da uče iz podataka. Ovi algoritmi su sposobni prepoznati obrasce i pravila unutar tih podataka. Prepoznavanje obrazaca je proces u kojem se algoritmi pokušavaju prilagoditi podacima. Dakle, prepoznavanje obrazaca jeste zapravo otkrivanja nepoznate matematičke funkcija koja najbolje opisuje podatke, što je suprotan pristup onome od tradicionalnih metoda analize podataka gdje se koriste unaprijed definirane formule, a zavisi od sljedećih faktora:

- kvalitete podataka - proces prepoznavanja obrazaca postaje jednostavniji ako su podaci precizni i dobro strukturirani. Npr., identifikacija stvarnih trendova postaje otežana ukoliko se radi o podacima koji imaju mnogo grešaka;
- količine podataka – veći skup podataka, uglavnom, omogućava bolje razumijevanje obrazaca i trendova;
- broja varijabli koje su povezane sa jednim (istim) ishodom – broj varijabli povezanih sa jednim ishodom igra značajnu ulogu u modeliranju. Npr., prinos neke poljoprivredne kulture zavisi od više varijabli (atributa), poput tekture i strukture zemljišta, tipa tla, sume aktivnih i efektivnih temperatura tokom određenog perioda, količine padavina, prisustva štetočina itd.

U ovom slučaju, predikcija ishoda (prinosa) zavisi od svih nabrojanih atributa – varijabli povezanih sa jednim ishodom. Uključivanje većeg broja varijabli omogućava preciznije predikcije, jer se uzimaju u obzir različiti faktori koji utječu na prinos (u ovom slučaju, faktor zemljišta, mikroklimata, zdravstvenog stanja biljke). S druge strane, korištenje nedovoljnog broja varijabli može rezultirati gubitkom ključnih informacija. Dakle, broj varijabli povezanih sa jednim ishodom je ključan za tačnost predikcija;

- međuodnos varijabli koje su povezane sa jednim (istim) ishodom - ako su odnosi između varijabli složeni, na primjer, ako su neki atributi međusobno povezani na način koji nije lako uočljiv, sama analiza je otežana, a preciznost predikcije umanjena.

Duboko učenje je podoblast mašinskog učenja koje je fokusirano na obuku vještačkih neuronskih mreža da uče i donose predviđanja i odluke. U praktičnom smislu, duboko učenje omogućava provođenje veoma kompleksnih predikcija uz značajan nivo tačnosti dobivenih rezultata. Ipak, modeli dubokog učenja još uvijek funkcionišu po modelu “crne kutije”, što znači da ne pružaju mogućnost matematičkog razumijevanja funkcije koja pretvara ulaze u izlaze.

Jedan od ključnih izazova u razvoju najvažnije tehnologije 21. stoljeća, jeste pronalaženje adekvatnih načina za dobivanje preciznih predikcija uz korištenje manjih količina podataka. Navedeno bi rezultiralo manjom potrošnjom resursa i stvaranjem ambijenta u kojem se više procesa može automatizovati (Jha *et al.*, 2019). To bi, u praktičnom smislu, značilo da se umjesto brojnih senzora za mjerenje vlažnosti tla na svakom dijelu parcele može koristiti samo nekoliko senzora koji prikupljaju podatke na ključnim tačkama. Umjetna inteligencija bi, koristeći napredne algoritme, predviđala potrebne informacije za cijelu parcelu, što bi stvorilo uslove za implementiranje digitalnih rješenja kada je u pitanju sistem za navodnjavanje.

Nedavno je nastala i nova grana AI, poznata kao “Generativna AI”, koja se fokusira na stvaranje novih podataka na osnovu postojećih informacija, tj., koristi skupove postojećeg sadržaja kako bi identificirala obrasce te ih koristila za generiranje novog sadržaja. Osim prethodno pomenute, postoji i oblast pod nazivom “Objašnjiva AI”, koja pomaže boljem razumijevanju načina na koji AI donosi odluke, razjašnjavajući proces unutar tzv. “crne kutije”.

Robotika i AI se često koriste kao sinonimi. Suština je da robotika u velikoj mjeri zavisi od AI kako bi se postigla autonomija robotskih sistema i kako bi se automatizovale specifične funkcije. AI se primjenjuje u različitim segmetnima robotike, uključujući:

- senzoriku - roboti koriste senzore kako bi “vidjeli” svijet oko sebe. Ovi senzori prikupljaju informacije iz okoline, što pomaže robotskim sistemima da „znaju“ šta se dešava oko njih;
- mapiranje - roboti mogu kreirati mape svog okruženja. Ove mape su važne za njihovu orijentaciju i omogućavaju im planiranje putanje;
- lokalizaciju - ova sposobnost omogućava robotima da prepoznaju svoju tačnu poziciju unutar kreirane mape okruženja, što je ključno za uspješno kretanje;
- planiranje – robotski sistemi koriste AI kako bi donijeli odluke o tome kako će se kretati kroz svoje okruženje, uključujući pronalaženje najboljih ruta i izbjegavanje prepreka;
- kontrolu - AI šalje komande motorima robota, što omogućava njihov pravilno i precizno kretanje.

Radi boljeg razumijevanja trenutnog stanja u oblastima robotike i AI, u nastavku je dat kratki pregled njihovog historijskog razvoja, a sve u kontekstu razvoja ovih tehnologija za potrebe poljoprivredne proizvodnje.

Industrijska revolucija, koja se dogodila sredinom osamnaestog i početkom devetnaestog stoljeća, značajno je promijenila obrazac migracije radne snage. Mnogi ljudi su napustili ruralna područja u potrazi za boljim ekonomskim prilikama u gradovima, što je rezultiralo povećanjem životnog standarda. Međutim, ovaj proces migracije doveo je do ozbiljnog nedostatka radne snage na globalnom nivou, posebno u poljoprivredi.

Jedna od prekretnica u razvoju automatizovanih rješenja za potrebe poljoprivredne proizvodnje bila je povećanje troškova rada tokom 1930-ih u SAD-u. Navedeno je posljedica prirodnih katastrofa (pješčane oluje i dugotrajna suša) koje su pogodile prerije u srednjem dijelu SAD-a i Kanade.

Nadalje, smanjenje radne snage u poljoprivrednoj proizvodnji uzrokovano svjetskim ratovima, te globalne krize u periodu poslije Drugog svjetskog rata, doveli su do toga da je tokom ranih 1990-ih poljoprivreda počela da intenzivno traži nove načine za povećanje efikasnosti i smanjenje troškova proizvodnje, što je rezultiralo integracijom novih rješenja u agro-ekosisteme.

Svi ovi faktori doprinijeli su kontinuiranom razvoju i istraživanju robotike i vještačke inteligencije u poljoprivredi (Fountas *et al.*, 2007; 2020).

U sljedećoj tabeli su predstavljena ključna dostignuća i inovacije u razvoju robotike i vještačke inteligencije u poljoprivredi, uz isticanje njihovog značaj za savremene poljoprivredne prakse (Tabela 2).

Tabela 2. Ključna dostignuća u primjeni robotike i vještačke inteligencije u poljoprivredi

Vremenski period	Značajna dostignuća
1920 -1945	Istraživanja fokusirana na automatizaciju i elektro-mehanička unaprjeđenja poljoprivredne opreme.
1941	Oranje polja kružnog oblika – oranje na način da se plug konopcom veže za fiksni objekat u centru kruga, oko kojeg će se, sa svakim novim prolazom, namotavati konopac i smanjivati radijus kretanja mašine koja vuče plug, sve do trenutka u kojem će konopac biti u potpunosti namotan, odnosno cjelokupna parcela obrađena.
1945	Korištenje radiofrekvencija za teleoperativno upravljanje poljoprivrednim traktorima.
1959	Implementacija višekanalne radio-kontrole za traktore koji koriste hidraulične aktuatorske sisteme.
1964	Razvoj i implementacija sistema „vođa-sljedbenik“ - odnosi se na tehnologiju koja omogućava automatizovanim vozilima da efikasno i precizno prate drugo vozilo, prilikom čega održavaju zadanu udaljenost od praćenog vozila.
1967	Utvrdjivanje pozicije traktora pomoću triangulacije, uz upotrebu infracrvenih senzora pokreta.
1970 -1990	Razvoj sistema za kontrolu rada prskalice (Harries i Ambler, 1981).
1981	Prva upotreba optičkih senzora u poljoprivredi za bezkontaktno mjerenje visine zida brazde.
1992 - 2000	Integracija globalnog pozicionog sistema (GPS) u poljoprivredna vozila, kao i naprednih, kontrolnih algoritama za preciznu navigaciju.
1995 - 2000	Razvijen sistem autonomnog upravljanja traktorima baziran na analizi podataka prikupljenih sa optičkih senzora (Gerrish <i>et al.</i> , 1997).
2000 - 2020	Saradnja industrije i istraživača na razvoju različitih robotskih platformi za poljoprivredu.

LITERATURA:

- 1) Barykin, S.Y., Kapustina, I.V., Kirillova, T.V., Yadykin, V.K., Konnikov, Y.A. (2020). Economics of digital ecosystems. *Journal of Open Innovation: Technology, Market, and Complexity*, 6(4): 124.
- 2) Baryshnikova, N., Sazhin, V., Malinovskaya, E. (2022). Sustainable food production and digital agricultural systems. *Sustainable Food Systems*, 14(1): 59-73.
- 3) Brewster, C., Roussaki, I., Kalatzis, N., Doolin, K., Ellis, K. (2017). IoT in agriculture: designing a Europe-wide large-scale pilot. *IEEE Communications Magazine*, 55(9): 26-33.
- 4) Cohen, J.E. (2003). Human population: the next half century. *Science*, 302(5648): 1172-1175.
- 5) Formaggio, A.R., Sanches, I.D. (2017). Remote sensing techniques for agricultural management. *Journal of Agricultural Monitoring*, 15(2): 89-104.
- 6) Fountas, S., Blaskmore, B. S., Vougioukas, S., Tang, L., Sørensen, C. A. G., Jørgensen, R. N. (2007). Decomposition of Agricultural tasks into Robotic Behaviours. *Agricultural Engineering International: CIGR Journal*, IX.
- 7) Fountas, S., Mylonas, N., Malounas, I., Rodias, E., Hellmann Santos, C., Pekkeriet, E. (2020). Agricultural Robotics for Field Operations. *Sensors*, 20: 2672.
- 8) Gu, D., Andreev, K., Dupre, M.E. (2021). Major trends in population growth around the world. *China CDC Weekly*, 3(28): 604.
- 9) Guidotti, R. (2015). Ecosystem interactions and agricultural sustainability: A review. *Journal of Agricultural Systems*, 5(3): 180-195.
- 10) Huang, K., Shu, L., Li, K., Yang, F., Han, G., Wang, X., Pearson, S. (2020). Photovoltaic agricultural internet of things towards realizing the next generation of smart farming. DOI: 10.1109/ACCESS.2020.2988663.
- 11) Jha, K., Doshi, A., Patel, P., Shah, M. (2019). A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*, 2: 1-12.
- 12) Kuldeep Singh, P.K. (2024). Software testing techniques. Wiley Press, Amsterdam.
- 13) Liu, Y., Ma, X., Shu, L., Hancke, G.P., Abu-Mahfouz, A.M. (2020a). From industry 4.0 to agriculture 4.0: current status, enabling technologies, and research challenges. *IEEE Transactions on Industrial Informatics*, 17(6): 4322-4334.
- 14) Liu, Y., Tang, J., Jiao, Y., Zhu, X., Liu, J. (2020b). Digital farming: Transitioning to a sustainable agricultural model. *Journal of Digital Agriculture*, 12(3): 45-60.
- 15) Mahant, Y., Rao, M., Patel, S. (2012). Machine learning and data analysis in agricultural applications. *Journal of Applied Agricultural Sciences*, 10(1): 112-130.
- 16) Matese, A., Toscano, P., Di Gennaro, S.F., Genesio, L., Vaccari, F.P., Primicerio, J., Belli, C., Zaldei, A., Bianconi, R., Gioli, B. (2015). Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing*, 7(3): 2971-2990.
- 17) Minerva, R., Biru, A., Rotondi, D. (2015). Towards a definition of the Internet of Things (IoT). *IEEE Internet Initiative*, 1(1): 1-86.

- 18) Ojha, T., Misra, S., Raghuwanshi, N.S. (2015). Wireless sensor networks for agriculture: the state-of-the-art in practice and future challenges. *Computers and Electronics in Agriculture*, 118: 66-84.
- 19) Ragazou, D., Ioannou, D., Kyriacou, A. (2022). The role of digital ecosystems in modern agricultural practices. *Smart Agriculture Journal*, 8(2): 213-225.
- 20) Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W. (1973). Monitoring Vegetation Systems in the Great Plains with ERTS. 3rd ERTS Symposium, NASA SP-351, Washington DC, 10-14 December 1973, 309-317.
- 21) Shafi, U., Mumtaz, R., Jabbar, S. (2019). Mobile technology applications in smart farming systems. *Mobile Agricultural Science*, 7(4): 271-286.
- 22) Tang, S., Zhu, Q., Zhou, X., Liu, S., Wu, M. (2002). A conception of digital agriculture. *IEEE Int Geosci Remote Sens Symp.*, 5: 3026-3028.
- 23) Trevelyan, J. (1999). Redefining robotics for the new millennium. *The International Journal of Robotics Research*, 18(12): 1211-1223.
- 24) Zambon, I., Cecchini, M., Egidi, G., Saporito, M. G., Colantoni, A. (2019). Revolutionizing agriculture: The impact of digital agriculture on farming systems. *Agricultural Systems*, 168: 39-45.

SAVREMENI SISTEMI U ISHRANI BILJAKA, ODRŽIVE STRATEGIJE GNOJIDBE, GNOJIVA I GNOJIDBA

Hamdija Čivić, Emina Sijahović

Savremeni sistemi u ishrani biljaka i održive strategije gnojidbe

Primjena novih znanja i tehnologija u poljoprivredi, a posebno u oblasti ishrane biljaka i gnojidbe čine osnovu moderne i održive poljoprivredne proizvodnje. Glavni razlozi za uvođenje novih tehnologija i znanja u poljoprivredi su ekonomske i ekološke prirode, ali isto tako i sve zahtjevnije tržište koje potražuje kvalitetniju i zdravstveno sigurniju hranu. Upotreba gnojiva je nezamjenjiva za uspješnu biljnu proizvodnju. Ona čine ujedno i najveći trošak u biljnoj proizvodnji, pa u tom smislu njihova potrošnja mora biti maksimalno racionalna. Ovakav pristup i strategija potrošnje gnojiva doprinosi ekonomski opravdanoj, ekološki održivoj i zdravstveno sigurnoj biljnoj proizvodnji i ujedno doprinosi smanjenju klimatskih promjena (Penuelas *et al.*, 2023).

Naime, tokom prošlog stoljeća poljoprivredna proizvodnja je zbog povećanog korištenja pesticida i gnojiva u cilju postizanja što većih prinosa doživjela svoj svojevrsni procvat. Proizvodnja po jedinici površine se značajno povećala, što je dovelo i do određenog ekonomskog razvoja zemalja, posebno onih zemalja koje su ove prednosti u većoj mjeri koristile. Međutim, dok se taj rast bilježio, vrlo često se zanemarivao negativan uticaj nekontrolirane i vrlo često prekomjerne upotrebe pesticida i gnojiva na ekologiju i zdravstveno sigurnosne aspekte tako proizvedene hrane.

Takav način poljoprivredne proizvodnje često je dovodio do onečišćenjem tla, podzemnih voda i zraka, eutrofikacije površinskih voda, degradacije tla, pa čak i do promjene cijelog ekosistema, dovodeći u pitanje održivosti moderne poljoprivrede na navedenim principima (Rakshit *et al.*, 2022; Sharma *et al.*, 2019). Kako bi se izbjegle negativne posljedice za okoliš, mora se značajno povećati učinkovitost primjene gnojiva (Shaviv i Mikkelsen, 1993; Liu *et al.*, 2014).

Postoji niz strategija koje se koriste za povećanje učinkovitosti korištenja gnojiva, uključujući i poboljšane metode primjene gnojiva. Postoji nekoliko metoda ili načina primjene gnojiva kao što su: a) „precizna gnojidba“ koja uz pomoć određenih uređaja i alata omogućava varijabilno rasipanje gnojiva na određenoj površini-parceli, b) „precizna gnojidba“ koja koristi određene uređaje i alate u sistemu fertirigacije, c) upotreba podijeljene ili lokalne primjene gnojiva, d) korištenje ekološki prihvatljivih gnojiva i sporodjelujućih gnojiva koja hraniva otpuštaju postepeno i zavisno od uslova sredine (Shaviv, 2005; Lü *et al.*, 2016).

Učinkovitost primjene gnojiva dodatno se može povećati ukoliko se poštuje i strategija koju je razvio Međunarodni institut za ishranu biljaka iz Kanade (IPNI). Ovaj Institut je razvio tzv. 4R strategiju upravljanja hranivima (4R *Nutrient Stewardshi: Right Source, Right Rate, Right Time, Right Place*, IPNI, 2019). Ovo je jedna od temeljnih strategija IPNI-ja za podršku svjetskom nastojanju poljoprivrede da zadovolji potrebe biljne proizvodnje na održiv način. Koncept 4R se temelji na 4 osnovna principa primjene gnojiva i to: 1) izvor hraniva i gnojiva mora biti pravi (vrsta gnojiva), 2) doza hraniva i gnojiva mora biti prava, prilagođena konkretnim uslovima, 3) vrijeme primjene gnojiva mora biti pravo i 4) mjesto primjene gnojiva mora biti tačno (pravo). Sva 4R principa se danas nastoje što više promovirati i širiti u praksi. Za primjenu ovih 4R „prava“ u praksi je vrlo bitno da su ona temeljena na naučnim principima, jer samo tako je moguće postići ciljeve održivog upravljanja gnojidbom. Za pravi izvor hraniva to bi značilo osiguravanje uravnotežene

opskrbe neophodnim (esencijalnim) elementima ishrane uvažavajući hraniva dostupna iz prirodnih rezervi, kao i svojstva gnojiva (mineralnih i organskih) obzirom na raspoloživost i količinu hraniva. Prava doza gnojidbe određuje se na osnovu bioraspoloživosti hraniva iz tla kao i potrebe biljaka za hranivima (temeljenim na agrohemijским analizama tla i biljaka). Pravo vrijeme primjene gnojiva temelji se na podešavanju dinamike usvajanja i bioraspoloživosti hraniva s vremenom primjene gnojiva uz uvažavanje fenoloških faza razvoja biljaka i potreba biljaka za hranivima shodno određenim fenofazama razvoja, mogućih gubitaka iz tla u podzemne vode i/ili atmosferu. Pravo mjesto primjene podrazumijeva uvažavanje prostorne varijabilnosti (heterogenost) parcele i specifičnih potreba usjeva s obzirom na dubinu korijenovog sistema i moguće gubitke (precizna i diferencirana gnojidba, gnojidba u trake i dr.). Ovim 4R pravilima bi se mogao pridodati i pravi izbor gnojiva spram njegovih fizičko-hemijskih svojstava i cijene. U praksi bi to značilo optimizaciju gnojidbe s obzirom na cijenu gnojiva po jedinici aktivne tvari, njegovu efikasnost i učinak na prinos i kvalitet proizvoda, kao i popravak proizvodnih svojstava tla.

Na osnovu svega iznesenog, mogao bi se izvući jedan zaključak za dobru ili održivu strategiju gnojidbe, a to je da ona mora uvažavati količinu, vrijeme i način primjene organskih i/ili mineralnih gnojiva, usaglašenu sa stanjem hraniva u tlu, njihovom dostupnošću, potrebama biljaka, očuvanjem okoliša i da je isplativa.

„Precizna gnojidba“, danas kao novi, moderni pristup gnojidbe, koristeći određene uređaje i alate, pruža veliku mogućnost i šansu za racionalniju upotrebu gnojiva i njegovu veću učinkovitost (Fan *et al.*, 2020). Tako, jednom od metoda precizne gnojidbe, tzv. metoda sa varijabilnom dozom rasipanja gnojiva, je moguće racionalnije upravljati potrošnjom gnojiva i povećati njegovu učinkovitost. Postoje dva pristupa ili načina za implementaciju varijabilnog modela doziranja gnojiva, jedan je baziran na korištenju senzora, a drugi na korištenju mapa (Pawase *et al.*, 2023). Ova metoda precizne gnojidbe podrazumijeva gnojidbu u kojoj se gnojivo rasipa po površini tla-parcele u varijabilnim, tj. različitim količinama. Zahvaljujući prethodno urađenim analizama tla ili na osnovu skeniranja tla na EC vrijednost dobivaju se podaci na osnovu kojih se kreiraju gnojidbene mape. Suština je u tome da, zemljište kao polifazni sistem, je vrlo heterogeno kako po sastavu tako i po osobinama i da kao takvo nije jednolično u pogledu sadržaja biljnih hraniva. Takvo stanje zemljišta se prenosi na mape, a onda se uz pomoć pametnih-preciznih sistema i uređaja koji mogu da koriste i očitavaju podatke sa tih mapa, rasipa gnojivo po površini zemljišta ovisno kako je na mapi prikazano stanje hraniva, odnosno njegovo stvarno stanje i sadržaj u tlu. Varijabilna doza gnojiva čini glavni stub „precizne poljoprivrede“ iz razloga što dosadašnja praksa uniformne (jednoobrazne) primjene doze gnojiva po cijeloj površini zemljišta nije opravdana, imajući u vidu njegov heterogeni sastav i sadržaj hraniva, ali i različite potrebe biljnih vrsta za određenim hranivima. Sve navedeno u konvencionalnom sistemu uzgoja i gnojidbe nije moguće kontrolisati za razliku od navedenog preciznog varijabilnog modela gnojidbe.

Varijabilno doziranje, odnosno rasipanje gnojiva po parceli prilagođeno stvarnom stanju hraniva u tlu, njegovim fizičko-hemijskim svojstvima i potrebama biljaka za hranivima omogućeno je zahvaljujući instaliranju i korištenju određenih alata i opreme, kao što su različite vrste senzora, kompjuterskih tehnologija, tehnologija za daljinsko detektovanje (*Remote Sensing*-RS), globalnog sistema pozicioniranja (GPS) i geografskog informacionog sistema (GIS). Najvažniji korak kod ovog sistema gnojidbe je generiranje karata tla (gnojidbenih karata) sa njegovim karakteristikama. Pravljenje gnojidbenih karata podrazumijeva prethodno prikupljanje neophodnih podataka vezanih za stanje plodnosti tla, njegova fizičko-hemijska svojstva i sadržaj hraniva u njemu. Do ovih podataka se dolazi na osnovu analiza prethodno uzetih uzoraka tla sa određenih površina i njihovim

unošenjem u odgovarajuće programe za pravljenje gnojidbenih mapa (Slike 6 i 7). Uzorci tla se uzimaju pomoću sonde za uzorkovanje tla. Za velike površine na kojima je potrebno uzeti veliki broj uzoraka, danas se koriste nosivi ili vučeni uređaji koji posjeduju sondu za uzorkovanje tla. Oni mogu imati i druge alate na sebi poput mjerača pH vrijednosti i skenera za mjerenje EC vrijednosti. Tako je moguće u jednom proходу prikupiti više vrsta podataka. Određivanje elektroprovodljivosti ili EC vrijednosti tla je moguće i pomoću posebnih uređaja za mjerenje ovog parametra tzv. skeneri za EC. Ovi skeneri se mogu priključiti na traktore ili druge vučene mašine, quad vozila i sl. Neki modeli skenera za EC vrijednosti se mogu montirati na dronove i na takav način snimiti i odrediti EC vrijednosti u tlu koje služe za pravljenje gnojidbenih mapa. Uređaji za daljinsko detektovanje, zajedno sa GPS uređajima za određivanje koordinata, omogućava pravljenje tačne karte i modele poljoprivrednih polja. Ovako se svi neophodni podaci prikupljaju i pohranjuju u obliku elektronskih kompjuterskih baza podataka, i uz pomoć GIS programa vrši analiza i obrada podataka, te se kreiraju mape varijabilnosti poljoprivrednog zemljišta u odnosu na njegova svojstva. Ovakve mape se instaliraju na GPS uređaje mašina koje se koriste za rasipanje gnojiva. Zahvaljujući mapi gnojidbe i GPS uređajima, moguća je varijabilna distribucija gnojiva na parcelama. Na ovakav način se upravlja racionalnijom potrošnjom gnojiva i tako postižu bolji ekonomski i ekološki efekti. Ove tehnologije povećavaju tačnost primjene varijabilne količine gnojiva i učinkovitu upotrebu inputa. Međutim, oni još nisu široko prihvaćeni u malim poljoprivrednim sistemima, kakav je nažalost u Bosni i Hercegovini. Precizna poljoprivreda, a sa njom i precizna gnojidba je još uvijek malo zastupljena i zbog drugih činjenica i poteškoća kao što su: potreba za određenim nivoom edukacije i stručnosti za njenu širu primjenu, visoki troškovi, kao i različita shvatanja farmera o njenoj upotrebi i prednostima. Ona se još naziva „klimatski pametna poljoprivreda”, jer može da ima značajnu ulogu u ublažavanju klimatskih promjena, gdje poljoprivredni sektor u ukupnoj emisiji stakleničkih gasova u zemljišnoj atmosferi učestvuje sa oko 13%. Na slikama ispod (Slike 1, 2, 3), prikazani su neki od uređaja i alata koji se koriste ili su neophodni za funkcionisanje sistema precizne gnojidbe sa varijabilnim načinom rasipanja gnojiva.




Slika 1. Veris U3 koristi tri vrste senzora za izradu pristupačnih karata: pH i EC vrijednost i sadržaj organske materije (izvor: <https://topfarms.com/technology/7,7-soil-testing-with-the-veris-u3-scanner>).




Slika 2. Nošeni-vučeni uređaj sa sondom za uzimanje uzoraka tla (Izvor: <https://www.carneuse.com/eu-en/support/field-support>).



Slika 3. Satelitsko snimanje i prikupljanje podataka (Izvor: https://web2.mendelu.cz/af221_multitext/hnojeni_plo-din/pdf/precizni_zemdelstvi.pdf).



Slika 4. Mape EC vrijednosti tla



Slike 5, 6 i 7. Traktor sa rasipačem gnojiva koji posjeduju uređaje za varijabilno doziranje gnojiva zasnovano na gnojidbenoj mapi (Izvor: <https://www.maschiogaspardo.com/hi/web/india/primo-ew-isotronic-double-shutter-system-for-fertilization>).

Primjena varijabilne doze gnojiva i tehnologije kontrole varijabilne doze u stvarnom vremenu sve se više primjenjuju u preciznoj poljoprivredi kako bi se prilagodili zahtjevima za unos i iznošenje hraniva putem biljaka na temelju tzv. “3S” tehnologije (daljinsko očitavanje RS, GIS i GPS karte). Ove tehnike za varijabilno doziranje gnojiva imaju širok raspon primjene kao npr:

- varijabilni aplikator granuliranog gnojiva temeljen na karti (postavljanje gnojiva u red usjeva),
- senzorska primjena temeljena na rastu NDVI i spektralnih vegetacijskih indeksa u stvarnom vremenu (SVI) (utvrđivanje statusa azota na temelju sadržaja hlorofila i strukture krošnje),
- rasipač s centrifugom (istovremena primjena više gnojiva),
- metoda diskretnih elemenata (dvostruki aplikator gnojiva),
- pop-up metoda (ljuska sjemena gnojiva),
- rasipač gnojiva s promjenjivom dozom (na temelju podataka o rastu u stvarnom vremenu - NDVI i SVI).

U usporedbi s konvencionalnim sistemom gnojidbe, aplikatori gnojiva s promjenjivom dozom štede oko 45% N gnojiva i daju 26% ekonomske koristi. Primjena promjenjive doze isplativa je i visoko-prinosna jer smanjuje uticaj na okoliš i povećava apsorpciju u usporedbi s primjenom

jednolične doze. Istraživanja na primjeru usjeva kukuruza pokazuju, da su varijabilne doze smanjile za 29-32% unos gnojiva i povećale prinos za 11-34% u usporedbi s jedinstvenom dozom. Također, određena istraživanja su pokazala, da kod voćnjaka tretiranje varijabilnim dozama je uštedjelo oko 40% gnojiva i 38% azotnih gnojiva koristeći karte veličine krošnje i karte određenih prinosa, odnosno 23% fosfatnih gnojiva. Ranija istraživanja pokazuju da kod gnojidbe ujednačenom dozom, samo 30% primijenjenog gnojiva je iskorišteno, a preostalih 70% je bilo podložno gubicima: ispiranju, adsorpciji ili površinskom oticanju. Baligar *et al.* (2001), navode da je ukupna učinkovitost ili iskorištenost hraniva od strane biljaka kod konvencionalnih metoda gnojidbe <50% za N, <10% za P i <40% za K. Za razliku od konvencionalnog metoda, varijabilni način precizne gnojidbe daje bolje rezultate i u istraživanjima koja su provedena u Kini. Tako je učinkovitost gnojidbe azotom specifičan za lokaciju smanjio ukupnu potrošnju azota za 33,6%, povećao prinos za 0,4 t/ha, poboljšao poljoprivrednu učinkovitost azota za 20% i učinkovitost oporavka azota za 16% u sistemu usjeva riža-pšenica. Učinkovitost korištenja gnojiva-hraniva može se izračunati pomoću podataka o odgovoru prije svega na prinos, ali i drugih parametara. Međutim, prinos usjeva i odgovor na hranjive tvari značajno variraju ovisno o klimatskim promjenama, varijacijama u tipu tla i osobinama krajolika u polju. Da bi ovaj model bio učinkovit i ekonomski opravdan, Sawyer (1994) navodi, da se varijacije unutar polja moraju tačno identificirati i pouzdano protumačiti. To je osnova i preduslov za njegov uspjeh, kao i dodatna istraživanja koja trebaju da upotpunosti razviju te sposobnosti.

Preciznu gnojidbu, osim prethodno opisanog varijabilnog načina aplikacije gnojiva, moguće je provoditi i kroz sistem za navodnjavanje tj. putem fertirigacije - kontrolirani sistem fertirigacije ili tzv. pametni (*smart*) sistem fertirigacije. Pametni sistem fertirigacije predstavlja naprednu poljoprivrednu tehnologiju koja kombinira procese navodnjavanja i gnojidbe na precizan i automatiziran način. Može značajno povećati produktivnost biljaka optimiziranjem primjene gnojiva i vode (Karašahin *et al.*, 2018). Ovaj sistem gnojidbe ujedno predstavlja dio sistema pametne (*smart*) poljoprivrede koja koristi informacione i komunikacione tehnologije za povećanje proizvodnih rezultata, efikasnosti i efektivnosti u poljoprivrednoj proizvodnji.

Poboljšanje upravljanja navodnjavanjem i gnojidbom, moglo bi se osigurati naprednom tehnologijom i pametnim sistemima za fertirigaciju. Razvojem internet stvari (IoT) i bežične senzorske mreže (WSN) kao novih tehnologija, kao i najnoviji napredak u razvoju senzora za implementaciju sistema navodnjavanja i ishrane biljaka, ubrzali su evoluciju pametnih sistema fertirigacije. Pametni sistem fertirigacije podrazumijeva prikupljanje podataka u stvarnom vremenu koji se odnose na parametre tla, biljke i vremenske uslove (prilike) koji su od značaja za rast i razvoj biljaka. Da bi se ovi podaci mogli prikupiti neophodno je njihovo praćenje.


Praćenje vlažnosti tla uključuje mjerenje dostupnosti vode u tlu koje se široko koristi za planiranje navodnjavanja. Međutim, nedostatak ovakvog pristupa navodnjavanja koji bi se temeljio ili se temelji samo na stanju vlage u tlu, je u tome, što na rast i razvoj biljaka ne utiče samo sadržaj vode u tlu nego i neki drugi faktori. Drugi faktori koji također mogu da dovedu do stresnih stanja biljaka su: nepovoljni atmosferski uslovi, sadržaj hranjivih tvari u tlu, salinitet u zoni korijena, štetočine i bolesti.

Zbog toga, za što bolje i učinkovitije navodnjavanje i ishranu biljaka (fertirigaciju), poželjno je, ili bolje reći neophodno je, i praćenje parametara vremenskih uslova (temperatura, relativna vlaga zraka, indeks zračenja itd.) Praćenje ovih parametara važno je za procjenu referentne evapotranspiracije (ET_o – ukupna količina vode koja iz tla odlazi u atmosferu procesima evaporacije (E) i transpiracije (T) putem referentne biljke u stvarnom vremenu, korištenjem prikupljenih vremenskih podataka. Nekoliko studija govori o korištenju vremenskih parametara za planiranje navodnjavanja. Učinkovita predikcija klime unutar vegetacione sezone, mogla bi pomoći poljoprivrednicima u

upravljanju navodnjavanjem i smanjenju rizika, ali potrebno je više studija koje koriste srednjoročne ili dugoročne meteorološke prognoze kako bi se poboljšala preciznost navodnjavanja.

Na kraju, kao treći, ali ništa manje važani parametri koje treba pratiti i integrirati u cijeli sistem, jesu parametri praćenja indeksa biljke i vode, kao što je korelacija između nedostatka vode u biljkama i nedostatka vode u tlu. Ovaj parametar daje optimalnu procjenu za raspored navodnjavanja. Praćenje stanja vode u biljci je od velikog značaja za učinkovitost navodnjavanja, jer pojedine fenofaze razvoja biljaka su jako osjetljive na nedostatak vode. Primarni nedostatak u primjeni senzora baziranih na biljkama za planiranje navodnjavanja je da oni ne daju direktno mjerenje količine vode za navodnjavanje koja će se primijeniti na usjeve. Međutim, svi ovi podaci prikupljeni sa sve tri vrste senzora (tlo, vremenske prilike i biljka), su vrlo važni za uspješan rad prilagodljivog sistema, za podršku odlučivanju ili tzv. DSS (*Decision Support System*), kao ključnog dijela ukupnog sistema pametne fertirigacije. DSS kao glavna komponenta zadužena je za donošenje konačne odluke o količini vode za navodnjavanje, ili ekvivalentno vremenu za navodnjavanje s obzirom na kontinuirani protok vode. Ova se odluka smatra inteligentnom na temelju informacija koje dostavljaju senzori tla, vremenskih uslova, vrste usjeva i analize interneta stvari (IoT). Zato je cilj ove komponente djelovati kao „ljudski stručnjak u procesima donošenja odluka“ za optimizaciju navodnjavanja i pomaganje poljoprivredniku. DSS nadalje ima za cilj osigurati racionalno korištenje gnojiva, vodnih resursa i u konačnici smanjeni pritisak na okoliš. Metoda omogućuje integraciju i optimizira upravljanje tradicionalnim sistemima uzgoja usjeva s trenutnim tehnologijama.


Ovo procjenjuje periodičnost i količinu gnojiva koje treba osigurati u procesu navodnjavanja i gnojidbe na temelju agronomskih metoda i prikupljenih podataka o temperaturi i vlažnosti tla i atmosfere. DSS je integriran s desktop platformom koja se koristi na nekoliko uređaja, kao što su računari, mobilni računari (laptopi), mobilni telefoni ili tableti, a korisnici mogu pratiti i upravljati aktivnostima fertirigacije. Ovaj pametni sistem optimiziran je za izračun količine vode i hranjivih tvari potrebnih biljci. Sistem kalibrira raspored navodnjavanja i količine gnojiva koje će se koristiti u fazama navodnjavanja i gnojidbe na temelju agronomskih modela i podataka senzora. Sistem je inovativan i vrlo funkcionalan za preciznu fertirigaciju jer koristi elektroničke ploče za obradu podataka i mreže bežičnih senzora (WSN) povezanih s udaljenom softverskom platformom. Predloženi sistem prima informacije vezane za parametre zraka, tla i biljaka putem prilagođenog WSN-a koji može biti napajan električnom energijom ili solarno preko solarnog panela. Kontrolna jedinica obrađuje prikupljene podatke korištenjem dinamičkih agronomskih modela implementiranih na platformi u iCloud-u (oblaku), za optimizaciju količine i tipologije gnojiva kao i učestalosti navodnjavanja, kao i funkcije vremenske prognoze dobivene putem on-line vremenske usluge (Visconti, 2020). Sve ovo omogućava da se sistem automatski može sam uključivati i isključivati, ovisno o stanju i potrebama tla i biljaka za vodom i hranivima. Sistem fertirigacije automatski razrađuje potrebe usjeva za vodom i prikuplja povijesne podatke i podatke u stvarnom vremenu. Učinkovito iskorištavanje vode i gnojiva postiže se uz pomoć automatskog sistema gnojidbe za navodnjavanje usjeva uzimajući u obzir potrebe biljaka i tla. Dizajniran je i razvijen sa sposobnošću inteligentnog donošenja odluka u pogledu navodnjavanja usjeva na temelju ETc-a uzimajući u obzir faktore kao što su vrsta usjeva, stadij rasta, vremenski podaci i uslovi, vlažnost, temperatura te podatke sa senzora tla i biljaka. Ovakav pametni sistem fertirigacije sastoji se od fizičkih modula koji se električno ili solarno napajaju i računarske infrastrukture povezane internet vezom za automatsko upravljanje fizičkim modulima. Zahvaljujući ovakvoj arhitekturi cijelog sistema i informatičkoj infrastrukturi, moguće je kontrolisati i aktivirati faze fertirigacije u skladu s vrstom usjeva i njihovom fazom rasta i razvoja, stvoriti istoriju operacija i dijeliti podatke korištenjem sistema za praćenje uslova u okruženju. Kako cijeli sistem funkcionira najbolje je prikazano na slici 8.



Slika 8. Struktura i način funkcionisanja pametnog sistema fertirigacije
(Izvor: <https://www.mdpi.com/2073-4395/12/5/1012>).

Kao što se može vidjeti iz gore navedene slike, sistem funkcioniše tako što koristi podatke o vremenskim prilikama koje dobiva sa mjernih senzora, podataka koje korisnik treba da unese, podatke o vrsti biljke, njenim osobinama i zahtjevima kao što su npr. zahtjevi za NPK hranivima, zatim podatke o tlu i biljkama u polju (kao što je npr. podatak o vlažnosti lista). Ovi podaci se također dobivaju putem senzora.

Na tržištu postoji više različitih sistema fertirigacije sa manjim ili većim stepenom preciznosti distribucije vode i hraniva. Ova preciznost zavisi prije svega od vrste i broja dijelova koji čine sam sistem odnosno njegovu arhitekturu. Sljedeća slika (br. 9) pokazuje sličan sistem i njegovu arhitekturu kao u prethodno opisanom slučaju.



Slika 9. Arhitektura i način funkcionisanja pametnog sistema za fertirigaciju (Izvor: <https://hr.yby-irrigation.com/drip-irrigation-system/drip-fertigation-system.html>)


Prednosti ovog sistema za korištenje gnojiva i gnojidbu ogledaju se dugoročno u:

- smanjenim troškovim,
- u preciznom i efikasnom doziranju vode i gnojiva zasnovanom na stvarnom stanju istih u tlu i potrebama biljaka za vodom i hranivima,
- kontrola cijelog procesa fertirigacije može se pratiti sa bilo kojeg mjesta u svijetu korištenjem internet veze i tako značajno štedjeti na vremenu, radnoj snazi i slobodi pristupa podacima.

Sličan ovom opisanom smart sistemu fertirigacije, nabavljen je i instaliran smart sistem fertirigacije na oglednom poligonu Butmir Poljoprivredno-prehrambenog fakulteta (PPF) u Sarajevu, kao dio opreme u okviru EU4Agri projekta. Poljoprivredno-prehrambeni fakultet je 2022. godine prijavio projekat pod nazivom „Pametni sistemi u poljoprivredi-odgovor izazovima 21. stoljeća“, na osnovu objavljenog javnog poziva UNDP u Bosni i Hercegovini, a u okviru EU4Agri projekta za dodjelu bespovratnih sredstava za mjeru podrške jačanju poljoprivredne prakse kroz povezivanje sa naučnim i istraživačkim organizacijama. Projekat je nakon evaluacije stručnog osoblja UNDP-a pozitivno ocijenjen i odobren za finansiranje. Tokom 2024. godine sva oprema koja je planirana u ovom projektu, a čija je ukupna vrijednost cca. 350.000 KM je nabavljena, instalirana i puštena u funkciju. Dio opreme nabavljene kroz ovaj projekat, a koji se odnosi na pametni (smart) sistem fertirigacije, je prikazan na slikama ispod.



Slika 10 i 11. Tank za vodu




Slika 12. Tank A i B za rastvor gnojiva



Slika 13. Centralna jedinica



Slika 14. Meteorološka stanica za mjerenje meteoroloških (vremenskih) podataka



Slika 15. Razvodnik sa ventilima za varijabilnu fertirigaciju po zonama (Zona 1, 2, 3, 4.)

Osnovni ciljevi u ovom projektu bili su:

- Doprinos uspostavljanju i jačanje saradnje između Poljoprivredno-prehrambenog fakulteta u Sarajevu i organizacija koje interesno ili ekonomski povezuju poljoprivredne proizvođače u Bosni i Hercegovini i šire, sa ciljem uspostavljanja efikasnog i održivog sistema prenosa novih informacija, znanja i tehnologija u poljoprivrednu praksu.
- Doprinos rješavanju određenih problema u primarnoj poljoprivrednoj proizvodnji i preradi kroz naučno-istraživački rad i rezultate rada do kojih se došlo realizacijom ovog projekta,
- Doprinos stabilizaciji i jačanju konkurentnosti i povećanju nivoa produktivnosti primarne poljoprivredne proizvodnje i prerade poljoprivrednih proizvoda u BiH, kroz modernizaciju i uvođenje novih tehnologija i stvaranje dodane vrijednosti poljoprivrednih proizvoda,
- Učiniti poljoprivredni sektor otpornijim na klimatske promjene primjenom novih znanja, vještina i tehnologija. Na takav način uticati na ublažavanje posljedica klimatskih promjena,
- Popularizacija upotrebe pametnih tehnologija u poljoprivrednoj proizvodnji kao odgovor izazovima poljoprivrednog sektora 21. stoljeća,
- Potaknuti mlade da se kroz upotrebu pametnih i modernih tehnologija u većem broju uključe u svijet poljoprivrede,
- Primjena rezultata naučnih istraživanja u primarnoj poljoprivrednoj proizvodnji.



Slika 16. Ogledne parcela sa usjevom kukuruza u kojem su ispitivani uticaji različitih normi zalijevanja i različitih varijanti gnojidbe (Ispitivanja su bila dio projektnih zadataka)



Slika 17. Ogledna parcela sa kukuruzom na kojoj je proveden eksperiment sa gnojidbom i navodnjavanjem pomoću tifona (Slike:11-18; Izvor: H. Čivić)

U ovom projektu, između ostalog, zadatak je bio da se uz pomoć pametnih sistema za navodnjavanje i gnojidbu-ishranu biljaka utvrditi efikasnost i učinkovitost ovih sistema u odnosu na konvencionalne, koji se najčešće koriste u praksi. Poljski ogledi su provedeni na kulturama jabuke i kukuruza.

Treba istaći, da ovo nisu jedini izazovi sa kojima se poljoprivreda suočava u posljednje vrijeme. Tu su svakako sve prisutniji izazovi vezani za klimatske promjene, kao što su: suše, poplave, mraz, erozija tla i drugi oblici degradacije tla. Osim ovih, treba spomenuti još: nisku poljoprivrednu produktivnost, konvencionalni sistem primjene gnojiva, sve učestaliji faktori koji izazivaju fiziološke stresove kod biljaka, visoka cijena gnojiva, itd. Za sve navedene izazove današnja poljoprivreda mora imati adekvatne odgovore i rješenja. Na većinu navedenih izazova može se u velikoj mjeri uticati gnojidbom.

Zbog svega navedenog, trendovi primjene gnojiva u 21. stoljeću, se osim opisane precizne ili pametne fertirigacije bazirani još i na: lokalnoj primjeni gnojiva, nanotehnologijama, gnojivima novije generacije posebno onim koja su ekološki prihvatljiva, biostimulirajuća gnojiva, a sve s ciljem poticanja održive poljoprivrede prakse. Osim ovih načina, veća učinkovitost gnojiva i gnojidbe se može postići korištenjem i nekih drugih mjera kao što je upotreba novih i adaptabilnih kultivara biljaka za određena područja. Tako npr. kod izbora kultivara, treba preferirati one koji imaju razvijeniji korijenov sistem, zatim kultivare koji omogućavaju simbiotske aktivnosti između korijena i korisnih mikroorganizama (mikoriza i sl.). Zatim, to su i kultivari sa pojačanim lučenjem korijenovih eksudata, te kultivari sa određenim fiziološkim promjenama koje doprinose smanjenim metaboličkim potrebama za hranivima i promjene u mehanizmu njihovog prenošenja. Također, danas postoje i kultivari koje imaju mogućnost da pomoću korijena prenose vodu iz dubljih slojeva tla do površine tla, što povećava topivost i pristupačnost hranjivih tvari.

Učinkovitost gnojidbe se može značajno popraviti i tačnijim-preciznijim načinima obračuna doza gnojiva. Takav je slučaj npr. sa drugačijim načinom obračuna gnojidbe sa fosforom u odnosu na dosadašnje prakse. Fosfor je postao ograničavajući prirodni resurs, a sa druge strane biljke ga ne trebaju ni blizu spram količina koje se obično kroz gnojidbu dodaje. Prema procjenama Bingham (1963), a na osnovu izračuna indeksa lisne površine, potrebe biljaka za fosforom su oko 7,2 kg/ha. Ova količina fosfora je puno manja u odnosu na uobičajene koje se unose putem gnojiva. Zbog toga postoji puno prostora da se radi i istražuje, posebno na polju oplemenjivanja biljaka u kontekstu moguće racionalnije upotrebe fosfora. Također, kod obračuna azotne gnojidbe postoji više načina obračuna, od kojih treba svakako koristiti one koji uzimaju u obzir više faktora.

Primjena biostimulirajućih gnojiva kao nove strategije za pospješivanje rasta biljaka i boljeg usvajanja hraniva dobiva sve više na značaju. Biostimulansi mogu, ovisno o osobinama tla i klime, poboljšati pristupačnost hranjivih elemenata u tlu. Biostimulansi mogu sadržavati neke vrste mikroorganizama, kao što su bakterije i/ili gljivice, zatim neke aktivne prirodne tvari, ekstrakte iz tla, komposta ili morskih algi. Gnojiva na bazi biostimulatora tako mogu da poboljšaju uslove u tlu za bolju ishranu biljaka. Tako npr. mikroorganizmi dokazano pozitivno utiču na dostupnost i apsorpciju fosfora, širenjem korijenovog sistema kroz mikorizne asocijacije između korijena biljaka i hifa gljivica. Isto tako, korijenove izlučevine-eksudati doprinose boljem otapanju fosfata u tlu, i tako dovode do bolje dostupnosti fosfora biljkama. Najviše opisanih bakterijskih biostimulatora pripadaju različitim sojevima *Bacillus* i *Pseudomonas*. Bakterijski biostimulatori temeljeni na rodu *Pseudomonas* sastavni su dio mnogih biognojiva, a njihova upotreba zajedno s mineralnim gnojivima

pospješuje njihovu učinkovitost i općenito pruža bolje uslove za ishranu biljaka. *Pseudomonas* pospješuje rast biljaka, otapanje fosfora u tlu i biološku fiksaciju azota. Također, postoje rezultati istraživanja koja pokazuju da može da oslobodi jedan dio Fe i Zn iz teško dostupnih oblika. Neke druge bakterije u tlu, kao što je *Bacillus amyloliquefaciens* može lučenjem svojih enzima (hitinaza, peroksidaza ili proteaza i fosfataza) u tlu da poboljša uslove za dostupnost nekih biljnih hraniva ili lučenjem nekih antibiotika (bacilomicin, fengicin ili difcudin) da zaštiti biljke od nekih patogena i bolesti.

Od gljivičnih biostimulanasa do sada su najviše istraživani kod sojeva gljivica *Trichoderma*, *Penicillium* i *Rhizophagus* (ranije poznati kao *Glomus*). Rod *Trichoderma* obuhvaća nitaste gljive koje se pojavljuju u većini tipova tala i različitim staništima, a neki sojevi su uspješno testirani kao biognojiva. Djeluju protiv širokog spektra biljnih patogena. Ove gljive pospješuju rast i razvoj biljaka, kao i razvoj korijenovog sistema. Određeni sojevi *Trichoderma* mogu poboljšati unos hranjivih tvari u biljke. Do povećanog rasta također dolazi zbog njegove snažne antipatogene aktivnosti, biosinteze hormona, poboljšanja unosa hranjivih tvari iz tla i razvoja korijena povećanjem brzine metabolizma ugljikohidrata i povećane fotosinteze. Gljivica *Penicilium bilalli*, također živi u simbiozi sa korijenom biljaka koje otpuštaju fosfate u tlu. Uspješno se koristi kao inokulant sjemena za razne usjeve, npr. pšenicu, kukuruz, uljanu repicu, grah, soju i druge mahunarke. Ovaj biostimulans podupire solubilizaciju mineralnog fosfata i poboljšava unos fosfora iz biljaka zbog proizvodnje kiselih metabolita, kao što su limunska i oksalna kiselina.

U biostimulante se ubrajaju brojni ekstrakti različitog porijekla. Uglavnom su to ekstrakti morskih algi ili komposta. Ekstrakti morskih algi naširoko se koriste kao dopune u sistemima proizvodnje usjeva zbog prisutnosti hranjivih tvari i drugih spojeva koji potiču rast biljaka (aminokiseline, vitamini, citokinini, auksini i apscizinska kiselina). Zabilježeno je, da stimuliraju rast biljaka i prinos, povećavaju otpornost na okolišni stres, povećavaju unos biljnih hraniva, pojačavaju antioksidativna svojstva i povećavaju otpornost protiv širokog spektra patogenih virusnih, bakterijskih i gljivičnih bolesti, kao i protiv napada insekata. Najpoznatija i najkorištenija alga je *Ascophyllum nodosum*. Pored ovih u praksi se dosta koriste i sintetički biljni hormoni u cilju postizanja boljeg rasta i razvoja biljaka (Murtić *et al.*, 2015).

Ipak, treba reći da se većina ispitivanja uticaja biostimulanasa provodila na biljkama koje su uzgajane u kontrolisanim uslovima u laboratorijama i da je njihov učinak i djelovanje ipak manji kada se koriste u prirodnim uslovima u polju. Razlozi za njihov manji učinak u prirodnim uslovima odnose se na prisustvo drugih mikroorganizama u tlu i njihova konkurencija, promjenljivi vremenski uslovi u odnosu na laboratorijske i drugačiji uslovi i osobine tla u odnosu na one iz kojih je mikroorganizam izoliran. Zbog svega ovoga, značaj biostimulatora u praksi je vrlo često precijenjen, prije svega od strane proizvođača, jer je njihov glavni cilj prodati svoj proizvod. Ono što je sigurno, jeste, da postoji dobar potencijal u biostimulatorima za koje treba naći načine kako taj potencijal najbolje iskoristiti. Taj potencijal se najbolje pokazao u zaštiti biljaka i to kada se biostimulatori nanose preko lista, a ne preko tla. Također, biostimulatori su dali bolje rezultate kod primjene u zaštićenim prostorima nego na otvorenom polju, kod dorade sjemena i kod lokalne primjene.

Standardne strategije i tehnologije gnojidbe tla često nisu dovoljno učinkovite zbog imobilizacije hraniva iz tla i velikih gubitaka hraniva ispiranjem, isparavanjem, denitrifikacijom, fiksacijom i retrogradacijom. Zbog svega navedenog, kod konvencionalnog načina gnojidbe iskoristivost hraniva iz gnojiva je vrlo slaba. Već smo ranije spominjali da je iskoristivost fosfora u ovakvim slučajevima

10-20%, a azota i kalija od 30 do 60%. Ovo često dovodi do primjene visokih doza gnojiva uz ekološke probleme, odnosno zagađenje voda, zraka i hrane, uzrokujući ozbiljne prijetnje zdravlju ljudi i stoke. Zato se traže novi načini i strategije za poboljšanje učinkovitosti gnojiva, kako bi se gubici hraniva i doze gnojiva značajno smanjile. Velika očekivanja u tom smislu su vezana za novu, naprednu bionanotehnologiju koja nudi određena rješenja za brojne izazove. Nanotehnologija je metoda koja nudi veće mogućnosti za bolje zadržavanje vode u tlu i podržavanje bioraspoloživosti hranjivih tvari. Ona nudi različite nanomaterijale ili nanostrukture različitih dimenzija i veličina u rasponu od 1 do 100 nm koji se mogu koristiti kao nanognojiva. Ona mogu biti različitog porijekla, ali su im fizikalno-hemijska svojstva jedinstvena kao npr, visok omjer površine i volumena, penetrabilnost, reaktivnost, topljivost, te brža i veću sposobnost translokacije u različite dijelove biljaka što ih čini prikladnijima za primjenu. Nanotehnologija je također prepoznata kao jedna od šest «ključnih tehnologija» ili «nano-ere» koje pridonose održivom rastu i razvoju.

Nanočestice se mogu izraditi od različitih materijala, kao što su biološki agensi (gljive, bakterije, kvasci i biljni ekstrakti), poluvodiči, metalni oksidi, polimeri, keramika i poljoprivredni ostaci, korištenjem pristupa odozgo prema dolje, smanjenjem velikih dimenzioniranih materijala do nivoa nanoveličina i pristupa odozdo prema gore, dodavanjem malih nivoa atoma i molekula do formiranje jezgri i veličina nanočestica. Primjena nano tehnologije u proizvodnji gnojiva je novi i vrlo inovativni pristup koji omogućuje kontrolirano oslobađanja hranjivih tvari u tlo, čime se postiže pravovremeno i ravnomjerno snabdijevanje biljaka hranivima u dužem vremenskom periodu. Ovakve mogućnosti nanognojiva značajno povećavaju njihovu učinkovitost u odnosu na konvencionalna mineralna gnojiva. Hraniva u nanognojivima mogu biti inkapsulirana tj. omotana tankim zaštitnim filmom i izmjenjivo vezana različitim nano poroznim materijalima. Mogu sadržavati, osim biljnih hraniva, i druge materije kao što su: bakterije, gljivice, pesticide, biljne hormoni. Također, nanognojiva mogu biti u vidu emulzija za folijarnu primjenu, mogu uključivati ugljikove nanocjevčice (alotropska su modifikacija ugljika čiji su atomi u strukturi pčelinjeg saća), koje lako prodiru u sjeme i utječu na njegovu bolju klijavost kao i brži porast klijanaca i mladih biljaka. Inkapsulacija korisnih mikroorganizama može povećati dostupnost u zoni korijena N, P i K iz rezervnih, trenutno nepristupačnih hraniva, čime se poboljšava rast biljaka. Nanočestice mogu biti različitog porijekla, a vrlo često se koriste jeftiniji prirodni minerali kao što su: nanogline, odnosno aluminijevi silikati u višeslojnim česticama veličine oko 10 nm, nusprodukti mehaničkih ili industrijskih procesa izgaranja i isparavanja različitih materijala. Tako npr. minerali hidroksiapatita ($\text{Ca}_{10}(\text{PO}_4)_6(\text{OH})_2$), imaju visok omjer površine i volumena, te mogu vezati na sebe veliku količinu elemenata i drugih tvari jer posjeduju izvrsnu biokompatibilnost. Nanohibridi hidroksiapatita s ureom (nanoinkapsulirana gnojiva) izvrsna su kao „sporo djelujući izvor azota”, zatim termoplastični skrob/urea koji također sporije otpušta ureu uz smanjeno isparavanje amonijaka (NH_3) u usporedbi s čistom ureom. Tako nanognojiva mogu kontrolirano (u određeno vrijeme, polahko ili brzo) ili pod utjecajem promjene pH tla, vlage, korijenskih izlučevina, temperature itd., oslobađati hraniva i tako ubrzati rast biljaka znatnije od konvencionalnih gnojiva, te se ubrzano razvijaju nova i pametna nanognojiva za primjenu preko korijena ili folijarno. Folijarna gnojiva se vrlo često smatraju učinkovitijim načinom gnojidbe, prije svega zbog reklamnog uticaja proizvođača tih gnojiva. Ipak se mora reći da ona imaju i niz nedostataka, a to su da se preko lista može unijeti relativno mala količina aktivne tvari, jer veća količina izaziva oštećenje lista pa i mogućnost njegovog uginuća. Neujednačena mogućnost unosa i transporta (translokacije) hraniva preko lista je drugi vrlo značajan nedostatak. Poznato je da neka hraniva se lakše i brže usvajaju i premještaju putem floema (bazipetalno), a neka vrlo

slabo poput Ca i B. Mnogi elementi ishrane se teško usvajaju preko lista zbog prekrivenosti lišća i plodova kutikulom (mrtva lipoidna membrana iznad epidermisa), koja najčešće sadrži kutin s ugrađenim epikutikularnim voskovima zbog kojih kapljice otopine skliznu s lista ili ploda, pa je potrebno primjenjivati tvari za bolje prijanjanje otopine uz list i brže usvajanje (surfaktanti, tenzini, penetratori, aktivatori, humektanti i drugi aditivi). Navedeni su samo neki od problema vezanih uz folijarnu gnojdbu koje bi trebala riješiti primjena nanognojiva. Nanotehnologija je polje koje se veoma brzo razvija i ima potencijal revolucionirati prehrambene sisteme, ali objektivno, ona zahtijeva puno znanja, složenu visoku tehnologiju tzv. nanoinžinjeru u proizvodnji i primjeni.

Kao izvor hraniva za biljke mogu da se koriste i razne vrste otpada. Jako mali dio otpada se reciklira, a još manje kompostira. Organski otpad ima značajan potencijal da se koristi kao gnojivo, najčešće kao kompost nakon kompostiranja. Međutim, organski otpad je moguće pretvarati u gnojiva i na druge načine kao što je anaerobni način razgradnje, spaljivanjem ili pirolizom. Piroliza je toplinska razgradnja organskog materijala pri povišenoj temperaturi u odsustvu kisika. Postupkom pirolize se proizvodi biougljen, koji se također može koristiti kao organsko gnojivo, koje u značajnoj mjeri popravljja fizička, hemijska, a posebno biološka svojstva tla. Spaljivanjem organske materije nastaje pepeo koji se također može koristiti kao gnojivo sa odličnim izvorom skoro svih biljnih hraniva, osim organogenih elemenata (C, H, O, N, S) koji su nestali u postupku spaljivanja organske materije u vidu gasova. Korištenje svježeg neobrađenog komunalnog mulja kao gnojiva je uglavnom ograničeno zbog sadržaja materija opasnih po zdravlje ljudi i okoliš. Jedan od načina obrade komunalnog mulja je njegovo kompostiranje ili spaljivanje do pepela. Spaljivanjem organske materije u pepelu uništiće se potencijalno patogeni mikroorganizmi, ali i dalje će zaostati potencijalno opasne materije poput teških metala.

Kao opšti zaključak vezan za navedene strategije gnojidbe, može se reći da samo kombinacijom navedenih strategija, ishrana bilja može postići dugoročnu održivost.

U Bosni i Hercegovini od svih spomenutih strategija i načina gnojidbe, ako se izuzme konvekcionalni način, najviše se praktikira fertirigacija. Zbog toga će se u nastavku ovog poglavlja govoriti o fertirigaciji kao načinu gnojidbe, gnojivima koja se koriste za fertirigaciju i dati neki primjeri gnojidbe putem fertirigacije.

Fertirigacija

Fertirigacija je metoda gnojidbe, kojom se kroz sistem za navodnjavanje kakav je npr. sistem „kap po kap“, zajedno sa vodom dodaju i gnojiva. Glavna prednost dodavanja gnojiva putem fertirigacije u odnosu na klasični-konvekcionalni, jeste u većoj učinkovitosti primijenjenih gnojiva i postizanju većih prinosa biljaka. Fertirigacijom se biljna hraniva direktno dostavljaju u zonu korijena, čime se minimaliziraju gubici skupih hranjivih tvari, racionalno troši voda za navodnjavanje, što u konačnici pomaže u poboljšanju produktivnosti i kvalitete poljoprivrednih proizvoda i smanjuje rizik od onečišćenja okoliša. Ona zahtijeva specifičnu opremu, ovisno o vrsti usjeva i sistemu navodnjavanja, te jasan odabir odgovarajućeg gnojiva i njegovih kombinacija. Hranjive otopine ubrizgavaju se u vodu za navodnjavanje pomoću odgovarajućeg uređaja za ubrizgavanje pod pritiskom, kao što su kap po kap. Raspršivači i mikro raspršivači dobro su prikladni za fertirigaciju. Za razliku od ovih sistema ubrizgavanja hraniva pod pritiskom, gnojiva primijenjena s otvorenim sistemom navodnjavanja, mogu dovesti do neravnomjerne raspodjele hraniva u polju. U sistemu fertirigacije vrijeme, količina, koncentracija i omjer hranjivih tvari lako se mogu kontrolisati, pa su zbog toga prinosi i kvalitet biljaka veći od onih dobivenih klasičnom primjenom gnojiva.

Prvi tehnološki savremeniji sistem fertirigacije počeo se primjenjivati 1960-tih godina u Izraelu, sa razvojem i uvođenjem mikronavodnjavanja. Električne pumpe i spremnici za miješanje razvijeni su za preciznu primjenu hranjivih tvari. U početku je raspodjela hranjivih tvari fertirigacijom bila relativno neravnomjerna kada su se koristili samo spremnici za gnojiva. Kasnije je postignuta ravnomjernija raspodjela kada su se koristile venturi usisne pumpe i injektori za gnojivo. Daljnja značajna poboljšanja postignuta su potpuno kompjuteriziranim jedinicama za fertirigaciju. Zbog toga fertirigacija, kao metod unošenja hraniva zajedno sa vodom, omogućava značajno veću učinkovitost primjene gnojiva u odnosu na klasični sistem dodavanja gnojiva u tlo. U tabeli 3. prikazana je učinkovitost korištenja NPK gnojiva s različitim metodama njegove primjene.

Tabela 3. Učinkovitost NPK gnojiva ovisno o metodama korištenja (Fertilizer Marketing News, 2010)

Hraniva tvar	Površinsko navodnjavanje + primjena gnojiva u tlo	Kap po kap - bez gnojiva	Kap po kap - fertirigacija
Azot	30-50	65	95
Fosfor	20	30	45
Kalij	50	60	80

Iz tabele se može vidjeti i zaključiti da nije opravdano provoditi navodnjavanje samo bez gnojidbe. Odnosno, fertirigacija kao način gnojidbe ima najveći stepen iskorištenosti hraniva iz gnojiva u odnosu na razdvojeni sistem navodnjavanja drip (kapanje) bez gnojidbe, odnosno, gdje se gnojidba provodi posebno izvan sistema navodnjavanja. Razlika je još veća u usporedbi fertirigacije i sistema površinskog navodnjavanja i primjene gnojiva u tlo. Tako je npr. kod ova dva sistema iskorištenost azota iz gnojiva, kod sistema površinskog navodnjavanja i gnojidbe koja se prethodno izvodi unošenjem gnojiva u tlo 10-50%, a u sistemu fertirigacije 95%. Ovi podaci jasno govore da fertirigaciju kao način gnojidbe treba koristiti gdje god je to moguće. Osim visokog stepena učinkovitosti gnojiva, zbog visoke dostupnosti hraniva izazvane vlažnošću tla u zoni korijena, prednosti fertirigacije se ogledaju i u sljedećem:

- minimalni su gubici hraniva u odnosu na klasični sistem gnojidbe,
- gnojidba u vidu prihrane se može često da provodi ovisno o potrebama biljaka,
- manja potrošnja gnojiva, značajna ušteda rada i energije.

Fertirigacija ima i svoje manjkavosti, a one se odnose na:

- zahtijeva specifična gnojiva koja moraju biti vodotopiva i čista,
- postoji određena nekompatibilnost između pojedinih gnojiva odnosno hraniva pri njihovom miješanju (npr. Ca i Mg sa fosfatima i sulfatima ili fosfati sa nekim mikrohranivima),
- oprema za fertirigaciju treba biti otporna na koroziju,
- visoki početni troškovi za nabavku i instalaciju fertigacionog sistema,
- potreban stalni radni pritisak kako bi se omogućilo ravnomjerno miješanje vode i gnojiva.

Vrste (metode) fertirigacije


Postoje četiri vrste fertirigacije i to kvantitativna, proporcionalna, kontinuirana i primjena u tri faze. Kod svih metoda zajedničko je to da se otopine gnojiva unaprijed pripremaju u tankovima ili spremnicima. Razlika među njima je u načinu ubrizgavanja otopina gnojiva u sam sistem za fertirigaciju. Koja vrsta fertirigacije će se primijeniti zavisi prije svega od vrste fertigacione opreme sa kojom raspolazemo, o vrsti kulture koja se uzgaja i vrsti i osobinama tla na kojem se fertirigacija izvodi.

- a) Kvantitativna fertirigacija. Ovaj tip fertirigacije ima mogućnost podjele fertigacionih površina na zone, tako da svaka zona fertirigacije prima određenu dozu hranjive otopine na temelju svojih individualnih potreba. Tako npr. zona A prima 15 litara, a zona B 30 litara. Ova vrsta fertirigacije podložna je automatizaciji i pruža potpunu kontrolu upravljanja kuda i gdje idu hranjive tvari.
- b) Proporcionalna fertirigacija. Kod ovog modela fertirigacije otopina gnojiva se pomoću odgovarajućih uređaja, injektora i pumpi, ubrizgava u stalnom i proporcionalnom omjeru protoka vode za navodnjavanje, tako da voda za navodnjavanje uzima fiksnu koncentraciju primijenjenog gnojiva. Tako npr. 1 litra otopine gnojiva se ubrizgava i umiješa u 1000 litara vode za navodnjavanje. Ovaj pristup ima prednost jer ga je lako implementirati i može pospješiti fertirigaciju tokom perioda intenzivnog unosa vode. Prednost se ogleda i u mogućnosti precizne kontrole, količine i momenta injektiranja, a nedostaci su visoka cijena, održavanje i kompliciran rad.
- c) Kontinuirana fertirigacija. Od početka do kraja procesa fertirigacije, gnojivo se primjenjuje ravnomjerno. Kompletan doza gnojiva se ubrizgava bez obzira koliko brzo voda teče.
- d) Fertirigacija primjene u tri faze. Ovaj model fertirigacije se odvija u fazama. Na početku navodnjavanja gnojiva se ne dodaju. Injektiranje gnojiva počinje kada tlo upije dovoljno vode i prestaje prije završetka ciklusa navodnjavanja. Treća faza je ponovo faza navodnjavanja bez gnojiva, koja obično služi i vremenski traje toliko da omogućiti da se hraniva mogu isprati iz sistema i da ne ostanu na površini tla, nego da se vodom za navodnjavanje mogu unijeti do zone korijena biljaka.

Za sve navedene modele fertirigacije potrebna je odgovarajuća oprema kako bi sistem optimalno funkcionirao. Ključni dio cijelog sistema fertirigacije predstavlja oprema za ubrizgavanje gnojiva (injektori). Odabir ispravne opreme za ubrizgavanje jednako je važan kao i odabir ispravne hranjive tvari (gnojiva). Pritisak ubrizgane otopine gnojiva mora biti veći od unutaršnjeg pritiska glavnog voda. Sistem filtera također mora postojati kako bi se spriječilo začepljenje kapaljki bilo kakvim čvrstim česticama otopine gnojiva koje bi dospjele do kapaljke. Također je potreban ventil za sprječavanje povratnog toka kako bi se spriječio povratni tok gnojiva-hemikalija u izvor vode. Kada je riječ o načinu ubrizgavanja hranjive otopine u fertirigacioni sistem, postoje tri vrste injektora pa tako i tri vrste ubrizgavanja-injektiranja hranjive otopine:

a) Injektiranje zasnovano na razlici pritiska (obilazni spremnik)

Ovaj sistem radi na principu razlike pritiska koji reguliše ventil pritiska. Razlika u pritisku tjera vodu da ulazi kroz zaobilaznu cijev u spremnik pritiska koji sadrži gnojivo i da ponovno izlazi, noseći različite količine otopljenog gnojiva (Sl. 18). Primjena hraniva je kvantitativna i neprecizna, što se može vidjeti na slici ispod. Na grafikonu 1. se jasno vidi da sa vremenom koncentracija hraniva u sistemu drastično opada, te se na ovakav način na početku fertirigacije distribuira znatno više hraniva u odnosu na vrijeme pred kraj. Ovaj sistem je prilagođen višegodišnjim nasadima poput voćaka.



Slika 18. Sistem injektiranja zasnovan na razlici pritiska (obilazni spremnik) Graf. 1. Koncentracija hranjivog rastvora ovisna o vremenu (Izvor: <https://www.slideshare.net/kaushalgadariya/fertigation-in-micro-irrigation-kvg>).

Prednosti ovog sistema su:

- jednostavan za rukovanje,
- osnovna otopina se ne mora prethodno miješati,
- lahko se postavlja i zahtijeva vrlo malo održavanja,
- jednostavna izmjena gnojiva,
- idealan za suhe formulacije,
- nije potrebna električna energija ili gorivo da bi sistem funkcionisao.

Nedostaci su:


- spremnik mora moći izdržati pritisak u cjevovodu za navodnjavanje,
- koncentracija otopine se smanjuje kako se gnojivo otapa,
- tačnost primjene je ograničena,
- gubitak pritiska u glavnom vodu za navodnjavanje,
- proporcionalna fertirigacija nije moguća,
- ograničeni kapacitet,
- automatizacija sistema nije moguća.

b) Vakuumsko ubrizgavanje (Venturi)

Temelji na principu venturijeve cijevi. Potrebna je razlika pritiska između ulaza i izlaza injektora što uzrokuje smanjeni pritisak (vakuum) koji usisava otopinu gnojiva u cjevovod. Sistem funkcionisanja venturija je prikazan na slici 19.

Prednosti ovog sistema su:

- vrlo jednostavan za rukovanje,
- jednostavan za postavljanje i održavanje,
- ubrizgavanje se može kontrolirati mjernim ventilom,
- podesan za proporcionalnu i za kvantitativnu fertirigaciju.




Slika 19. Sistem Venturi injektiranja i Graf. 2. Koncentracija hranjivog rastvora ovisna o vremenu
(Izvor: <https://www.irrigationking.com/>)

- Nedostaci su: gubitak pritiska u glavnom vodu za navodnjavanje,
- kvantitativna fertirigacija je otežana,
- automatizacija otežana,
- vrlo osjetljiv na promjene pritiska.

c) Ubrizgavanje pumpom

Pumpe se koriste za ubrizgavanje otopine gnojiva iz opskrbnog spremnika u cjevovod (Sl. 20). Energiju ubrizgavanja osiguravaju elektromotori ili hidraulični motori.



Slika 20. Sistem injektiranja pumpom i Graf. 3. Koncentracija hranjivog rastvora ovisna o vremenu
(Izvor: https://agritech.tnau.ac.in/agriculture/sugarcrops_sugarcane.html)

Prednosti ovog sistema su:

- vrlo precizan za proporcionalnu fertirigaciju,
- nema gubitka pritiska u cjevovodu,
- lahko prilagođen za automatizaciju.

Nedostaci su:

- visoka cijena,
- komplicirana konstrukcija uključujući i niz pokretnih dijelova,
- dijelovi se brže troše i vjerojatniji su kvarovi.

d) Automatizovani sistemi fertirigacije

Na tržištu su danas prisutni i automatizovani sistemi fertirigacije. Ovaj sistem se zasniva na prethodnom načinu ubrizgavanja hranjivih otopina, tj pomoću pumpe. Tako npr. poznata talijanska firma IRRITEC na tržištu nudi ovakva rješenja koja kombinuju praktičnost i pouzdanost sa modernim sistemom ubrizgavanja hranjivih otopina. Upravljanje gnojivom regulirano je jednostavnim receptima za fertirigaciju koji se mogu postaviti prema agronomskim/nutritivnim potrebama biljaka/usjeva. Shaker Pro (Sl. 21) je jedinica za ‘ciljnu, ali i proporcionalnu fertirigaciju’ koju je dizajnirao Irritec da ponudi precizan i pouzdan sistem fertirigacije.

Lahko programiranje i napredne funkcije Commander-a EVO programator, omogućava kompletno upravljanje sistemom za fertirigaciju, pri čemu osigurava ispravno dopremanje nutrijenata na osnovu pH i EC vrijednosti koje postavlja korisnik, ili na osnovu potrebnih procentualnih vrijednosti. Shaker Pro omogućava ubrizgavanje do 4 vrste otopina, proporcionalna gnojiva plus korekcijsku kiselinu. Jednostavan je za rukovanje. Za upravljanje podešenim vrijednostima unose se potrebne vrijednosti

pH i EC provodljivosti, kao i procenti rastvora gnojiva (npr. pH 6,0; EC 2 mS; 5% fert. A; 10% fert. B; 10% fert. C; 5% fert. D). Mašina će, koristeći informacije iz ugrađenih senzora pH i EC provodljivosti, ubrizgati ispravne količine kiseline i gnojiva potrebne za održavanje konstantne vode na vrijednostima koje je postavio korisnik. Za proporcionalno upravljanje, vrijednosti su postavljene za pH i procenat ubrizgavanja svakog gnojiva (npr. pH 6,0; 0,5% fert. A; 0,5% fert. B; 0,3% fert. C; 0,2% fert. D).



Slika 21. Shaker set automatske prihrane (Izvor: <https://atpdoo.rs/index.php/sistemi-za-navodnjavanje/automatski-sistemi-navodnjavanja/shaker-pro>)

Gnojiva i gnojidba

Gnojiva su drugi osnovni faktor i uslov za fertirigaciju. Prilikom odabira gnojiva za fertirigaciju treba uzeti u obzir nekoliko važnih osobina gnojiva namijenjenih za fertirigaciju.

- Vodotopivost gnojiva i osobine vode koja se koristi za fertirigaciju;
- Elektroprovodljivost otopina gnojiva koja se koriste i vode koja se koristi za fertirigaciju;
- pH vrijednost otopina gnojiva i vode koja se koristi za fertirigaciju.

Za fertirigaciju u ponudi se na tržištu nalaze brojna gnojiva. Zajedničko svim gnojivima bi trebalo da bude da su dobro vodotopiva i bez primjesa, odnosno da ne stvaraju talog koji bi mogao da dovede do začepjenja sistema za fertirigaciju i time izazove ozbiljne probleme. Proizvođači vodotopivih gnojiva nude različite sastave i formulacije ovih gnojiva. Ova osobina je vrlo važna kod izbora gnojiva i ona zavisi od više faktora: plodnosti, fizičkih, hemijskih pa i bioloških osobina tla na kojem se izvodi fertirigacija, vrste biljaka ili usjeva, fenofaze razvoja i stvarnih potreba biljaka za hranivima, vrste ili modela fertirigacije koja se primjenjuje kao i načina ubrizgavanja hranjive otopine u sistem, kompatibilnosti gnojiva za miješanje itd.

Kada je u pitanju hemijski sastav, najčešće vodotopiva gnojiva za fertirigaciju od komponenti sadrže: amonijev nitrat, urea amonijev nitrat, kalcijev nitrat, amonijev tiosulfat, kalijev hlorid, kalijev sulfat, kalijev nitrat, fosforu kiselinu, sumpornu kiselinu itd. Također, mogu da sadrže i mikroelemente obično u formi helata i/ili biostimulatore. Tako npr. bakterije *Thiobacillus* u

amonijevom tiosulfatu potpomaže u procesu otapanja karbonata i njegovog pretvaranja u gips, što poboljšava strukturu tla.

Izbor odgovarajuće formulacije gnojiva za fertirigaciju najviše ovisi o stanju hraniva i njihovom odnosu u tlu i fenofazi razvoja biljaka, kao i specifičnim zahtjevima pojedinih biljaka ili kultura za određenim hranivima. Opće je poznato da, ukoliko su prethodni uslovi optimalni i zadovoljeni, u početnim fazama razvoja biljkama treba obezbijediti više fosfora, pa se u tom smislu tada koriste formulacije NPK + ME vodotopivih gnojiva sa naglašenim sadržajem fosfora (P). Fosfor stimulira razvoj korijenovog sistema i značajan je u fazi formiranja generativnih organa biljaka, pa je u tim fenofazama razvoja biljaka vrlo značajan i tada bi trebalo pojačati ishranu sa ovim elementom.

S obzirom da azot, kao biljno hranivo ima uticaj na vegetativni prirast i formiranje mladih organa i tkiva, vodotopiva NPK + ME gnojiva sa izbalansiranim NPK odnosom, ili formulacije sa dominantnijim sadržajem azota ili pojedinačna azotna vodotopiva gnojiva kakvo je npr. $\text{Ca}(\text{NO}_3)_2$ ili $(\text{NH}_4)_2\text{SO}_4$ i slična, mogu se, i trebaju, koristiti u fenofazama biljaka kada se intenzivno odvija rast vegetativnih organa.

Kalij kao elemenat koji ima značajnu ulogu kod biljaka vezanu za poboljšanje kvaliteta plodova, njihov sastav, boju okus itd., treba ga dodavati kroz NPK + ME formulacije vodotopivih gnojiva u kojima dominira sadržaj kalija i to u fenofazama razvoja biljaka od formiranja plodova pa sve do njihovog sazrijevanja. U ovom periodu se mogu koristiti i pojedinačna vodotopiva gnojiva koja sadrže kalij kao što je npr. kalij nitrat (KNO_3), pri čemu treba voditi računa o ukupnom odnosu N i K koji će se dodati putem gnojiva, jer nepovoljan odnos azota i kalija u ishrani većine biljaka, pogotovo plodovitog voća i povrća, može da smanji njihov kvalitet.

Osim navedenih osobina kod izbora gnojiva treba voditi računa i o njihovoj topivosti, kompatibilnosti, kiselosti i slanosti (osmotskom pritisku).

Za fertirigaciju se mogu koristiti tečna gnojiva koja su već otopljena i čvrsta tzv. kristaloni vodotopiva gnojiva koja se prethodno moraju otopiti u vodi. Topivost predstavlja količinu gnojiva koja se može otopiti u 1 l destilirane vode, pri temperaturi 20 °C, prije nastanka taloga. Ova osobina se značajno razlikuje i ovisi o sastavu i formulaciji gnojiva. Topivost je važan parametar kod pripreme matične otopine, pogotovo u automatskim sistemima za fertirigaciju, gdje se primjenjuje koncentrovana matična otopina. Kao što se vidi, topivost gnojiva osim sastava zavisi i od temperature. Zato je važno uzeti u obzir i godišnje doba, jer će se stepen topivosti razlikovati u proljeće i ljeto. Osim toga, neka se gnojiva mogu istaložiti iz otopine kada se dodaju u visokim koncentracijama, tvrdoj vodi ili kada temperatura padne, npr. u hladnijoj sezoni ili hladnim noćima. Ovo treba uzeti u obzir kada se otopine unaprijed pripremaju i ostave da stoje. Taloženju su tako podložni monoamonijev fosfat, urea fosfat ili fosfatna kiselina. Za razliku od njih amonijev nitrat, kalijev nitrat, urea i amonijev fosfat su brzo vodotopiva gnojiva. Poznato je da sa porastom temperature topivost gnojiva raste. Tako je npr. topivost amonijevog nitrata dva puta veća kada se uspoređuju temperature od 0°C i 30°C. Kod 0°C topivost iznosi 1183 g/L, a na 30°C 2420 g/L. To znači da će se u istoj količini vode otopiti veća količina hranjivih tvari.

Međutim, postoji još jedan važan aspekt koji treba imati na umu. Otopine za sistem fertirigacije mogu biti endotermne ili egzotermne, odnosno, temperatura otopine se ili smanjuje ili povećava u procesu otapanja. Općenito, većina gnojiva na bazi azota uzima toplinu iz vode, pa temperatura otopine pada. Posljedično, proces pripreme će trajati više vremena, a više vremena će značiti hladniju tekućinu i smanjenje procijenjene koncentracije. U tabeli 4. prikazana je topivost gnojiva iste ili

približno iste NPK formulacije različitih proizvođača. Ovo pokazuje zapravo da sastav gnojiva ima značajnu ulogu u njihovoj topivosti.

Tabela 4. Topivost vodotopivih gnojiva formulacije NPK 20:20:20

Formulacija gnojiva	Proizvođač	Topivost u vodi (grama/l)
Polyfeed NPK 20:20:20	Haifa, Izrael	275
Greenplant NPK 20:20:20	GreenHass, Italija	360
Hydrofert NPK 20:20:20	Biolchim, Italija	431
Green-Go NPK 19:19:19	Biolchim, Italija	597

Kompatibilnost

Važno je znati da se ne mogu sva gnojiva međusobno miješati jer su nekompatibilna, odnosno mogu međusobno da stupe u određene nepoželjne hemijske reakcije koje obično za posljedicu imaju stvaranje taloga. Zbog toga u sistemu fertirigacije imamo obično minimalno dva tanka za pravljenje osnovnih ili matičnih hranljivih otopina (tank A i tank B). Tako npr. nikada u istom tanku ne trebaju da se nađu fosfor ili sumpor s kalcijem, helati sa ne-helatima. Helate također ne treba miješati sa kiselinama jer ih kiseline razgrađuju.

Kiselost ili pH otopine rastvora gnojiva

Kiselost ili pH otopine gnojiva se mjeri pri koncentraciji od 1 gram/litru vode pri temperaturi od 20 °C. Različite formulacije vodotopivih gnojiva imaju i različite pH vrijednosti. Generalno, biljke preferiraju slabo kisele otopine (pH 6,0-6,5). Kod primjene tvrdih, karbonatnih voda, preporučuje se primjena gnojiva s nižim pH vrijednostima. Neki proizvođači vodotopivih gnojiva imaju i posebnu „acid“ (kiselu) liniju gnojiva. One imaju nizak pH te se koriste kod uzgoja acidofilnih kultura poput borovnica, kod uzgoja kultura na karbonatnim tlima ili kod primjene izrazito tvrdih voda. Kiselost otopine gnojiva uzrokuje koroziju. Ona oštećuje metalne dijelove sistema za fertirigaciju. Kisele otopine imaju visoku korozivnost, dok alkalne tekućine predstavljaju rizik od taloženja. Gnojiva na bazi hlorida također su poznate po svojim korozivnim svojstvima. Također, diamonijev fosfat npr. stvara višu pH od monoamonijevog fosfata. Azotna kiselina snižava pH otopine čak i pri relativno niskim koncentracijama. Kalijev sulfat daje neutralnu reakciju. Kalcijev nitrat ili kalijev nitrat stvara alkalnu pH reakciju otopine. Amonijev nitrat, urea, amonijev sulfat, monoamonijev fosfat i diamonijev fosfat proizvode kiselu reakciju. Primjena fosforne kiseline uzrokuje najjaču kiselost tla. U tabeli 5. prikazane su različite pH vrijednost (reakcija) vodotopivih gnojiva istih i različitih formulacija mjenjenih pri standardnoj koncentraciji (Tabela 6) otopine, 1 g gnojiva na litru vode.

Tabela 5. pH vrijednosti vodenih otopina istih NPK formulacija

Formulacija gnojiva	Proizvođač	pH vrijednost
Grogreen NPK 18:18:18	Lima, Belgija	3,5
Hydrofert NPK 20:20:20	Biolchim, Italija	3,7
Nutricomplex NPK 20:20:20	Tradecorp, Španjolska	4,3
YaraTerra Kristalon NPK 18:18:18	Yara, Norveška	4,4
Polyfeed NPK 20:20:20	Haifa, Izrael	5,0
Greenplant NPK 20:20:20	GreenHass, Italija	6,0

Tabela 6. pH vrijednosti vodenih otopina različitih NPK formulacija

Formulacija	Proizvođač	pH vrijednost
Green-Go 12:8:24	Biolchim, Italija	2,6
Nutricomplex NPK 7:12:40	Tradecorp, Španjolska	2,7
Yara Blue Acid NPK 16:6:17	Yara, Norveška	2,8
Greenplant VIP NPK 13:8:24	GreenHass, Italija	3,0

Električna provodljivost (EC) i osmotski pritisak hranljive otopine

Elektro provodljivost, oznake EC (*Electro Conductivity*), predstavlja vrijednost električnog otpora, odnosno sposobnost vodene otopine da provodi električnu energiju. Ona zavisi od prisustva i koncentracije slobodnih jona u vodenoj otopini, što je koncentracija i broj jona veći i EC je veći. Mjeri se sa uređajem koduktometrom u standardnoj otopini koncentracije 1 gram gnojiva/1 litri vode pri temperaturi vodene otopine od 20 °C. EC vrijednost gnojiva izražava se u jedinicama mS/cm ili dS/m, te se kreće u vrijednostima obično od 0,5-2,0, ovisno o formulaciji i proizvođaču vodotopivih gnojiva (Tab. 7, 8, 9 i 10). Prema postojećoj zakonskoj regulativi mora se obavezno navesti na deklaraciji gnojiva.

Osim poznavanje EC vrijednosti vodotopivih gnojiva, potrebno je poznavati i EC vrijednost vode koja se koristi za fertirigaciju. EC vrijednost vodene otopine gnojiva je zbir EC vrijednosti vode (koja ponekad može biti vrlo visoka) i EC vrijednosti vodotopivog gnojiva. Zbog toga je poželjno prije svakog ciklusa fertirigacije kontrolisati EC vrijednost vode i tome prilagoditi potrebnu dozu vodotopivog gnojiva. Obično je voda za navodnjavanje do određenog stepena slana, a dodavanje gnojiva koja sadrže sol još više doprinosi slanosti. Salinitet se odnosi na osmotski pritisak. Negativan osmotski potencijal otežava apsorpciju vode korijenjem biljke, što rezultira smanjenjem prinosa. Usjevi pate od osmotskog stresa i ne mogu koristiti vlagu čak ni kada je ima u tlu, jer ona teče iz manje slanog područja u slanija. Biljke tako troše više energije za apsorpciju vode i hranjivih materija iz fertirigacije, a ako je osmotski stres dosegao kritične vrijednosti, biljke mogu da uginu. Zbog toga treba birati gnojiva sa što nižim osmotskim pritiskom.

U pravilu se ne mjeri potencijal saliniteta gnojiva. Elektro provodljivost i njegov odnos prema osmotskom pritisku služe kao mjere za to. Elektro provodljivost i pH se mjere i zatim upoređuju. Specifična je za svaku hemijsku tvar. Na primjer, amonijev sulfat bi stvorio viši osmotski pritisak u otopini (po ukupnoj primijenjenoj količini hranjivih tvari) nego amonijev nitrat. U tabeli 7. prikazane su osobine gnojiva: koncentraciju hraniva, elektro provodljivost (EC) i pH u 10 mmol/L otopine gnojiva.

Tabela 7. Osnovne hemijske osobina hranjivih otopina različitih vrsta gnojiva

Spoj	Hraniva tvar	Koncentracija (mg/L)	EC (dS/m)	pH
Amonijev nitrat	N	280	0,7	5,5
Amonijev sulfat	N	280	1,4	4,5
Amonijačna voda	N	140	0,7	5,5
Kalcijev nitrat	N	280	2,0	6,9
Di-amonijev fosfat	N, P	280, 310	0,6	7,8
Di-kalijev fosfat	P, K	310, 780	1,9	9,2
Magnezijev hlorid	Mg	240	2,0	6,8
Magnezijev sulfat	Mg	240	2,2	6,9
Mono-amonijev fosfat	N, P	140, 310	0,4	4,7
Mono-kalijev fosfat	P, K	310, 390	0,7	4,6
Azotna kiselina	N	140	0,7	2,0
Fosforna kiselina	P	310	0,4	2,3
Kalij hlorid	K	390	0,7	7,0
Kalij nitrat	N, K	140, 390	0,7	7,0
Kalijev sulfat	K	780	0,2	7,0
Urea	N	280	2,7	7,0

Tabela 8. EC vrijednosti vodotopivih gnojiva formulacije NPK 20:20:20 ili sličnih formulacija

Formulacija gnojiva	Proizvođač	EC vrijednost (dS/m)
Hydrofert NPK 20:20:20	Biolchim, Italija	0,67
Greenplant NPK 20:20:20	GreenHass, Italija	0,84
Nutricomplex NPK 20:20:20	Tradecorp, Španija	0,84
Polyfeed NPK 20:20:20	Haifa, Izrael	0,90
Grogreen NPK 18:18:18	Lima, Belgija	0,94
YaraTerra Kristalon NPK 18:18:18	Yara, Norveška	1,00

Tabela 9. EC vrijednosti vodotopivih gnojiva formulacije NPK 15:5:30 ili sličnih formulacija s naglaskom na azot i kalij

Formulacija gnojiva	Proizvođač	EC vrijednost (dS/m)
Hydrofert NPK 15:5:30 + 3MgO	Biolchim, Italija	1,08
Nutricomplex NPK 15:5:30 + 2MgO	Tradecorp, Španjolska	1,14
Polyfeed NPK 16:8:32 + 2MgO	Haifa, Izrael	1,17
YaraTerra Kristalon NPK 15:5:30	Yara, Norveška	1,40
Greenplant NPK 15:5:25	GreenHass, Italija	1,65

Tabela 10. EC vrijednosti vodotopivih gnojiva formulacije NPK 13:40:13 ili sličnih formulacija sa naglaskom na fosfor

Formulacija gnojiva	Proizvođač	EC vrijednost (dS/m)
Hydrofert NPK 13:40:13	Biolchim, Italija	0,89
Nutricomplex NPK 13:40:13	Tradecorp, Španjolska	0,94
Grogreen NPK 12:42:12	Lima, Belgija	0,99
Polyfeed NPK 11:44:11	Haifa, Izrael	1,08
YaraTerra Kristalon NPK 13:40:13	Yara, Norveška	1,10
Greenplant VIP NPK 10:40:10	GreenHass, Italija	1,15

Tabela 11. Promjena EC vrijednosti vodene otopine gnojiva kod promjene doze gnojiva

Doza primjene gnojiva Basaplant Orange NPK 15:5:30	EC vrijednost (dS/m)
0,5 grama/litri vode	0,76
1,0 grama/litri vode	1,47
1,5 grama/litri vode	2,14
2,0 grama/litri vode	2,81
2,5 grama/litri vode	3,45
3,0 grama/litri vode	4,08

Još jedan aspekt je značajan za raspodjelu hraniva, a to je njihova vrsta i sposobnost adsorpcije u tlu. Tako npr. nitrati i sulfati se ne vežu u tlu dok kalij, fosfor i amonijačni joni mogu. Konkretno, fosfor se veže s kalcijem ili aluminijem, a pozitivno nabijeni kalij i amonijačni jon se adsorbuje na negativno naelektrisane minerale gline. Ove činjenice mogu da imaju značaja kod odabira vremena primjene gnojiva, kako bi se omogućila što veća učinkovitost fertirigacije. Da bi učinkovitost fertirigacije bila što bolja i veća, usjevima treba prilagoditi sva neophodna hraniva spram fenofaza njihovog razvoja i stanja hraniva u tlu. Svaki višak ili manjak hraniva imaće negativne posljedice. Višak hraniva može dovesti do njihovih gubitaka (ispiranje, volatizacija i sl.), a nedostatak će uticati na slabiji razvoj biljaka i prinose. Zbog toga fertirigaciju treba provoditi u pravo vrijeme, sa pravom količinom i vrstom hraniva koje treba aplicirati što direktnije u apsorpcionu zonu korijena. Dalje, manje količine gnojiva primijenjene tačno na vrijeme štede novac poljoprivrednicima i sprječavaju neopravdano zaslanjivanje tla. Zbijanje tla također se može izbjeći korištenjem metoda kao što je navodnjavanje kap po kap, koje ne zahtijevaju upotrebu teških strojeva za remećenje tla kako bi se biljkama osigurale hranjive tvari.

Ovisno o potrebama usjeva u određenom vremenskom okviru, strategija upravljanja hranjivim tvarima može zahtijevati fertirigaciju na dnevnoj, sedmičnoj ili mjesečnoj bazi. Također, ima smisla primijeniti hraniva malo prije nego što ih kultura treba za uspješan rast. Tipično, najintenzivnije razdoblje fertirigacije treba biti tokom rasta biljke, uz smanjenu ili potpunu obustavu gnojidbe u fazi berbe.

Moderni sistemi fertirigacije imaju veliku mogućnosti prilagođavanja. Jedna od takvih je pogodnost koja omogućuje poljoprivrednicima da odstupe od jednoobrazne obrade i gnojidbe polja, odnosno da se formiraju različite zone polja. Ovakve zone imaju različite potrebe za ishranom.

Upravo moderni sistemi fertirigacije omogućuje primjenu gnojiva s promjenjivom dozom, odnosno po zonama. Ove zone se mogu identificirati na osnovu satelitskih snimaka vegetacije, te na osnovu boje nadzemnih dijelova biljaka se može izvršiti procjena njihove ishranjenosti. Biljke sa normalno zelenom bojom nadzemnih dijelova, po pretpostavci su optimalno ishranjene, sa tamno zelenom bojom i bujnijim nadzemnim dijelom imaju pretjeranu ishranu, a sa blijedo zelenom i crvenkastom bojom su slabo ishranjene. Na ovakav način je moguće identificirati i formirati zone u polju, a onda uz pomoć modernih sistema za fertirigaciju, koji podržavaju zonalnu distribuciju hranjivih otopina, moguće je provesti i adekvatnu ishranu po zonama.

Kao što vidimo, savremeni sistemi u biljnoj proizvodnji nezamislivi su bez navodnjavanja i prihrane. Navodnjavanje i fertirigacija su mjere koje sve više dobivaju na značaju i zbog klimatskih promjena i sve češćih suša. Zbog toga, značaj i uticaj kvaliteta vode za navodnjavanje i fertirigaciju ne treba i ne može se zanemariti iz više razloga.

Kvalitet vode za navodnjavanje

Često se uticaju kvaliteta vode za navodnjavanje i fertirigaciju ne posvećuje značajna pažnja, iako on može biti nekada i ograničavajući faktor proizvodnje. Bitni parametri kvaliteta vode za navodnjavanje su sljedeći: pH, EC, sadržaj CaO, MgO i HCO_3^- , Cl^- i Na^+ .

Optimalna pH vrijednost vode za navodnjavanje i fertirigaciju je 6-6,5. Tvrde vode čija pH je obično iznad 7,2 obično se moraju zakiseljavati sa nekom od kiselina (azotna, fosforna ili sumporna), ili ako je pH vrijednost vode previše niska ($\text{pH} < 5,5$) vrši se alkalizacija vode sa kalij hidroksidom, kalij karbonatom, natrij hidroksidom ili Na-karbonatom. Kontrola pH vrijednosti vrši se sa pH-metrom. Otapanjem gnojiva u tvrdim (alkalnim) vodama, može doći do interakcije između pojedinih hraniva iz gnojiva i kalcija i bikarbonata iz vode. Ovakvim reakcijama nastaju netopive soli koje se talože (precipitiraju). Hraniva koja ulaze u sastav tih soli postaju nepristupačna biljkama (blokirana), a istaložene soli prave brojne probleme u sistemu fertirigacije (začepljenje sistema). Zato je sadržaj pristupačnog kalcija i bikarbonata u vodi vrlo značajan parametar. Bikarbonati (HCO_3^-) mogu vezati Ca i tako ga blokirati i činiti nepristupačnim biljkama. Osim toga gnojiva koja sadrže fosfate i sulfate, kada se otapaju u ovakvim vodama, grade netopive kalcijeve fosfate i kalcijev sulfat (gips), koji se talože i izazivaju začepljenje sistema. Ukoliko nema drugog izbora i ovakve vode se moraju koristiti, onda je neophodno izvršiti neutralizaciju bikarbonata nekom od kiselina (HNO_3 , H_3PO_4 ili H_2SO_4). Na taj način od bikarbonata nastaju voda i ugljen dioksid, oslobađa se Ca, smanjuje vrijednost EC-a i snižava pH vrijednost. Prisustvo bikarbonata u vodi u koncentracijama do 60 ppm je poželjno zbog pufernih svojstava. Također, miješanjem npr. fosfatne kiseline sa cinkom, željezom, bakrom i magan sulfatom mogu nastati netopivi fosfati ovih metala.

Elektroprovodljivost (EC) je vrlo značajan parametar kvaliteta vode. Ova osobina vode odražava sposobnost vode da provodi struju zahvajući otopljenim solima (jonima) koje se nalaze u njoj. Pošto sve prirodne vode sadrže manje ili više otopljene soli u sebi, to znači da imaju i različite vrijednosti EC. Dodavanjem gnojiva-soli u vodu povećava se njihova koncentracija i EC vrijednost vode. Za ishranu biljaka nije poželjna ni previsoka niti preniska EC vrijednost, jer dolazi do debalansa i otežanog usvajanja između vode i hraniva od strane biljaka. EC vrijednost mjeri se pomoću EC-metra ili konduktimetra, a vrijednosti se izražavaju u mmhos ili u mS/cm^2 . Odlična voda za navodnjavanje je ona čije su vrijednosti manje od 0,5 mmhosa (mS/cm^2). Vrijednost od 0,5 do 0,8 mmhosa smatra se dobrom. Srednjeg kvaliteta je voda sa vrijednošću EC od 0,8 do 1,1.

Voda sa vrijednostima EC-a iznad 1,1 mmhosa smatra se lošom za navodnjavanje i fertirigaciju. Na visoke vrijednosti EC-a posebno su osjetljive mlade biljke. Prilikom spravljanja hranjivih rastvora potrebno je poznavati EC vrijednosti vode, EC vrijednost nakon spravljanja hranjive otopine i EC vrijednosti mjerene na kapaljci.

Normiranje vode i gnojiva, zalivne norme

Količina vode potrebne za navodnjavanje biljaka ovisi o više faktora. Razvoj korijenovog sistema u tlu (supstratu) u mnogome zavisi od stanja vode i hraniva u njemu. Drugim riječima, korijen u tlu ili vještačkim supstratima manje se razvija po dubini ukoliko u površinskom sloju postoji kontinuirana i optimalna opskrba sa vodom i hranivima. Zato, povrtlarske biljke nakon rasađivanja treba malo „zasušiti“, kako bi se korijenov sistem u potrazi za vodom što bolje i jače razvio kako po dubini tako i po širini. Ovo se postiže tako, što se tlo prije rasađivanja na nekoliko dana zalije do poljskog vodnog kapaciteta. Nakon rasađivanja biljke se dobro zaliju, a ukoliko je potrebno izvršiti prihranu vodotopivim gnojivima, onda se to radi sa gnojivima koja imaju povećan sadržaj fosfora (npr. Yara Tera Kristalon Yellow 13-40-13). Prihrana ovakvim vrstama gnojiva je obavezna mjera ako je vrijeme prohladno i ukoliko je sadržaj fosfora u tlu nizak. Kod lakših zemljišta, viših temperatura i lošijeg rasada može se izvršiti još jedno zalijevanje u ovoj fazi razvoja. Nakon toga treba obustaviti zalijevanje-navodnjavanje kako bi u zoni korijena došlo do deficita u vodi i kao bi se korijen u potrazi za vodom bolje razvio. Biljke sa razvijenijim korijenovim sistemom biće otpornije na brojne stresne situacije jer će takav korijen bolje i lakše snabdjevati biljku sa vodom i hranivima.

Čest je slučaj da u rano proljeće treba izvršiti prihranu a ne i navodnjavanje. U tom slučaju se upotrebljavaju jače koncentracije hranjive otopine, kako bi se s većom količinom hraniva unijelo manje vode u tlo.

Zalivne norme (količine vode) zavise od više faktora, ali se ipak one određuju po dva principa.

Prvi princip odnosi se na „razvijenost korijenovog sistema“. To znači da su norme zalijevanja jednake onoj količini vode i vremenu trajanja koje je potrebno da voda stigne do dna korijena. Ovo je moguće provjeravati na više načina. Prvi način navodnjavanja je „standardni“, gdje se pomoću tenziometara koji se postavljaju na dvije dubine određuje moment početka i kraja navodnjavanja. Prvi je na 20-cm i on određuje momenta kada treba početi navodnjavanje, a drugi na dubini od 30-50 cm i on služi da odredi moment kada je voda stigla na tu dubinu, i to je moment kada treba prekinuti navodnjavanje. Odrediti pravi momenat kraja navodnjavanja vrlo je bitno jer se na taj način spriječava ispiranje hraniva van zone korijena, pri čemu ta hraniva više ne bi bila dostupna biljci. Osim što gubitak hraniva ima negativan ekonomski efekat, on ima i određene štetne ekološke efekte. Često se usljed nedostatka drugog tenziometra, iskopa profil tla do te dubine (50-60 cm) i vizuelno prati tokom jednog navodnjavanja koliko je potrebno vremena da voda pod određenim pritiskom iz sistema dođe do naznačene dubine. Na ovaj način se odredi potrebno vrijeme za zalivanje, tako da za svako naredno zalijevanje se zna potrebno vrijeme navodnjavanja. Pri ovom načinu praksa pokazuje da ne treba mijenjati zalivnu normu (količinu) vode, već dinamiku-period između dva zalijevanja treba prilagoditi vremenskim uslovima, razvoju biljke i osobinama tla.

Drugi način je „intenzivno“ navodnjavanje, koje podrazumijeva češće navodnjavanje (1-10 puta) sa manjim količinama vode. Ovaj način je najčešće zastupljen kod uzgoja biljaka na vještačkim supstratima. Prednosti ovog načina su:

- biljke doživljavaju manji stres,
- veća je učinkovitost,
- manja je potrošnja gnojiva,
- veći prinosi i bolji kvalitet.

Nedostaci su:

- potrebna savremenija tehnologija,
- manja zapremina korijena-veća mogućnost greške kod ishrane i navodnjavanja,
- veća mogućnost zaslanjivanja tla,
- teže je odrediti potrebnu količinu vode za navodnjavanje (poznavanje evapotranspiracionih koeficijenata za svaku kulturu po fenofazama razvoja).

Osim značaja određivanja momenta početka i kraja navodnjavanja-fertirigacije, veoma značajno je znati odabrati pravo vrijeme (doba dana za navodnjavanje i prihranjivanje). Za tradicionalni način se preporučuje jutarnje navodnjavanje i prihrana, kako bi biljke imale tokom dana dovoljne količine vode i hraniva. Osim toga relativna vlažnost zraka u zaštićenim prostorima je u jutarnjim satima manja nego ako se navodnjavanje i prihrana vrše tokom noći. Ova činjenicu je bitno znati iz razloga što brojne gljivične bolesti za svoj razvoj trebaju veću relativnu vlagu zraka.

Pošto se kod intenzivne fertirigacije navodnjavanje i prihrana obavljaju više puta u toku dana, onda se ona preporučuje u ranim jutarnjim satima i oko podneva.

Najčešće greške u ishrani ogledaju se u kod odabira pravih formulacija, smiješa i količina hraniva. Preporuke proizvođača gnojiva obično se odnose na standardne uslove koji u praksi često odstupaju (različite plodnosti tla, kvaliteta vode itd.). Zato program ishrane treba prilagoditi datim uslovima na terenu.

Prije nego se pristupi pravljenju otopina, potrebno je znati količine gnojiva-hraniva koje treba upotrijebiti, adekvatne formulacije, kompatibilnost pri miješanju gnojiva, količinu i osbine vode (sadržaj Ca^{2+} , bikarbonata HCO_3^- , magnezija- Mg^{2+}). Druge dodatne informacije od izuzetnog značaja su: analiza i stanje hraniva u zemljištu, tip zemljišta, kultura koja se prihranjuje, potrebne količine hraniva koje se iznose prinosima, osnovna gnojidba, itd. Sve ove informacije doprinose pravljenju boljeg i preciznijeg programa ishrane.

Standardnim načinom ishrane se preporučuje prvo puštanje malo vode kroz sistem za navodnjavanje, zatim se, ako se radi o vrsti fertirigacije po venturi modelu, usisno crijevo i sito venturija stavi se u tank A. Nakon potrošnje tog rastvora sito se prebacuje u tank (B), a nakon potrošnje i tog rastvora sistem se nekoliko minuta ispiri sa čistom vodom sve dok i kroz posljednju kapaljku ne prođe voda. Važno je da uskladimo vrijeme navodnjavanja i prihranjivanja da traju zajedno, ili ako ne traju isto vrijeme, prihranu treba dodavati u drugoj polovini vremena natapanja, kako ne bi došlo do ispiranja hraniva van zone korijenovog sistema. Trajanje zalivanja i prihrane zavisi od tipa tla, vrste kulture, fenofaze razvoja, razvijenosti korijena, klimatskih uslova, itd. Zbog svih navedenih razloga preporučuje se proizvođačima nabavka tenziometra - uređaja pomoću kojih se određuje vrijeme početka i kraja zalijevanja.

Tenziometar je uređaj za mjerenje stanja vlage u tlu. Uređaj funkcionira na principu mjerenja sisajuće moći (napona) nezasićenog tla vodom, a to mu omogućava vodopropusna keramička ploča na vrhu. Zapravo tenziometar se ispuni do vrha vodom i dobro zatvori, vodeći računa da u njemu ne ostane zraka. Na tlu ili ako se proizvodnja odvija na vještačkim supstratima napravi se manja rupa u koju se stavlja tenziometar. Nakon toga se zemlja (supstrat) sabije uz tenziometar, kako bi došlo do što boljeg kontakta između keramičke ploče tenziometra i tla. Pošto se to obično radi kada je tlo zasićeno vodom, vremenom sadržaj vode u tlu opada, što usljed usvajanja od strane biljnog korijenja, što evaporacijom (isparavanjem). Usljed toga smanjenja vode u tlu, čestice tla svojim silama povlače vodu iz tenziometra preko vodopropusne keramičke ploče pa se u tenzimetru stvara vakum-podpritisak, koji se mjeri pomoću barometra koji se nalazi na uređaju. Kada pritisak u tenziometru (kazaljka) dovoljno padne, tada se pušta sistem za navodnjavanje i prihranu. Ovako se tenziometrom određuje vrijeme početka navodnjavanja. Kraj se određuje drugim tenziometrom koji se nalazi na većoj dubini (40-50 cm), ili se ašovom tlo zakopa pored kapaljke i provjeri za koje vrijeme se voda procijedi u tlu do željene dubine. Na taj način se određuje dužina trajanja i zalivna norma.

Intenzivna fertirigacija, o kojoj smo već govorili, podrazumijeva zalijevanje i prihranu više puta u toku dana (10-20) sa manjim količinama. Međutim, ovaj sistem zahtijeva dodatnu opremu, komplikovaniji je, skuplji, ali ima i svoje prednosti.

Drugi način-metod za određivanje zalivnih normi jeste pomoću evapotranspiracije.

Evaporacija je isparavanje vode sa površine zemlje, a transpiracija je odavanje (isparavanje) vode preko biljke. Ukupno isparavanje sa površine tla i preko biljaka naziva se evapotranspiracija. Brojna istraživanja su do sada utvrdile koeficijente evapotranspiracije za svaku fazu razvoja biljke. Drugim riječima to znači, da na osnovu poznavanja vrijednosti tih koeficijenata i količina isparene vode sa površine tla, možemo izračunati potrebnu količinu vode koju je putem navodnjavanja potrebno obezbijediti biljkama (tabela 12).

Tabela 12. Orijentacione vrijednosti koeficijent evapotranspiracije kod paradajza (ne važi za pjeskovita tla)

Faza razvoja	Rasađivanje do cvjetanje	Cvjetanje do oplodnje prvih plodova	Porast plodova do berbe	Berba
Koeficijent	0,5	0,6	0,8-1,1	> 1

Kako odrediti zalivnu normu pomoću ovog modela?

U precizno baždarenu posudu (baždarenje u mm) poznate površine, sipa se voda. Tokom dana prati se koliko će opasti nivo vode u mm izazvan isparavanjem. Ako npr., u toku dana nivo vode u posudi opadne za 3 mm, a paradajz se nalazi u fazi porasta plodova (koeficijent evapotranspiracije 0,8-1,1), to znači da paradajzu treba za svaki mm isparene vode iz posude nadoknaditi u ovoj fazi razvoja 0,8-1,1 mm vode. Ako se zna da je 1mm vode isto što i 1 litar vode/m², onda je lako izračunati potrebnu količinu vode za navodnjavanje paradajza u navedenoj fazi razvoja. Potrebna količina bi iznosila 3 mm (na dan) x 1 (koef.) = 3 mm (3 l/m²) vode za navodnjavanje. Ako je površina za zalijevanje npr. 100 m² (površina nekog plastenika), i zalijevanje se predviđa provesti u dva navrata tokom dana, tada je potrebno oko 300 l, podijeljeno u dva turnusa je 150 l vode potrebno za jedno zalijevanje, i isto toliko za drugo u toku jednog dana.

Navedeni koeficijenti važe za srednje teška i teška tla. Kako često i sa kojim količinama treba navodnjavati neko tlo zavisi od više faktora: primijenjene tehnologije uzgoja, načina navodnjavanja, tipa tla, vremenskih uslova itd. Radi ilustracije navodimo orijentacionu procjenu da tlo efektivno može da primi 6 l vode/m² na dan. Uvažavajući ovu činjenicu količine vode za navodnjavanje ne bi trebale da prelaze navedenu vrijednost, bez obzira na dnevnu evapotranspiraciju, izuzev samo u nekim slučajevima. Drugim riječima, to znači da dnevna zalivna norma u plastenicima od 100 m² ne bi trebala da prelazi količinu od 600 litara, jer bi u protivnom došlo do potencijalne opasnosti od ispiranja i gubitaka hraniva izvan zone korijena.

Za razliku od navedenih starijih načina i metoda određivanja zalivnih normi, današnji načini su vezani za pametne sisteme navodnjavanja i fertirigacije. Kod ovih sistema, kako je već ranije objašnjeno, stanje vlažnost tla i EC vrijednosti zemljišnog rastvora se pomoću senzora prate i mjere. Sam sistem, pored senzora ima svoj hardverski i softverski dio. Svi ovi dijelovi međusobno komuniciraju i razmjenjuju podatke koristeći WSN bežične i internetske veze. Svi prikupljeni i zadati podaci se programski analiziraju i obrađuju, tako da cijeli sistem na kraju sam automatski određuje vrijeme zalijevanja i prihrane, kao i njihove količine. Senzori šalju signal da je tlo dostiglo donji nivo vlažnosti, sistem se automatski uključuje i navodnjavanje starta. Nakon što se nivo vlažnosti u tlu podigne do zadane vrijednosti, senzor će ponovo poslati signal i sistem za navodnjavanje će se automatski isključiti.

Normiranje hraniva-gnojiva za prihranu

Količinu potrebne hrane-gnojiva koju treba dati biljkama u toku vegetacije sistemom fertirigacije moguće je odrediti na nekoliko načina.

- 1) Određivanje pomoću „**EC-metra**“. Ovaj način nije najprecizniji ali je koristan. Pomoću njega se određuje koncentracija hraniva-soli u rastvoru. Nedostatak ovog načina je što na osnovu vrijednosti EC-a ne znamo odnos hraniva, a to je vrlo važan faktor u ishrani. Pomoću EC metra se mjeri elektro provodljivost rastvora uslovljena disosovanim jonima u njemu. Izražava se, kako je već rečeno, u mmhos ili mS/cm². Uz pomoć vrijednosti EC-a, moguće je pomoću sljedećih obrazaca izračunati ukupnu koncentraciju soli (*Total Dissolved Salts*, TDS) u otopini i osmotski pritisak.

$$\text{TDS (mg/dm}^3\text{)} = 560 \times \text{EC}$$

$$\text{Osmotski pritisak (bar)} = 0,36 \times \text{EC}$$

- 2) Drugi način izračuna je pomoću „**matematičkih modela**“. Ovaj model podrazumijeva da se u određeni volumen vode dodaju unaprijed određene količine hraniva. Tako za pojedine kulture postoje već ustaljene recepture ishrane, čak i po fenofazama razvoja. Npr. standardna otopina za ishranu paradajza podrazumijeva da se u 500 l vode nalazi 69 g N, 18 g P₂O₅, 118 g K₂O, 56 g CaO i 30 g MgO. Prihrana se vrši uz pomoć injektora, preko tanka za hranjivu otopinu. Ukupnu količinu hraniva-gnojiva moguće je odrediti ako se zna ukupna količina vode koja će se primijeniti zalijevanjem u toku vegetacije. Prednost ovog modela jeste što se u njemu jasno znaju odnosi i količine hraniva u vodi.
- 3) Treći način obračuna hraniva jeste „**preko površine**“. Kod ovog modela daju se tablice prihrane izražene u količinama hraniva-gnojiva po jedinici površine tla, koje se daju po jednom danu. Obično se u tim tablicama navode dvije vrijednosti za neko hranivo. Prva podrazumijeva količinu hraniva koju treba dati u početnim fazama razvoja biljaka, a druga vrijednost označava količinu hraniva koju treba dati u kasnijim fazama razvoja. Ovo je i razumljivo ako

se uzme u obzir činjenica da tokom vegetacije biljka raste, razvija se i samim tim ima veću potrebu za hranom. S obzirom da se navodnjavanje ne obavlja svakodnevno (standardni način fertirigacije), onda se količina hraniva-gnojiva koja se preporučuje u tablicama pomnoži sa proizvodnom površinom i brojem dana koliko je prošlo između dva uzastopna navodnjavanja. Tako izračunata količina gnojiva se primjeni kroz sistem za navodnjavanje (fertigacija). Ako su u tablicama navedene količine hraniva za 1000 m²/danu, i upravo se radi o toj proizvodnoj površini, onda se date količine hraniva-gnojiva iz tablica množe samo sa brojem dana koliko je prošlo između dva navodnjavanja. Ovdje treba ipak imati na umu da se naznačene količine hraniva u tablicama odnose uglavnom na lijepe, tople, sunčane dane. Zato ukoliko se radi o tmurnim, oblačnim danima, navedene količine hraniva-gnojiva treba reducirati za 30-50%, jer je rast, razvoj i usvajanje hraniva od strane biljaka u takvim uslovima smanjen.

Nakon proračuna, pripreme hranjive otopine i njene primjene, posao prihrane nije završen. Potrebno je i dalje pratiti i vršiti kontrolu prihrane. Kontrolu je moguće vršiti na više načina, od kontrole i analize tla, vode za navodnjavanje, pH i EC vrijednosti hranjive otopine i reakcije biljke na prihranu. Danas u savremenim sistemima uzgoja kontrolu je moguće provoditi i pomoću ekstraktora. Ekstraktor je uređaj sličan tenziometru. Služi za uzimanje zemljišnog rastvora za analizu. Postavlja se u tlo kao i tenziometar. Ekstraktor ima vodopropusnu keramičku pločicu preko koje zemljišni rastvor uđe u uređaj. Nakon toga iz uređaja se uzme uzorak zemljišnog rastvora za analizu i obično pomoću brzih (terenskih) laboratorija izvrši analiza na osnovne parametre. Tako npr. za paradajz nakon očitavanja EC vrijednosti hranjive otopine ispod kapaljke (X) i EC vrijednosti zemljišnog rastvora uzorkovanog ekstraktorom (Y) važi sljedeće: Ako je Y manje ili jednako X prihranu treba pojačati. Ako je $Y = X + 1,5$ prihrana je dobra i ako je Y veće od $X + 1,5$ postoji opasnost zaslanjivanja. Ako je količina gnojiva ispravna treba pojačati navodnjavanje (količinu vode).

Gnojidba jabuke

U ovom dijelu će se prikazati jedan detaljniji opis gnojidbe jabuke na primjeru koji se prakticira u Norveškoj. Baziran je na naučno-stručnom znanju i praksi koja se koristi u ovoj zemlji kod uzgoja jabuke (Ličina, 2024). Ipak, na startu treba imati u vidu da se ekološki uslovi za uzgoj biljaka pa tako i jabuke u ovoj zemlji u značajnoj mjeri razlikuju od većeg dijela ostatka Evrope. Prema norveškim istraživanjima, zemljišta u regijama gdje se uzgaja jabuka imaju pH 5,5 i pH 7, što utiče na dobru dostupnost hraniva, posebno fosfora kojeg inače ova zemljišta sadrže približno u optimalnoj vrijednosti. U većini norveških voćnjaka jabuke, opskrba azotom tokom sezone je oko 40-75 kg/ha, maksimalno 90 kg/ha, dok je prosječna opskrba fosforom između 10 i 20 kg/ha, a kalijem između 35 i 75 kg/ha. U usporedbi s vodećim zemljama proizvođačima jabuka, može se reći da su navedene doze gnojiva niske ili umjerene. Ovo možemo slobodno reći da važi i u Bosni i Hercegovini, pogotovo ako se promatraju naši voćnjaci koji prakticiraju intenzivni sistem proizvodnje. Jedan od razloga za ovu ograničenu opskrbu hranjivim tvarima je bogatstvo tla voćnjaka organskom tvari, koja zadovoljava potrebe biljaka za mineraliziranim hranjivim tvarima i stvara savršene fizičke uslove za rast korijena i adsorpciju. Kao što je ranije spomenuto, sadržaj organske tvari u norveškim voćnjacima je >10%, a normalan sadržaj je u rasponu od 5 do 8% čak i u pjeskovitim tlima. Relativno velike varijacije u sadržaju organske tvari unutar regija povezane su s lokalnim klimatskim uslovima, ali i s upotrebom komposta i životinjskog gnojiva kao “prirodnih” gnojiva za poboljšanje tla. To podupiru regionalne savjetodavne službe NLR (Norsk Landbruksrådgiving), koje naglašavaju važnost organske tvari za rast jabuka i tvrde da visok omjer ugljika i azota (C:N = 12–18) može biti pozitivan pokazatelj za visoko oslobađanje N navodi Ličina (2024) u svojoj studiji.

Fertirigacija voćnjaka jabuka

Primjena tekućeg gnojiva kroz sistem navodnjavanja (fertirigacija) smatra se najučinkovitijim načinom povećanja prinosa jabuka s najvećim utjecajem na kvalitet plodova (Čivić, 2010). Učinkovitost gnojidbe ovisi o svojstvima tla i karakteru hraniva. To pokazuju različita ponašanja različitih hranjivih jona u tlu i različiti učinci primijenjenih otopina gnojiva.

Prije svega, program ishrane voća fertirigacijom ovisi o karakteristikama tla, pri čemu su najvažnija neka njegova fizička svojstva kao što su poroznost i sposobnost vezanja unesenih hraniva. Ponašanje dodanih jona u tlu također uveliko ovisi o svojstvima tla, a prisutnost velikih količina dodanih jona nakon otapanja trebala bi biti fino podešena prisutnošću gline ili organske tvari kao jezgre koloida i otopine tla. Glavni cilj svih sistema fertirigacije je distribucija razrijeđenog gnojiva do korijena biljaka u konstantnoj koncentraciji.

Općenito, koncentracije vodenih otopina koje se daju putem fertirigacije su vrlo niske i iznose 0,1-0,2%. Prednost ovakvog načina gnojidbe, je trajna i maksimalna opskrbljenost hranjivima prema trenutnim potrebama voćaka tokom cijelog vegetacijskog ciklusa. Posebno treba posvetiti pažnju ishranu jabuke sa onim hranivima koja su bitna za pojedine fenofaze razvoja, kako bi se zadovoljile potrebe biljaka. Međutim, osim količine i vrste korištenog gnojiva, moraju se uzeti u obzir i drugi parametri, kao što su njegova topljivost, utjecaj na kiselost, kompatibilnost i cijena. Kod normiranja doza gnojiva treba nastojati da ona budu ekološki prihvatljiva i ne predozirati sa gnojidbom. U praksi to znači racionalno upravljanje s tri postojeća izvora hraniva. Prvi izvor su rezerve hraniva u tlu nastale prethodnom gnojidbom, mineralizacijom organske tvari u tlu i prirodnim trošenjem i otapanjem minerala u tlu. Drugi izvor su hraniva pohranjena u skladišnim organima stabala, a treći izvor je količina hraniva/gnojiva primijenjena tokom vegetacije. Sva tri faktora treba uzeti u obzir kada se planira i programira gnojidba nakon provedene analize tla.

U tabeli 13 su prikazane preporučene količine za gnojidbu jabuke u Norveškoj, putem fertirigacije sa azotom, fosforom i kalijem. Ovdje su osim gnojiva „Yara“, date i preporuke za gnojiva od NIBIO proizvođača (NIBIO- Norveški institut za bioekonomska istraživanja), koji je razvio biognojiva na bazi ribljeg mulja i otpada od ribe koji zaostaje nakon njene prerade.

Tabela 13. Preporučena primjena azota, fosfora i kalija na produktivno stablo jabuke u kg/1000 m² i kg/ha u Norveškoj

	N		P		K	
	kg/1000 m ²	kg/ha	kg/1000 m ²	kg/ha	kg/1000 m ²	kg/ha
Yara	2–2,5	20–30	1,5–2,0	15–20	7–9	70–90
NIBIO	3–5	30–50	1,0–2,0	10–20	5–7	50–70
NIBIO/NLR	4,5–6,5	45–65	2,0	20	3,5–10	35–100

Osim dodavanja hraniva putem fertirigacije, ista se mogu dodavati i preko lista (folijarno). Folijarna ishrana biljaka dobiva sve više na značaju. Uopšteno, svrha ovakve primjene hraniva nije ispraviti nedostatke hraniva, već pospješiti rast biljaka i poboljšati kvalitet plodova. Ovaj pozitivni trend folijarne ishrane se primjenjuje i širi i na ostale biljne vrste.

U praksi se mogu naći različita folijarna gnojiva, a koja se uglavnom razlikuju po hemijskom sastavu i učinkovitosti. Proizvođači također nude kompletan program folijarne gnojidbe, pa tako svaki poljoprivrednik može sam napraviti otopinu soli i tretirati svoje biljke u voćnjaku.

Kod svih ovih otopina treba paziti da koncentracija ne bude prevelika jer lišće samo ograničeno može apsorbirati soli. Koncentracija bi trebala biti između 0,1 i 0,2%, najviše do 0,5%, ali samo za pojedine tolerantnije biljne vrste. Folijarnu ishranu inače treba provoditi u vrijeme kada vani nisu visoke temperature i prilagoditi je fenofazama rasta i razvoja jabuke i njenim specifičnim potrebama za hranivima u pojedinim fenofazama.

U tabeli 14 prikazan je okvirni program folijarne gnojidbe koji se primjenjuje u Norveškoj.

Tabela 14. Program folijarne gnojidbe jabuka predložen od strane konzultanata i istraživača u Norveškoj

Faze razvoja	Folijarna primjena	Gnojiva
Prije cvatnje	B folijarno gnojivo	<i>Bortrac</i> ("Yara Vita")
Cvatnja	Mn ²⁺ folijarno gnojivo Mg ²⁺ folijarno gnojivo	MgSO ₄ 2-3 prskanja nakon cvatnje 25 mL <i>Mantrac</i> ("Yara Vita")
Faza razvoja lista i ploda (preporučuje se analiza lista i ploda)	Ca ²⁺ folijarno gnojivo K ⁺ folijarno gnojivo	400–700 g/ha CaCl ₂ , (ukupno 4–6 puta) ("Yara Vita") 50 mL <i>Aminosol</i> ("Lebosol") 50–70 mL <i>Zintrac</i> ("Yara Vita")
Odmakla faza razvoja ploda	Ca ²⁺ folijarno gnojivo K ⁺ folijarno gnojivo	Dva prskanja <i>MKP monokalijeveg fosfata</i> (monokalijeveg fosfata) („Van Iperen International”—Njemačka) prije berbe (oko 7 dana) za poboljšanje boje i čvrstoće
Nakon berbe a prije kraja vegetacije	Urea 5% - u nekoliko navrata ili 10-15 kg/ha ukupne količine Folijarna gnojidba borom (po potrebi i cinkom)	Urea

Iako se folijarna gnojidba tretira kao dodatna ishrana, odgovor na prskanje folijarnim gnojivima u nasadima jabuka može biti značajan. To posebno vrijedi za elemente s niskom pokretljivošću floemom kao što su Ca, B, Fe, Mn ili Zn u ranoj fazi rasta, kada bi njihova folijarna gnojidba u neznatnim količinama mogla imati povoljan učinak. Murtić i sar. (2017), u svojim istraživanjima, o efektima različitih načina primjene kalcija kod jabuke, pokazuju da je dodavanje kalcija preko lista u kombinaciji sa njegovim dodavanjem preko tla, dalo najbolje rezultate u pogledu njegovog sadržaja u nadzemnim dijelovima i kvaliteti plodova jabuke.

Još jedna značajna prednost folijarne gnojidbe je njen stimulativan učinak na metabolizam biljaka. Stoga bi široko rasprostranjena praksa folijarne ishrane jabuke, praćena naučnim istraživanjem i praktičnom primjenom, trebala podržati specifične faze rasta i razvoja, kao što su otvaranje pupoljaka, stadij ružičastih pupoljaka, cvatnje, diobe ćelija, rast, razvoj i sazrijevanje plodova, berba i period nakon berbe.

Uzimajući u obzir kontinuirani razvoj i trenutnu reputaciju norveškog proizvođača „Yara“ gnojiva, može se pretpostaviti da su gore navedene preporuke temeljene na znanju i da su prethodno ispitane. Posljedično, može se pretpostaviti da ova kompanija ima veliki uticaj na proizvođače jabuka, ali i na ostale poljoprivredne proizvođače u Norveškoj kao njihov konzultant za gnojiva (*Yara Apple Program*). S tim u vezi, ove preporuke bi se mogle smatrati relevantnim i za naše proizvođače jabuke u Bosni i Hercegovini. Naravno, ovdje treba uzeti u obzir određene ekološke specifičnosti i razlike koje su evidentne kada je u pitanju proizvodnja jabuke u ove dvije zemlje.

LITERATURA:

- 1) Ahmad, U., Alvino, A., Marino, S. (2022). Solar Fertigation: A Sustainable and Smart IoT-Based Irrigation and Fertilization System for Efficient Water and Nutrient Management. *Journals Agronomy* Volume 12 Issue 5.
- 2) Baligar, V. C., Fageria, N.K., Zhenli H. (2001). Nutrient Use Efficiency in plants. *Soil Science and Plant Analysis*, 32: 7, 921-950.
- 3) Bingham, F. (1963). Relation between phosphorus and micronutrients in plants. *Soil Science Society of America Journal* 27 (4): 389-391.
- 4) Čivić, H., Murtić, S., Vukobratović, M., Đurić, M. (2010). Effect of Different Models of Fertilization on the Yield and Mineral Composition of Apple Fruits. 21st Scientific-Expert Conference of Agriculture and Food Industry, Neum, Bosnia and Herzegovina. Volume: Proceedings, pp.149-160.
- 5) Fan, J., Lu, X., Gu, S., Guo, X. (2020). Improving nutrient and water use efficiencies using water-drip irrigation and fertilization technology in Northeast China. *Agricultural Water Management*. Volume 241.
- 6) International Fertilizer Industry Association (IFA) (2009). The Global “4R” Nutrient Stewardship Framework Developing Fertilizer Best Management Practices for Delivering Economic, Social and Environmental Benefits.
- 7) International Plant Nutrition Institute (2019). 4R Plant Nutrition Manual: A Manual for Improving the Management of Plant Nutrition.
- 8) Karaşahin, M., Dündar, Ö., Samancı, A. (2018). The Way of Yield Increasing and Cost Reducing in Agriculture: Smart Irrigation and Fertigation, *Turkish Journal of Agriculture -Food Science and Technology*, 6(10):1370-1380.
- 9) Kulhánek, M., Alamnie, D., Pavel, A., Ondřej Sedlář, S., Černý, J., Balík, J. (2023). Plant Nutrition-New Methods Based on the Lessons of History: A Review. *Journals Plants*. Volume 12, Issue 24.
- 10) Ličina, V., Krogstad, T., Fotirić Akšić, M., Mekjell Meland, M. (2024). Apple Growing in Norway-Ecologic Factors, Current Fertilization Practices and Fruit Quality: A Case Study. *Journals Horticulturae* Volume 10, Issue 3.
- 11) Liu, G., Zotarelli, L., Li, Y., Dinkins, D., Wang, Q., Ozores-Hampton, M. (2014). Controlled-Release and Slow-Release Fertilizers as Nutrient Management. UF/IFAS Extension. University of Florida.
- 12) Lü, S., Feng, C., Gao, C., Wang, X., Xu, X., Bai, X., Gao, N., Li, M. (2016). Multifunctional Environmental Smart Fertilizer Based on l-Aspartic Acid for Sustained Nutrient Release. *Journal of Agricultural and Food Chemistry* Vol 64/Issue 24.
- 13) Murtić, S., Čivić, H., Ahmić, A., Karić, L., Omanović-Miklićanin, E. Gadžo, D. (2015). Uticaj primjene različitih biljnih hormona na parametre kvaliteta presadnica paprike (*Capsicum annuum* L. Cv. ‘Sivrija’): Agroznanje 16(3), pp. 367-377.
- 14) Murtić, S., Čivić, H., Avdić, J., Ašimović, Z., Kobilica, K. (2015). The influence of indole-butyric acid on rooting and quality parameters of elderberry cuttings (*Sambucus nigra* L.): *Radovi Poljoprivredno-prehrambenog fakulteta Univerziteta u Sarajevu* 65(2), pp. 31-37.

- 15) Murtić, S., Oljača, R., Kolečka I., Čivić, H. (2017). Apple Quality and Calcium Content as Affected by Fertilizer Treatment. *Polish journal of environmental studies* 26(5): 2107-2111.
- 16) Pawase, P. P., Nalawade, S. M., Bhanage, G. B., Walunj, A. A., Kadam, P. B., Durgude, A. G., Patil, M. G. (2023). Variable rate fertilizer application technology for nutrient management: *International Journal of Agricultural and Biological Engineering*, Vol. 16, No. 4, pp11-19.
- 17) Penuelas, J., Coello, F., Sardans, J. (2023). A better use of fertilizers is needed for global food security and environmental sustainability. *Agriculture & Food Security*. Volume 12, article number 5.
- 18) Rakshit, A., Meena, V. S., Chakraborty, S., Sarkar, B., Ghosh, S. (2022). Editorial: Adaptive Farming Sustainability Practices: Fundamentals to Advances. *Frontiers in Sustainable Food Systems*.
- 19) Sawyer, J.E. (1994): Koncepti tehnologije promjenjive doze s razmatranjima za primjenu gnojiva. *Journal of Production Agriculture*. Volume 7, Issue 2.
- 20) Sharma, R., Aravind, T., Sharma, R. (2019). Sustainable agriculture: Trends and opportunities for 21st Century. *Journal of Applied and Natural Science*, 11(3): 666 -672.
- 21) Shaviv, A. (2005). Environmental friendly nitrogen fertilization. *Life Sciences*. Volume 48, pages 937–947.
- 22) Shaviv, A., Mikkelsen, R. L. (1993). Controlled-release fertilizers to increase efficiency of nutrient use and minimize environmental degradation - A review. *Nutrient Cycling in Agroecosystems*., Volume 35, pages 1–12.
- 23) Visconti, P., De Fazio, R., Primiceri, P., Cafagna, D., Strazzella, S., Giannoccaro, N.I. (2020). A Solar-Powered Fertigation System based on Low-Cost Wireless Sensor Network Remotely Controlled by Farmer for Irrigation Cycles and Crops Growth Optimization. *Intl Journal of Electronics and Telecommunications*, Vol. 66, No. 1, pp. 59-68.
- 24) Vukadinović, V. (2023). Jesu li nanognojiva budućnost gnojidbe? http://tlo-i-biljka.eu/Gnojidba/Nano_gnojiva.pdf

PAMETNI SISTEMI NAVODNJAVANJA BILJAKA U BILJNOJ PROIZVODNJI

Sabrija Čadro

Navodnjavanje je hidromeliorativna mjera kojom se u nedostatku padavina nadoknađuje deficit vode u tlu i stvaraju povoljni uslovi za rast biljaka (Žurovec, 2012). Navodnjavanje može biti primijenjeno kao obavezna ili dopunska mjera. U uslovima Bosne i Hercegovine (BiH), za ratarske usjeve na otvorenom polju navodnjavanje predstavlja dopunsku mjeru, dok pri uzgoju povrtlarskih kultura u zaštićenom prostoru ili voćarskih, ono je obavezno.

Cijeli prostor BiH karakterizira izražen trend zagrijavanja, odnosno pozitivan trend maksimalne i minimalne temperature zraka tokom cijele godine, posebno se to odnosi na ljetni period. Značajan porast temperature vazduha rezultirao je i u promjeni količine vode koja se iz tla gubi evapotranspiracijom (ET), ali i promjenama ostalih komponenti vodnog bilansa tla, prvenstveno viška i manjka vode. Kao rezultat klimatskih promjena na prostoru BiH sve učestalija je pojava dugotrajnih suša većeg intenziteta (Čadro *et al.*, 2024), uz pojavu ekstremno visokih temperatura zraka i dugotrajnih toplotnih valova (FNC, 2021), posebno tokom ljetnih mjeseci kada su potrebe poljoprivrednih kultura za vodom i najveće (Čadro *et al.*, 2019). Javljaju se veoma nepovoljne godine, godine sa neadekvatnim rasporedom padavina ili padavinama koje nisu dovoljne za normalan rast i razvoj poljoprivrednih kultura. Kada suša otpočne, sektor poljoprivrede je obično prvi na udaru zbog njegove izuzetne zavisnosti od sadržaja vlage u tlu. Taj problem je posebno izražen u uslovima kišom hranjenog tipa poljoprivrede, kao što je kod nas najčešće slučaj.

Suho ratarenje i poljoprivreda hranjena kišom transformira se u poljoprivredu gdje navodnjavanje predstavlja obaveznu mjeru. Budućnost poljoprivrede u BiH direktno zavisi od primjene novih, održivih sistema proizvodnje. U tom cilju neophodno je dimenzionirati sisteme za navodnjavanje koji mogu da podmire, u vegetaciji, i tokom godina, promjenjive potrebe usjeva za vodom (Vukadinović, 2017).

Navodnjavanje se ne koristi samo za smanjenje deficita vode u tlu, nego i za ishranu biljaka kada se u adekvatnoj koncentraciji u vodi za navodnjavanje nalaze i hranjive materije (fertilizacija), ili zaštitu biljaka kada su u vodi zaštitna sredstva - pesticidi (fitosanitetska irigacija). Pored toga, koristi se i za ispiranje soli iz zemljišta (desalinizacija), a kako bi se njihove koncentracije smanjile na nivo ispod toksičnosti, hlađenje usjeva ili protiv-mraznu zaštitu.

Također, pogrešno navodnjavanje može imati čitav niz negativnih posljedica koje mogu rezultirati ekonomskim gubicima, smanjenjem prinosa, štetama na biljkama, degradaciji tla ili zagađenju okoliša. Pretjerano navodnjavanje može dovesti do razvoja bolesti koje u potpunosti mogu uništiti zasade. Pretjerano navodnjavanje također može dovesti do ispiranja hranjiva u dublje slojeve tla i podzemne vode, što smanjuje efikasnost njihovog iskorištavanja ali i mnogo važnije, dovodi do njihovog zagađenja. Također, može dovesti do zabarivanja površinskog sloja tla što za rezultat može imati degradaciju tla, posebno njegove strukture, te smanjenje udjela pora koje mogu infiltrirati i drenirati vodu, te pora koje vodu mogu zadržavati. Osim navedenog, dovodi i do zbijanja tla i stvaranja pokorice i sl., zaslanjivanja koje dovodi do povećanja koncentracije određenih soli u tlu do toksičnih nivoa za biljke. Ovo se posebno dešava prilikom navodnjavanja zaštićenog prostora sistemima lokalnog navodnjavanja, kao što je sistem kap po kap.

Prvi sistemi za navodnjavanje nalazili su se u Mezopotamiji još prije 6000 godina. Navodnjavanje je bilo razvijeno također i u drevnom Egiptu, Kini, Indiji, kao i u vrijeme Nabatejaca, koji su živjeli u regiji oko Petre u današnjem Jordanu. Ova drevna civilizacija, koja je cvjetala između 4. i 2. stoljeća prije nove ere razvila je sisteme navodnjavanja kako bi preživjela u sušnim uvjetima pustinje. Sumerani su izgradili otvorene kanale koji su dovodili vodu iz rijeka u polja, čime su omogućili uzgoj usjeva tijekom cijele godine. Jedan od najpoznatijih kanala je iz Sumerskog grada Lagaša i dug je bio 150 kilometara, a iskopan je prije 5500. godina (Ingo, 2018).


Navodnjavanje i razvoj poljoprivrede doveli su do ekonomskog razvoja ovih prostora ali često i do njihove propasti. Propast Sumera, oko 2000. godine prije nove ere, upravo počinje kao rezultat navodnjavanja. Prekomjerno navodnjavanje uzrokovalo je nakupljanje soli u tlu, što je smanjilo plodnost tla. Prinosi su opadali iz godine u godinu, uzrokujući društvene probleme, političku nestabilnost i ekonomski kolaps.

Početkom dvadeset i prvog stoljeća, kao rezultat negativnog uticaja čovjeka na vodne resurse, a koji se očituju u smanjenju dostupne količine svježje vode i pogoršanju njenog kvaliteta, razvoj navodnjavanja ide u pravcu tehnoloških rješenja koje osiguravaju efikasnije i preciznije navodnjavanje. Uporedo sa razvojem naprednih tehnologija i pametnih uređaja razvijaju se i pametni sistemi navodnjavanja, odnosno pametno navodnjavanje.

Vodni bilans tla


Povećanje temperature zraka i promjene u količini padavina rezultira i promjenama u evapotranspiraciji (ET) i vrijednostima osnovnih parametara vodnog bilansa (Giugliano *et al.*, 2013), koji nam pokazuje odnose ulaza i izlaza vode na određenom području u određenom vremenskom intervalu. Vodni bilans tla ili agrohidrološki bilans je od izuzetne važnosti u određivanju pristupačnosti vode u tlu, momenta navodnjavanja i količine vode koja će biti data tokom navodnjavanja (obrok navodnjavanja), potrebi poljoprivrednih kultura za vodom, analizi rizika od poplava, upravljanju vodama na nivou regije, analizi suše, studijama zaštite okoliša, razumijevanju mogućnosti za organizaciju poljoprivredne proizvodnje na nekom području, a koristi se i za modeliranje uslova uzrokovanih klimatskim promjenama i dizajniranje efektivnih mjera adaptacije i mitigacije (Pereira *et al.*, 2015; Žurovec *et al.*, 2017).

Zavisno od potrebe, vodni bilansa može biti rađen za dnevni, dekadni, mjesečni, sezonski ili čak godišnji nivo analize. Dnevni vodni bilans koristi se kako bi se prilagodile potrebe biljaka za vodom odnosno primijenilo navodnjavanje u pravom momentu i sa odgovarajućom normom, dok se vodni bilansi dužeg vremenskog intervala koriste za upravljanje vodama šireg područja, kao što je sliv nekog vodotoka. Shematski prikaz jednog takvog vodnog bilansa, sa svim elementima koji ulaze ili se dobivaju u toku njegove kalkulacije, uključujući temperaturu zraka (T), padavine (P), rezervu vode u tlu ili retencioni kapacitet (ST), vodni kapacitet tla, referentnu (ET_0) ili potencijalnu evapotranspiraciju (PET), aktuelnu evapotranspiraciju (AET), količinu snijega, direktni površinski oticaj i podzemni oticaj, prikazan je na grafikonu 1.



Grafikon 1. Elementi vodnog bilansa tla

Termin bilansa, kao jednostavnoga pristupa bilansiranju vode u tlu, sličnog onome u knjigovodstvu, iz ekonomije u hidrologiju uveo je američki (Arlington, Virdžinija) naučnik Charles Warren Thornthwaite, 1948. godine (Slika 22). Thornthwaite je vodni bilans razvio za tlo koje ima kapacitet za vodu od 300 mm (Thornthwaite, 1948). Međutim, kroz primjenu u praksi ova vrijednost je izmijenjena i danas se vrijednost prilagođava osobinama tla utvrđenim vodno-fizičkim analizama tla u laboratoriji ili procjenama na osnovu određenih parametara, a najčešće mehaničko – teksturnog sastava tla.




Slika 22. Tvorac termina vodni bilans tla,
Charles Warren Thornthwaite (7. mart 1899. - 11. juni 1963.)

Thornthwaite-ov vodni bilans je kasnije doživio mnoge izmjene i poboljšana u pravcu preciznijih proračuna uzimajući u obzir sve uticaje na ulazak, zadržavanje i kretanje vode u tlu, kao i skraćivanje vremenskog intervala za koji se radi. Sam Thornthwaite, zajedno sa Metherom, modifikuje svoj metod u više navrata. Zatim Palmer (1965) koriguje Thornthwaite-ovu metodu i dijeli tlo na dva sloja, prvi – obradivi ili površinski sloj (S_s), koji prihvata vodu od padavina i iz kojeg se voda direktno isparava, i drugi podpovršinski (S_u), koji se aktivira tek nakon što je voda isparila iz prvog sloja. Također, kao rezultat bilansiranja u okviru Pelmerovog bilansa dobiva se indeks suše – *PDSI* (eng. *Palmer Drought Severiry Index*), koji pokazuje intenzitet suše ili vlažnosti u određenom vremenskom periodu. Nastavak procesa unapređenja ide u pravcu definiranja površinskog oticaja Alley (1984), količine snijega i drugo (Dingman, 2002; McCabe & Markstrom, 2007).

U okviru svakog vodnog bilansa tla, pored padavina (P) i evapotranspiracije (ET) veoma važan parametar je rezerva vode u tlu. Posmatrano sa aspekta biljke, rezerva ukupno pristupačne vode u tlu (UPV), vode koju biljka može slobodno koristiti dijeli se na lako pristupačnu vodu (LPV) i teže pristupačnu vodu (TPV). Što je vode u tlo manje, ona je sve teže pristupačna biljci, jer je potrebna veća sila (sukcija) da biljka vodu usvoji korijenovim dlačicama. Pored ove pristupačne vode, u tlu možemo imati i nepristupačnu (nepokretnu) ili fiziološki neaktivnu vodu koja se drži apsorbirana – fizički vezana za čestice tla. Također, imamo i štetnu vodu, a to je ona koja zauzima gravitacione pore, pore koje u idealnim uslovima vlažnosti tla trebaju biti ispunjene zrakom.

Odnos pora tla (porozitet), glavni je faktor koji utiče ne ove odnose vode u tlu (Slika 23). Pa tako krupne pore (promjer $>10\mu m$) uvjetuju djelovanje gravitacione sile na vodu u tlu, srednje pore (promjer $0,2 - 10\mu m$) na pojavu kapilarne sile i procese kohezije i adhezije, dok u sitnim (finim) porama (promjer $<0,2 \mu m$) imamo sorpcionu silu. Pored ovoga, postoji i hidratna voda, a to je hemijski vezana voda u čvrstoj fazi tla. Voda u kapilarnim porama je biljci pristupačna, obzirom da su kapilarne sile dovoljno jake da se odupru gravitaciji, a opet dovoljno slabe da omoguće korijenu biljke da vodu upije.

Svako tlo ima karakteristične vodne konstante, koje predstavljaju vrijednosti volumnog sadržaja vode pri određenom negativnom vodnom potencijalu (Ψ) ili sukuciji (tenziji) koja se definira logaritamskom pF skalom. U uslovima kada je tlo potpuno ispunjeno vodom, sve grupe pora su ispunjene vodom, tlo ima vrijednost pF 0, odnosno ovakvo stanje vlažnosti tla definira se kao maksimalni vodni kapacitet (MVK). Kad se voda procijedi iz gravitacionih pora tla, a ostane u kapilarnim i sitnim, stanje vlažnosti tla označeno je kao Poljski vodni kapacitet (PVK). Dešava se pri vrijednosti pF od 2,4 ili vrijednosti vodnog potencijala od 0,33 bara. Ovo je izuzetno važan nivo vlažnosti tla, obzirom da definira gornju granicu pristupačne vode biljci. Sa aspekta navodnjavanja, predstavlja maksimalan nivo vode u tlu do kojeg je potrebno navodnjavati. Ako se ovakav nivo vlažnosti određuje laboratorijskim istraživanjima definira se kao Retencioni vodni kapacitet (R_k).



Slika 23. Vodne konstante tla

S obzirom da pristupačnu vodu dijelimo na lako i teže pristupačnu, tačka pri kojoj se to dešava naziva se lentokapilarna tačka, a u suštini predstavlja granicu između djelovanja kapilarnih i sorpcionih sila u tlu. Pri Lentokapilarnoj vlažnost (LK) voda u tlu se drži silom od 3,8 pF ili 6,25 bari. Nakon što je iz tla izgubljena i teže pristupačna voda (TPV), voda se počinje gubiti iz sitnih pora tla. Ovo stanje vlažnosti tla naziva se Vlažnost trajnog venuća (VTV) i predstavlja vlažnost tla pri kojoj biljke nemaju mogućnost usvajanja vode, sila držanja vode od strane tla je 4,2 pF ili 15,5 bari (Slika 24). U poljoprivrednoj proizvodnji ovo stanje vlažnosti tla ukazuje na vodni stres i može dovesti do potpunog sušenja biljke.

Vodne konstante (MVK, PVK, LK, VTV), higroskopna vlažnost tla i volumna specifična gustina tla (VSG) određuju se laboratorijskim analizama. Analize mogu biti obavljene na neporemećenom (cilindar kopeckog) ili poremećenom uzorku tla, standardnim laboratorijskim metodama ili specijalizovanim laboratorijskim uređajima (membranski aparati, boks sa kaoli glinom). Naposljetku, moguće je odrediti njihove vrijednosti i indirektnim, računskim metodama.

Standardna, laboratorijska metoda za precizno određivanje vlage u tlu podrazumijeva gravimetrijski postupak (termogravimetrijski metod) - kvantitativno određivanje sastojaka (vode i čvrste faze tla) na osnovu mase. Tokom ovog postupka, glavni koraci su vaganje uzorka tla, sušenje na 105°C do konstante težine i ponovno vaganje, razlika masa predstavlja maseni udio vode u uzorku tla (Mas. %), koji se izražava kao relativna vrijednost. Množenjem masenog udjela vode u tlu sa volumnom specifičnom gustinom tla (g/cm³) dobiva se volumni sadržaj vode u tlu vol. %, po formuli:

$$\text{Volumni sadržaj vode u tlu (Vol. \%)} = \frac{\text{Masa vode (g)}}{\text{Masa tla (g)}} \times \text{gustina tla} \left(\frac{\text{g}}{\text{cm}^3} \right)$$

Mada standardna, ova metoda nema praktičnu primjenu jer je dugotrajna, destruktivna (uzorak se uništava) i skupa. Metoda se isključivo koristi za naučne svrhe ili za baždarenje i korekciju drugih metoda ili uređaja za određivanje vlažnosti tla, kao što su senzori za vlagu tla.

Praktične metode podrazumijevaju korištenje različitih uređaja ili senzora koji se postavljaju u tlo i vrše mjerenja njegove vlažnosti.

Računski je moguće odrediti ukupno pristupačnu (UPV) i lako pristupačnu vodu (LPV) u tlu iz odnosa poljskog vodnog kapaciteta (PVK) i vlažnosti trajnog venuća (VTV), odnosno lentokapilarne tačke (LK) na osnovu jednačina:

$$UPV(\text{Vol. \%}) = PVK - VTV$$

$$LPV(\text{Vol. \%}) = PVK - LK$$

Podatke o volumnom sadržaju vode pri određenoj vodnoj konstanti računskim putem je moguće izraziti kao količinu vode (mm ili m³/ha) u tlu na određenoj površini (parceli) i do definirane dubine (h) posmatranja. U svrhu navodnjavanja, vrijednost dubine se prilagođava zavisno od dubine aktivne zone korijena, te se kreće od 0,1 – 0,7 m. Jednačina za proračun sadržaja vode u tlu u m³/ha, glasi:

$$\text{Sadržaj vode u tlu (m}^3\text{/ha)} = 100 \times h \times \text{Volumni sadržaj vode u Vol \%}$$

S obzirom da se obrok (količina vode data jednim navodnjavanjem) i potrebe biljaka za navodnjavanjem najčešće izražavaju u mm ili m³/ha, dobivene vrijednosti trenutnog stanja vlažnosti tla ili vlažnosti pri određenim vodnim konstantama, mogu se upoređivati, te se na taj način može bilansirati vlažnost tla i definirati momenti za navodnjavanje.

Sve navedene metode za određivanje važnosti tla, s obzirom na komplikovanu proceduru utvrđivanja, služe za određivanje vodo-fizičkih osobina tla ili kalibraciju terenskih uređaja za praćenje stanja vlažnosti tla kao što su različiti senzori.

Održiva poljoprivreda i tehnološki napredak

Održiva poljoprivreda bazira se na razvijanju tehnologija i praksi koje nemaju negativan uticaj na okoliš, koje su poljoprivrednim proizvođačima pristupačne, te vode ka boljoj iskorištenosti resursa i povećanju proizvodnje hrane. To je veoma složen zadatak, koji je pod uticajem mnogih faktora koji moraju biti pod kontrolom, kao što su vrijeme, raspoloživost vode i hranjiva, efikasno eliminiranje konkurentskih korova, zaštita od bolesti i štetnika i sve to optimizirano i podređeno agrotehničkim normama i ostvarenju profita.

Moguće rješenje je primjena visoke, potpuno nadzirane tehnologije uz potpuno poznavanje stanja usjeva, proizvodne parcele i prinosa. Takav pristup je omogućen primjenom različitih senzora stanja usjeva i tla (od senzora na parceli, pa sve do beskontaktnih senzora na bespilotnim letjelicama ili satelitima), multispektralnom analizom usjeva, fotogrametrijom i daljinskim osmatranjem te korištenjem softvera za upravljanje proizvodnjom ili određenim aktivnostima unutar nje (Vukadinović, 2017).

Napredak informaciono-komunikacijskih tehnologija (ICT) značajno je unaprijedio i poljoprivredu i usmjerio je u pravcu održivosti. Kao rezultat brzog razvoja ICT-a danas je u upotrebi veliki broj pojmova koji se koriste naizmjenično, ali imaju različita značenja i naglašavaju različite aspekte tehnološkog napretka u poljoprivredi. Ovi pojmovi uključuju Pametnu poljoprivredu, Digitalnu poljoprivredu, Digitalni farming, Preciznu poljoprivredu i Poljoprivredu 4.0. Mnogi od ovih pojmova nemaju adekvatan prevod na naš jezik, pa se često u literaturi koriste engleski termini.

Pametna poljoprivreda se odnosi na upotrebu tehnologije za optimizaciju poljoprivrednih praksi, često s fokusom na održivost i efikasnost. Uključuje korištenje podataka, dobivenih u realnom vremenu, iz različitih izvora (npr. senzori, sateliti, dronovi), za praćenje, automatizaciju i unapređenje poljoprivrednih procesa. Ovakva poljoprivreda koristi tehnologije kao što su IoT uređaji (Internet stvari), automatizirane mašine i sl. Osnovna ideja je poboljšanje donošenja odluka korištenjem informacija u realnom vremenu i analitike. Internet stvari – IoT (*eng. Internet of things*) odnosi se na sistem međusobno povezanih objekata spojenih na internet koji su u stanju da prikupljaju i prenose podatke putem bežične mreže bez ljudske intervencije (Slika 25).


Pametna poljoprivreda kombinira senzorima i digitalnim uređajima prikupljene podatke i fotografije sa analizama u realnom vremenu, kako bi se poboljšala produktivnost poljoprivrednog gazdinstva i to kroz mapiranje prostorne varijabilnosti u parceli. Pri tome se koristi različitim softverskih i hardverskim rješenjima, kao što su senzori postavljeni na biljku, u tlo ili na bespilotnu letjelicu (dron), kao i aplikacije (računarske i mobilne) za obradu informacija i upravljanje poljoprivrednim gazdinstvom u realnom vremenu.

Kao rezultat, povećava se efikasnost proizvodnje, smanjuju inputi, povećavaju prinosi, a značajno smanjenje negativan uticaja na okoliš.

Prema tome, pametna poljoprivreda uključuje slijedeće:

- digitalne uređaje,
- softverske aplikacije,

- sisteme komunikacije i razmjene informacija, koji obuhvataju i bežične mreže za komunikaciju između uređaja,
- tehnologije pozicioniranja,
- daljinsko osmatranje/detekcija i fotogrametrija,
- upravljanje bazama podataka (prikupljanje, skladištenje, provjera kvalitete, strukturiranje, zaštita, obrada, analiza, ažuriranje i pristup podacima).



Slika 25. Elementi pametne poljoprivrede

Sveprisutne klimatske promjene i potreba stalnog praćenja vremenskih uslova i prilagođavanje njima, definira i pojam Klimatski pametna poljoprivreda (*eng. Climate smart agriculture - CSA*). CSA je pristup za transformaciju i izmjene poljoprivrednih sistema kako bi se u okviru njih efikasno provodio održivi razvoj i postigla sigurnost hrane u uslovima promjenjive klime (FAO, 2020). Klimatski pametna poljoprivreda ima tri glavna cilja:

1. održivo povećanje poljoprivredne produktivnosti i prihoda,
2. prilagođavanje i izgradnja otpornosti na klimatske promjene, i
3. smanjenje i / ili uklanjanje emisija stakleničkih plinova, gdje je to moguće.

Digitalna poljoprivreda je nešto širi pojam koji obuhvata sve vrste digitalnih tehnologija korištenih u poljoprivredi. To uključuje softvere, platforme i digitalne alate koji pomažu u prikupljanju podataka, praćenju i upravljanju poljoprivrednim aktivnostima. Opseg može varirati od

mobilnih aplikacija za upravljanje farmama do složenih AI algoritama koji predviđaju prinose. Fokus ovakve poljoprivrede je digitalna transformacija svih poljoprivrednih procesa. U okviru digitalne poljoprivrede imamo i digitalni farming. On podrazumijeva praktičnu primjenu digitalnih rješenja na nivou farme (poljoprivrednog gazdinstva). Prema tome, obuhvata tehnologije kao što su softveri za upravljanje farmama, digitalni interfejsi za praćenje rada poljoprivredne mehanizacije, sisteme za navodnjavanje ili odvodnjavanje ili stanja usjeva. Uključuje integraciju podataka iz različitih izvora (mehanizacija, vremenski uvjeti, senzori u tlu) kako bi se optimizirale odluke na nivou farme, često putem digitalnih interfejsa poput mobilnih aplikacija ili platformi.

Precizna poljoprivreda se fokusira na primjenu tačne količine inputa (kao što su voda, đubriva ili pesticidi) na pravo mjesto i u pravo vrijeme unutar polja, na osnovu detaljnih podataka. Cilj je povećanje efikasnosti, maksimiziranje prinosa i minimiziranje uticaja na okolinu upravljanjem varijabilnošću unutar polja. U takvoj poljoprivredi koriste se GPS-vođeni traktori, tehnologija promjenjivih stopa (VRT), dronovi za nadzor usjeva i drugo. Tehnologija promjenjivih doza (VRT) podrazumijeva primjenu poljoprivrednih inputa (sjeme, đubriva, pesticidi i voda) u prilagodljivim količinama zavisno od stvarnih potreba različitih zona u okviru određene poljoprivredne površine. Prilagođavanje količina datih inputa bazirano je na prikupljenim podacima u realnom vremenu, za razliku od do sada korištenog pristupa uniformne količine za cijelo polje. Dostupnost velikoga broja informacija pri donošenju odluka je osnovna pretpostavka precizne poljoprivrede (Krevh, 2018).

Poljoprivreda 4.0 odnosi se na transformaciju poljoprivrednog sektora u skladu sa širim konceptom Industrije 4.0. Uključuje integraciju najsavremenijih tehnologija poput umjetne inteligencije (AI), robotike, mašinskog učenja (*eng. machine learning*) i velikih baza podataka (*eng. big data*) u poljoprivredu. Poljoprivreda 4.0 naglašava automatizaciju, povezanost - komunikaciju i upotrebu pametnih mašina koje mogu raditi samostalno ili uz minimalnu ljudsku intervenciju.

Prema tome, pametna poljoprivreda je usmjerena na efikasnost i održivost korištenjem podataka u realnom vremenu, dok digitalna poljoprivreda obuhvata sve digitalne inovacije u poljoprivredi, a njihova praktična primjena na farmi je digitalni farming. Precizna poljoprivreda naglašava optimizaciju inputa korištenjem detaljnih podataka. U konačnici Poljoprivreda 4.0 označava širu transformaciju poljoprivrede ka automatiziranom, AI-pokretanom sektoru.

Svi definirani pojmovi mogu se primijeniti i na upravljanje vodnim resursima u poljoprivredi, posebno u kontekstu navodnjavanja. U tom smislu, upravljanje vodnim resursima treba biti integralno i održivo kako bi se osiguralo dugoročno korištenje ovog dragocjenog prirodnog resursa. Održivo upravljanje vodom ključan je faktor za sve korisnike pitke (slatke) vode, jer omogućava ravnomjernu i dugotrajnu dostupnost vode za sve potrebe, uključujući poljoprivredu, bez ugrožavanja budućih generacija.

Mjera koja služi za praćenje obrasca potrošnje pitke vode naziva se vodni otisak (*eng. water footprint*). To je ekološki pokazatelj koji određuje ukupno korištenje pitke vode za proizvodnju dobara i usluga koje konzumiraju pojedinci, zajednice ili kompanije. Mjeri se u m³ ili l utrošene ili onečišćene vode u jedinici vremena. Može se izračunati za različite subjekte, uključujući pojedince, porodice, gradove ili čitave nacije, pružajući uvide u njihove navike potrošnje vode i ekološke uticaje.

Vodni otisak se sastoji iz: Plavog vodnog otiska koji se odnosi na vodu korištenu u proizvodnji, posebno za navodnjavanje ili industrijske potrebe; Zelenog vodnog otiska koji predstavlja vodu

koju koriste biljke (poljoprivreda i šumarstvo) za izgradnju svoje biomase ili transpiraciju; i Sivog vodnog otiska koji pokazuje količinu pitke vode potrebne za razrijeđivanje zagađivača kako bi se ispunili standardi kvaliteta vode, odnosno on prikazuje uticaj zagađenja na vodne resurse.

Pametno navodnjavanje

Pametno navodnjavanje predstavlja integraciju naprednih tehnologija i praksi koje omogućavaju efikasno korištenje vode u poljoprivredi, posebno u kontekstu klimatskih promjena i održivog razvoja. Ovaj pristup obuhvata korištenje senzora, automatizovanih sistema, aplikacija i sistema za podršku u odlučivanju (DSS), čime se smanjuje potrošnja vode i povećava prinos usjeva. U posljednjem periodu razvoj pametnih sistema navodnjavanja je rezultat integracije vještačke inteligencije (AI) u ove sisteme.

Pametno navodnjavanje predstavlja jedan od mehanizama pametne ili precizne poljoprivrede, pristupa upravljanja poljoprivrednim gazdinstvom korištenjem informaciono-komunikacijskih tehnologija (ICT), podataka satelitskog pozicioniranja i daljinskog osmatranja, a sa ciljem optimizacije povrata uložених sredstava uz smanjenje negativnog uticaja na okoliš (Zarco-Tejada *et al.*, 2014). Najjednostavnije opisana precizna poljoprivreda predstavlja „**primjenu prave mjere na pravom mjestu u pravo vrijeme**“ (Gebbers & Adamchuk, 2010). U kontekstu navodnjavanja to bi značilo davanje vode adekvatne količine i kvaliteta, u pravo vrijeme, pravoj biljci, na pravom mjestu.

Podaci i informacije su u središtu procesa pametnog navodnjavanja. Prikupljanje, obrada i skladištenje podataka mogu se odvijati u zatvorenom ili otvorenom sistemu. U zatvorenom sistemu, podaci se prikupljaju i obrađuju lokalno unutar sistema, bez vanjske mrežne (internet) komunikacije. To podrazumijeva da se pohrana i obrada podataka odvija na računaru koji je lociran na farmi ili unutar područja koje koristi sistem pametnog navodnjavanja. Podaci se ne dijele ili šalju vanjskim serverima, čime se smanjuje rizik od gubitka podataka, a sistem je manje ovisan o stabilnosti internetske veze. Međutim, njihova funkcionalnost može biti ograničena u pogledu pristupa udaljenim bazama podataka i naprednim analitičkim alatima.


U otvorenom sistemu, podaci se prikupljaju lokalno ili putem interneta s udaljenih uređaja ili iz dostupnih baza podataka (*eng. cloud*). Izvor podataka mogu biti senzori u tlu ili biljkama, senzori u okviru meteorološke stanice koje prate klimatske parametre (npr. temperaturu, padavine, vlažnost zraka, vjetar), podaci sa dronova ili satelita i sl. Ovi podaci mogu biti u realnom vremenu, pružajući trenutne uvide, ili rezultat napredne obrade, uključujući prediktivne modele (prognozne sisteme) koji pomažu u planiranju navodnjavanja unaprijed. Podaci se pohranjuju u centralnu bazu podataka, koja može biti smještena lokalno ili na *cloud* platformi, ovisno o arhitekturi sistema. Nakon što su podaci prikupljeni i pohranjeni, oni se analiziraju putem algoritama i softverskih aplikacija.

Ove analize mogu uključivati procese poput:

- proračun vremenskog rasporeda – turnusa navodnjavanja,
- prepoznavanje obrazaca u korištenju vode,
- procjena potreba za navodnjavanjem na temelju stanja tla i vremenskih uslova i sl.

Nakon analize, odluke o navodnjavanju donose se automatski ili uz ljudsku intervenciju. Na osnovu tih odluka, sistem može pokrenuti ili zaustaviti navodnjavanje putem automatizovanih

ventila i pumpi. Internet konekcija osigurava kontinuiranu povezanost između različitih dijelova sistema, omogućavajući daljinsko upravljanje putem aplikacija na mobilnim uređajima ili računarima (Grafikon 2).




Grafikon 2. Shema pametnog sistema za navodnjavanje

Prenos informacija sa senzora do kontrolnog uređaja i baze podataka, odnosno aplikacije, kao i od aplikacije do automatizovanih sistema i pumpe, može se odvijati putem žičane ili bežične komunikacije, zavisno o infrastrukturi i specifičnim zahtjevima sistema.

Sumirajući sve ranije navedeno, pametno navodnjavanje predstavlja transformativni pristup u upravljanju vodom u poljoprivredi, koristeći modernu tehnologiju za povećanje efikasnosti, očuvanje resursa i povećanje kvaliteta i kvantiteta proizvodnje. Integracijom različitih elemenata kao što su senzori, automatizacija, analiza podataka i IoT povezanost, ovi sistemi pružaju prilagođena rješenja koja odgovaraju specifičnim potrebama različitih usjeva i okolišnih uvjeta.

Generalno posmatrano, aktivnosti vezane za navodnjavanje imaju dvije faze:

- a) Faza planiranja i projektovanja, uključuje detaljno projektovanje sistema za navodnjavanje koji odgovara potrebama biljne vrste koja se planira navodnjavati, ali i karakteristikama tla, klime, raspoloživosti vode i opreme, kao i načina proizvodne. U okviru ove faze potrebni su građevinski eksperti i agronomi. Faza projektovanja također uključuje i elemente organizacije upravljanja vodom za navodnjavanje na određenom definiranom području (slivu), a koji osigurava da su svi korisnici vode (poljoprivreda, industrija, okoliš i sl.) adekvatno snabdjeveni ovim prirodnim resursom i da se on koristi na održiv način.
- b) Faza eksploatacije, koja se fokusira na određivanje rokova zalijevanja, obroka i normi navodnjavanja, a zavisi od složenih odnosa i interakcija biljka-tla-atmosfera (Slika 26).



Slika 26. Proračunska shema AquaCrop modela¹ (Vanuytrecht *et al.*, 2014)

Upravo u fazi eksploatacije sistema za navodnjavanje dolazi do izražaja pametno navodnjavanje kao rješenje za konstantno pitanje, kada i koliko navodnjavati?


Generalno gledano, režim navodnjavanja, te potreba vode za navodnjavanje poljoprivrednih kultura koje se planiraju navodnjavati u određenoj godini, određuje se slijedećim redoslijedom:

1. rokovi sjetve/sadnje i ukupno trajanje vegetacije;
2. evapotranspiracija - referentna evapotranspiracija (ET_0) i njena dinamika u toku vegetacionog perioda;
3. dubina aktivnog sloja tla, odnosno sloja u kojem se nalazi glavnina korijenovog sistema u različitim fazama razvoja određene kulture;
4. prirodna zaliha vode u tlu (podzemna voda, stanje vlažnosti tla na početku vegetacije) i njena dinamika u vegetacionom periodu;
5. dozvoljene donje i gornje granice vlažnosti tla u njegovom aktivnom sloju;
6. količina i raspored padavina, odnosno efektivnih padavina (P_{eff}) koje dopijevaju u tlo i koje biljka može koristiti u toku vegetacije;

¹ Isprekidanom linijom su prikazani procesi pod utjecajem vodnog (a-e) i temperaturnog (f-g) stresa; CC - pokrovnost tla zelenim dijelovima biljke; Zr - dubina korijena; ET_0 - referentna evapotranspiracija; WP - normalizirana produktivnost vode; HI - žetveni indeks; i GDD - Jedinice prirasta, eng. Growing degree days.


7. potrošnja vode i njena dinamika, odnosno definira se norma navodnjavanja, kao i dinamika promjene dnevne potrošnje vode spram faze razvoja u kojoj se biljka nalazi i sistema za navodnjavanje;
8. obrok, rokovi i turnusi navodnjavanja.

Pametni sistemi za navodnjavanje na određeni način, i uz različit nivo preciznosti, dolaze do svih ovih informacija i na osnovu njih daju preporuke kada i koliko navodnjavati određenu poljoprivrednu kulturu. Preciznost informacija zavisi od njene namjene. Detaljni podaci koji se dobivaju na osnovu egzaktnih terenski istraživanja, dugoročnih analiza klimatskih uslova, fenoloških karakteristika poljoprivrednih kultura, laboratorijskih analiza karakteristika tla posebno njegovih vodno-fizičkih osobina, koriste se u modelima koji imaju naučno-istraživačku svrhu. Ovakva naučna istraživanja mogu poslužiti i za kreiranje računskih metoda i softverskih modela i aplikacija koje mogu koristiti istraživači ili eventualno agronomi. Primjeri ovakvih softverskih modela za određivanje potreba vode za navodnjavanje su: *CROPWAT* (Smith, 1992), *SPAW* (Rao & Saxton, 1995), *ISAREG* (Pereira *et al.*, 2003), *CUP-E*, *WISE*, *CROPFLEX* (Karleuša, 2007), *AquaCrop* (Raes *et al.*, 2009) i *SIMDualKc* (Ran *et al.*, 2017) (Slika 27). Mada im je osnovna namjena praćenje potrebe za vodom, također, predstavljaju modele rasta i razvoja poljoprivrednih usjeva.



Slika 27. Primjeri softverskih modela za određivanje potrebe za vodom

Ovakvi softverski modeli često uključuju simulacije i prostorni prikaz analiziranih parametara, kroz primjenu geografskom informacionog sistema (GIS), što im omogućava istovremene analize za nekoliko usjeva i različite vremenske intervale (Liu *et al.*, 1998). Model je u stanju da generiše alternative rasporeda navodnjavanja, koje se prilagođava različitim potrebama ili prognozama. Osnovna vodilja je eliminacije relativnog gubitka prinosa, koji nastaje kao rezultat manje aktuelne evapotranspiracije usjeva u odnosu na njenu potencijalnu.



Slika 28. Potrebni ulazni podaci za AquaCrop model (Steduto *et al.*, 2009)

Obzirom na potrebne informacije (Slika 28) i podatke koje je potrebno prikupiti te na adekvatan način unijeti u ovakve modele, isti nemaju praktičnu primjenu. Poljoprivredni proizvođači ne trebaju biti stručni za takvo nešto niti imaju vremena baviti se prikupljanjem i unošenjem ovakvih detaljnih informacija. Njima su potrebna rješenja čija je preciznost zadovoljavajuća, rezultati dovoljni da opravdaju njihovo korištenje, a vrijeme potrebno za donošenje odluke kada i koliko navodnjavati minimalno.

Ključni elementi pametnog navodnjavanja podrazumijevaju:

1. Kontrolne jedinice za navodnjavanje

- Kontrolne jedinice zasnovane na vremenskim uslovima koriste lokalne vremenske podatke (evapotranspiraciju i padavine) kako bi automatski prilagodili termine i obroke navodnjavanja:
 - Bazirani na predefinisanim momentima navodnjavanja;
 - Bazirani na historijskim (prosječnim) podacima o evapotranspiraciji;
 - Bazirani na mjerenjima na licu mjesta.
- Kontrolne jedinice zasnovane na vlažnosti tla.

2. Korištenje senzora

- Senzori za vlagu tla;
- Senzori vremenskih uslova (mini-meteorološke stanice);

- c. Senzori za evaporaciju i evapotranspiraciju;
- d. Senzori vlage lista.

3. Automatizacija i upravljanje na daljinu

- a. Automatski ventili: električni ventili koji se mogu otvarati na daljnu preko mobilnih aplikacija ili računara;
- b. Cloud platforme: podaci koji se prikupljaju sa različitih senzora često se šalju na cloud platforme gdje se primjenjuju napredne analize sa ciljem optimizacije navodnjavanja.

4. Obrada i analiza podataka

- a. Upravljanje u realnom vremenu;
- b. Prognozni modeli.

5. Inegracija sa IoT: podrazumijeva povezivanje sa IoT uređenima koji osiguravaju komunikaciju između senzora, kontrolnih jedinica i korisničkog interfejsa te na taj način postiže se upravljanje sistemom i monitoring njegovog rada.

6. Dronovi i daljinsko osmatranje: dronovi koji nose odgovarajuće kamere mogu poslužiti za praćenje stanja zdravlja usjeva i nivoa vlage u tlu.

7. Voda-Energija Nexus: neka pametna rješenja za navodnjavanje također uzimaju u obzir energetska efikasnost optimizirajući rad pumpi na osnovu podataka u realnom vremenu, čime se smanjuju troškovi energije povezani s isporukom vode.

Upravljanje pametnim sistemom za navodnjavanje

Kada je sistem za navodnjavanje već u funkciji, potrebno je odrediti rokove i obroke navodnjavanja i norme zalijevanja, tj. odrediti “kad i koliko” vode treba isporučiti kulturama na parceli koja se navodnjava.

Količina vode koja se treba dati jednim navodnjavanjem (obrok navodnjavanja) izražava se u mm, m³ i litrima, a zavisi od:

- dubine tla do koje se želi navodnjavati, što je u direktnoj vezi sa aktivnim slojem tla gdje se nalazi glavna masa korijena biljke koju navodnjavamo,
- karakteristika tla, posebno se to odnosi na vodne konstante tla,
- vlažnosti tla prije samog navodnjavanja, i
- načina navodnjavanja.

Ovim, jednim navodnjavanjem potrebno je tlo u zoni korijena biljke navlažiti do PVK. Da bi se odredili rokovi i norme zalijevanja koriste se metode bazirane na stanju biljke, tla ili klimatskih parametara.

Tradicionalne metode podrazumijevaju vizuelno zapažanje reakcije biljke na vodni stres kao što su promjena boje ili opadanje turgora. Ovakve metode nisu adekvatne s obzirom da do retardacije u porastu kod biljke dolazi i mnogo prije nego ona pokaže vizuelne znakove stresa. Slično je i sa metodom određivanja vlažnosti tla rukom ili predefinisanim – turnusnim momentima navodnjavanja. Ovi pristupi su subjektivni i neprecizni te dovode do grešaka. Biljke u takvim okolnostima ne ostvaruju svoj maksimalni potencijal i prinosi su umanjeni. Kako bi taj problem bio riješen koriste se uređaji za praćenja stanja biljke, tla ili klimatskih parametara.

Ovdje ćemo se fokusirati na pristup na bazi praćenja klimatskih parametara koji u suštini ima kalkulaciju dnevnog vodnog bilansa tla, dok će princip rada uređaja za praćenje stanja biljke i tla biti pojašnjen u narednom poglavlju.

Manjak (deficit) vode u tlu, odnosno potrebe biljaka za navodnjavanjem, može se odrediti bilansnom procedurom uz adekvatne podatke. Prije svega to se odnosi na u vremenu promjenjive klimatske parametre temperature zraka ($^{\circ}\text{C}$), relativne vlažnosti zraka (%), brzine vjetra (m/s), insolacije (h) i količine padavina (mm), a zatim i na nepromjenjive podatke vezane za vodno-fizičke karakteristike tla, preciznije rezervu lako pristupačne vode tla (mm).

Standardna automatska meteorološka stanica, postavljena na odgovarajuće mjesto na parceli, a kako je to pojašnjeno ranije u poglavlju 2., sasvim je dovoljna za prikupljanje ovih podataka u realnom vremenu. Ovakve stanice se često nazivaju ago-meteo stanice ili mini-meteo stanice.

Prikupljeni podaci se koriste za proračun i procjenu evapotranspiracije (ET), podatka koji ukazuje na gubitak vode iz tla (prenos vode i energije u atmosferu) putem procesa evaporacije (E) i transpiracije (T), dok podaci o padavinama i stanju vlage u tlu iz prethodnog perioda analize predstavljaju ulaze vode. Razlika ovih ulaza i izlaza vode može biti određen manjak (deficit), koji se sumira sve dok ne dosegne ranije definirani obrok navodnjavanja, a koji je prilagođen načinu navodnjavanja. Za lokalne sistem navodnjavanja, kao što je sistem navodnjavanja „kap po kap“ obično se podešava obrok navodnjavanja do 10 mm, dok sistemi kišenja mogu imati obroke navodnjavanja i do 40 mm. Kad je bilansnim postupkom postignuta vrijednost obroka navodnjavanja to je ujedno i signal za aktivaciju sistema, koji isporučuje definiranu količinu vode, a sam proračun se resetuje.

Precizna procjena evapotranspiracije (ET) je veoma teška, a što je rezultat složenih interakcija u okviru sistema tlo – biljka – atmosfera, odnosno zbog velikog broja parametara uključenih u ovaj proces, kao što su: temperatura zraka, vlažnost zraka, sunčevo zračenje, pritisak vodene pare i drugi (Allen *et al.*, 1998). Evapotranspiracija zavisi od četiri ključna faktora. Prvi i najvažniji je vlažnost tla, jer do evapotranspiracije ne može doći ako u tlu nema vode. Međutim, ako u tlu ima dovoljno vode, na evapotranspiraciju utiču ostala tri faktora: vrsta biljke, njena razvijenost i vremenski (klimatski) uslovi.

Evapotranspiracija se može mjeriti direktno veoma skupim i komplikovanim uređajima ili procijeniti različitim računskim metodama. Ove računske metode se razlikuju prema zahtjevima za ulaznim podacima i preciznosti. U Svijetu su široku primjenu našle metode po Thorntwaite-u (Thorntwaite, 1948), Turc-u (Turc, 1961), Penman-u (Penman, 1963), Hargreaves (Hargreaves & Samani, 1985) i sl.

Od 2000. godine naučnici širom svijeta prihvataju i isključivo preporučili FAO-56 Penman-Monteith metodu (FAO-PM) kao standardnu jednačinu (Čadro *et al.*, 2019a) za proračun evapotranspiracije (ET):

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T_{sred} + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)}$$

gdje je:

ET_0 referentna evapotranspiracija (mm/dan),

R_n ukupno sunčevo zračenje na površini usjeva (MJ/m²/dan),

G zemljišni fluks toplote (MJ/m²/dan),

T_{sred} srednja temperatura vazduha na 2 m visine (°C),

u_2 brzina vjetra na 2 m visine (m/s),

e_s pritisak vodene pare pri zasićenju (kPa),

e_a aktuelni pritisak vodene pare (kPa),

$e_s - e_a$ deficit pritiska vodene pare na 2 m visine (kPa),

Δ pad krive pritiska vodene pare (kPa/°C) i

γ psihrometrijska konstanta (kPa/°C).

Ovako proračunate ET naziva se referentnom evapotranspiracijom, obilježava sa ET_0 , a predstavlja vrijednost evapotranspiracije sa hipotetičke referentne kulture (travnjak) koja aktivno raste, obezbjeđena je sa dovoljno vode, potpuno zasjenjuje tlo i ima ujednačenu visinu od 0,12 m.

Obzirom da pametni sistem navodnjavanja podrazumijevaju precizne proračune, evapotranspiracija se proračunava za svaku biljnu vrstu zavisno od faze razvoja u kojoj se nalazi, i u tom slučaju dobivamo evapotranspiraciju kulture (ET_c). Za to se koristi standardna metodologija definirana u dokumentima *FAO Irrigation & Drainage Paper br. 56* (Allen *et al.*, 1998).


Prema tome, u okviru praktičnih modela proračuna potreba za navodnjavanjem, evapotranspiracija može biti određena na osnovu:

- prosječne evapotranspiracije,
- regionalnih podataka,
- mjerenja na licu mjesta.

U slučaju da ne postoji dovoljno relevantnih podataka za proračun evapotranspiracije, dok su podaci o temperaturama i padavinama dostupni, moguće je koristiti prosječne vrijednosti evapotranspiracije ili historijske podatke za određenu lokaciju.

Regionalni podaci uključuju dostupne baze podataka kojima sistem pristupa kako bi preuzeo relevantne informacije za područje na kojem se nalazi parcela. Ovaj način prikupljanja podataka je čest, posebno zbog relativno visokih troškova opreme potrebne za praćenje klimatskih parametara na vlastitoj parceli. Takvi podaci su obično pouzdaniji u regijama sa ujednačenim reljefom, dok klimatski parametar poput padavina može predstavljati izazov zbog velikih prostorno-vremenskih


varijacija. Baze podataka često sadrže informacije sa tačaka mjerenja na lokacijama meteoroloških uređaja, ali i interpolacione modele koji omogućavaju kreiranje prostornih podataka za sve relevantne parametre. Na ova način mogu se koristiti i meteorološke stanice koje se nalaze u blizini parcele na kojoj se upravlja sistemom za navodnjavanje. Princip je, što se mjerna stanica nalazi dalje, to je podatak manje precizan.



Slika 29. Primjer računarske aplikacije za upravljanje pametnim sistemom za navodnjavanje

Sistemi za podršku u upravljanju navodnjavanjem mogu biti softverski alati pohranjeni lokalno na kontrolnom računarunutar poljoprivrednog gazdinstva koje se navodnjava, ali i online servisi koji zahtijevaju internet vezu za pristup i korištenje (Slika 30). U oba slučaja, prije korištenja potreban je unos prostornih i organizacionih karakteristika parcele, uključujući lokaciju, granice, površinu, nagib, te vrstu poljoprivredne kulture. Unose se podaci o rokovima sjetve/sadnje, broju biljaka, fazama razvoja, trajanju vegetacije, korijenovom sistemu i karakteristikama tla, poput tipa tla, mehaničkog sastava, vodnih kapaciteta i plodnosti. Ovi servisi također omogućavaju praćenje stresa biljaka uzrokovanog bolestima, štetočinama ili nedostatkom hranjivih tvari. Kako bi se olakšao proces, često je moguće odabrati standardne uslove za određene kulture i tipove tla (Slika 29).

Ovakvi servisi najčešće su dostupni i kao desktop aplikacija na računarima i kao mobilna aplikacija, što osigurava daljinsko upravljanje pametnim sistemom za navodnjavanje (Slika 30).



Slika 30. Primjer mobilne aplikacije za upravljanje pametnim sistemom za navodnjavanje

Pored veze sa izvorima podataka, servis može biti direktno povezan sa kontrolnom jedinicom sistema za navodnjavanje, a kojoj je zadatak da pri prijemu signala pali i gasi sistem za navodnjavanje. Odnosno, kontroliše elektro-ventile i rad pumpe kako bi se postigla puna automatizacija sistema.

Još jedna važna karakteristika ovog načina kontrole navodnjavanja su prognozni modeli. U slučaju pristupa prognoznim podacima o temperaturi zraka, padavinama i evapotranspiraciji, moguće je unaprijed predvidjeti potrebu za navodnjavanjem za period od 3 do 4 dana. Na taj način, sistem navodnjavanja se može efikasnije koristiti i prilagoditi ne samo trenutnim uslovima, već i onima koji se očekuju u budućnosti.

Ovakvi sistemi mogu biti povezani i sa uređajima za praćenje vlažnosti tla, pH vrijednosti ili električne provodljivosti (EC), čime se poboljšava njihova preciznost i osigurava multifunkcionalnost sistema.

Jedna od ključnih komponenti pametnog sistema za navodnjavanja, jesu i elektroventili (solenoidni ventili ili solenoidi). Rade na principu elektromagnetne sile. Kada električni signal (najčešće iz kontrolne jedinice za navodnjavanje) aktivira solenoid, elektromagnetna zavojnica povlači klip ili membranu unutar ventila, otvarajući ili zatvarajući prolaz za vodu. Upotreba ovakvih ventila omogućava zonalnu kontrolu sistema za navodnjavanje, što omogućava precizno upravljanje različitim dijelovima površine. Prenos podataka prema kontrolnoj jedinici može biti putem žičane ili bežične komunikacije. Solenoidni ventili (Slika 31) omogućuju automatsko upravljanje navodnjavanjem putem aplikacija ili senzora, čime se povećava efikasnost upotrebe vode.



Slika 31. Elektroventili (selenodi) sa žičanim i bežičnim prenosom signala

Pored elektroventila, pametni sistem za navodnjavanje također može imati i digitalne uređaje za praćenje pritisak u cijevima, protoka vode i količine vode (pametni vodomjeri), nivoa vode u rezervoaru, sistemi koji kontrolišu rad pumpe, automatizovani filteri, sistemi za fertirigaciju.

Korištenje različitih senzora u pametnom navodnjavanju

Određivanje kada i koliko navodnjavati može se bazirati na uređajima ili sensorima koji prate stanje biljke, klime ili stanje tla. Ovi pristupi se mogu i kombinirati radi veće preciznosti.

Pod stanjem biljke, podrazumijevamo unutarnje fiziološke promjene na biljkama. Ovi uređaji baziraju se na mjerenjima:

- koncentracije ćelijskog soka,
- temperature biljaka, korištenjem termalne kamere,
- brzine otvaranja i zatvaranja stoma,
- jačine turgora,
- mjerenje brzine rasta ili promjeni debljine stabljike ili ploda (dendrometri) i sl.

Ove metode zbog složenosti mjerenja, kao i skupih uređaja, nisu našle široku primjenu u praksi.

Metode bazirane na stanju klimatskih parametara baziraju se na proračunu vodnog balansa tla kako je to već ranije objašnjeno. U tu svrhu koriste se različite izvedbe senzora koji mogu biti postavljeni samostalno, kao i zajednički na kontrolnim uređajima ili mini meteorološkim stanicama. Ovi senzori obuhvataju senzore za temperaturu tla, padavine, brzinu vjetra, relativnu vlažnost zraka, vlažnost lista i insolaciju. Korištenje meteoroloških stanica je ranije pojašnjeno u okviru poglavlja 2. Ovo je veoma praktičan pristup određivanju kada i koliko navodnjavati, međutim obzirom da se radi o procjenama baziranim na proračunima može doći do grešaka te je potrebno u intervalima od 2-3 mjeseca provjeravati stanje vlažnosti tla, a kako bi se eventualno izvršila korekcija.

Uređaji kojima se prati vlažnost tla široko se primjenjuju u poljoprivrednoj praksi i smatraju se najpreciznijim načinom praćenje potrebe za navodnjavanjem.

Uređaji za praćenje vlažnosti tla

Postoji veliki broj uređaja koji se koriste za praćenje vlažnosti tla. Prema principu mjerenja možemo ih podijeliti u slijedeće četiri grupe:

- tenziometrijski,
- elektrometrijski,
- elektromagnetni, i
- radiacioni uređaji.

Ovi uređaji mjere nivo vlažnosti tla i najčešće ga izražavaju kao volumetrijski postotak vlažnosti tla (vol. %), koji prikazuje volumen vode u odnosu na ukupni volumen tla, uključujući organski i mineralni dio. Na primjer, ako je vrijednost 20%, to znači da voda zauzima 20% volumena, dok preostalih 80% čini tlo. Ove vrijednosti se mogu porediti sa poznatim vrijednostima poljskog vodnog kapaciteta (PVK), tačke lakog kapanja (LK) ili vlažnosti trajnog venuća (VTV) za određeno tlo kako bi se interpretiralo stanje vlažnosti.

Vlažnost tla može biti izražena i u jedinicama pritiska, kao što su centibari (cbar), bari (bar), kilopaskali (kPa) i atmosfere (atm). Ove jedinice označavaju potencijal (ili sukciju) tla, odnosno silu koju biljka mora generirati da bi apsorbirala vodu iz tla. Niža vrijednost znači da je tlo zasićenije vodom i biljci je potrebno manje napora za usvajanje vode.


Osim toga, vlažnost tla se može izraziti u kubnim metrima vode po kubnom metru tla (m^3/m^3), gdje se mjeri volumen vode u odnosu na volumen tla. Vlažnost se također može izraziti pomoću pF skale (logaritam negativne vrijednosti vlažnosti), koja mjeri sposobnost tla da zadrži vodu. Vrijednosti na pF skali obično se kreću od 0 (zasićeno tlo) do 4,2 (vrlo suho tlo).

Tenziometrijski

Na ovom principu rade uređaji koji se nazivaju tenziometri (Slika 32). Ovi uređaji mjere sukciju (tenziju), silu sa kojom biljka izvlači vodu iz tla, pružajući na taj način informacije o dostupnosti vode.

Standardni tenziometar na sebi ima skalu u centibarima (cbar) koja se kreće od 0 – 100 cbar (kPa). Međutim, vrijednosti na kojima rade kreću se od 0 – 75 cbar. Vrijednosti od 0 ukazuju na potpuno saturisano – vodom zasićeno tlo. Vrijednosti oko 10 cbar odgovaraj poljskom vodnom kapacitetu (PVK) u propusnim – pjeskovitim tlima, dok se vrijednosti za finija – teža tla pri PVK kreću oko 30 cbar. Gornji limit od 75 cbar na lakšim tlima predstavlja ispražnjenost ukupne rezerve pristupačne vode (UPV) od 90%, dok kod težih (ilovastih i glinovitih) zemljišta to je samo oko 30%. Vrijednost iznad 60 cbar mjerodavna je vlažnosti trajnog venuća (VTV), odnosno stanju vlažnosti tla kada su biljke pod vodnim stresom koji dovodi do venjenja.

Navodnjavanje treba biti obavljeno kada je vlažnost u intervalu od 60 do 20 cb, zavisno do tipa tla. Vrijednosti iznad 10 cb ukazuju na previsoku vlažnost tla, što nam opet može biti dobar znak kad je u pitanju prevencija pojave bolesti i štetočina.



Slika 32. Tenzijometar za mjerenje vlažnosti tla

Prije postavljanja, tenzijometar je potrebno nekoliko dana potopiti u vodu, kako bi keramički vrh bio potpuno zasićen vodom. Zatim se u tenzijometar sipa voda i postavlja se u parcelu.

Postavljanju tenzijometara se treba posvetiti posebna pažnja. Keramički vrh mora biti u potpunom kontaktu sa tlom. Mjesto postavljanja treba da predstavlja uslove tipa tla, pada, ekspozicije određene parcele, a da nije na putu obrade i agrotehnike. Najčešće se na jednoj lokaciji postavlja jedan tenzijometar ili dva u paru, s tim da je prvi na dubini aktivne mase korijena, a drugi nekih 20-30 cm ispod. Važno je da je keramički vrh na adekvatnoj dubini i da je uspostavio puni kontakt sa tlom koji ga okružuje. Dublji tenzijometar služi za praćenje kretanja podzemne vode i njenog uticaja na vlažnost tla. Prema tome, na tržištu se mogu naći tenziometri različitih dužina. U uslovima kontinentalne klime postavljanje obaviti u periodu sjetve/sadnje (mart – april), držati ga na parceli bez pomjeranja, sve do kraja vegetacije (septembar - oktobar), kada ga je potrebno izvaditi, isprazniti vodu, očistiti i uskladištiti na suhom mjestu do proljeća. Tenzijometar ne smije ostati u parceli tokom zimskih mjeseci, voda u njemu će zaleđiti i može doći do trajnog oštećenja. U uslovima mediteranske klime tenzijometar može ostati u parceli tokom cijele godine.

Za upotrebu u pametnim sistemima za navodnjavanje, praktični su digitalni tenziometri koji pružaju digitalna očitavanja i mogu se povezati s daljinskim upravljanjem i nadzorom navodnjavanja. Mjerenja se šalju bežično ili putem žičane veze direktno u kontrolni centar ili na centralni server, omogućavajući pravovremene odluke o navodnjavanju.

Kako bi se postigli precizni rezultati, tenziometri, kao i ostali uređaji za praćenje vlažnosti tla, moraju biti kalibrirani za specifičan tip tla. Detaljan proces kalibracije bit će objašnjen nakon pregleda svih uređaja.


Elektrometrijski uređaji

Ovi uređaji mjere električni otpor tla (*eng. soil electrical resistance*). Kao elektrode često se koriste bakarne ploče zbog izvrsne električne provodljivosti i otpornosti na oksidaciju. Primjeri takvih uređaja su gipsani blokovi i granular matrix senzori (GMS).

Kod gipsanih blokova, elektrode su ugrađene u gips, koji djeluje kao medij za mjerenje vlažnosti tla. Promjene u električnoj provodljivosti gipsa, uslovljene promjenom sadržaja vode, omogućuju

preciznu procjenu vlažnosti tla. Što je veća vlažnost, manji je električni otpor, a time je tačnija procjena raspoložive vode u tlu. Njihov interval mjerenja je od 0 do 100 cbar (0 – 1 bar; 0 – 3 pF), što odgovara vlažnosti tla od potpuno saturisanog do vlažnosti blizu lentokapilarne tačke od pF 3,8.

Granular matrix senzori (npr. *Watermark senzori*) koriste sintetički materijal umjesto gipsa, koji je otporniji na habanje i daje stabilnije rezultate u širem rasponu vlage, pogodan za dugotrajnije i preciznije mjerenje vlažnosti tla (slika 33). Ovaj materijal brže reaguje na vlaženje i sušenje nego gipsani blokovi. Interval mjerenja od 10 do 200 cb (0,1 – 2 bar; 0 – 3,3 pF).



Slika 33. Granular matrix senzori i senzor temperature tla

Ovi senzori imaju duži vijek trajanja, lakše održavanje i ne smeta im mraz. Također, oni zadržavaju svoju formu u zemljištu i imaju konzistentniji raspored pora te su mjerenja preciznija. Senzori se u tlo mogu postavljati sami kopanjem manje rupe ili pomoću PVC cijevi koja legne na gornji dio senzora, dok se kablovi provuku kroz cijev.

GMS ostvaruje slab kontakt sa okolnim tlom u pjeskovitim, skeletnom – lakšem zemljištu, te su očitavanja nepouzdana. Nakon vlaženja, brže se suše nego okolno tlo (histerezni efekt), što može dovesti do pogrešnih očitavanja (vrijednosti su manje nego je stvarna vlažnost tla). Također, kalibracija je potrebna za svaki individualni senzor posebno. Kada se jednom ukopaju na neko mjesto najbolje je da tu i ostanu tokom cijele godine – perioda mjerenja. Prosječan vijek trajanja senzora je od 3 do 5 godina.

Prije instalacije potrebni ih je držati potpuno potopljene u vodi dva dana. Uz GMS se obično postavlja i temperaturni senzor (slika 33) kako bi se dobivene vrijednost vlažnosti tla mogle korigovati.

Senzori gipsanih blokova i granular matrix senzori dolaze s opcijama digitalnog povezivanja kada se spajaju na kontrolne sisteme putem Data Loggera ili bežičnih komunikacijskih modula. Na taj način, podaci o vlažnosti tla mogu se automatski prenositi u centralni kontrolni sistem za navodnjavanje. Prema tome, oba tipa senzora mogu biti integrisana u napredne pametne sisteme za navodnjavanje, omogućavajući automatizaciju na temelju stvarnih podataka s terena.

Elektromagnetni metoda

Elektromagnetni metod za mjerenje vlažnosti tla temelji se na korištenju dielektrične konstante (relativne permitivnosti) vode u poređenju s drugim komponentama tla. Voda ima vrlo visoku dielektričnu konstantu od oko 80, dok komponente tla kao što su zrak, organska materija i minerali imaju znatno niže vrijednosti, koje se kreću između 1 i 7. Ova velika razlika omogućava precizno mjerenje sadržaja vode u tlu.

Ovaj metod koristi elektromagnetne impulse ili radiofrekvencije koje prolaze kroz tlo. Kada elektromagnetni talasi prolaze kroz tlo, brzina i intenzitet talasa variraju u zavisnosti od količine vode, jer voda značajno utječe na dielektričnu konstantu. Na osnovu ovih promjena u elektromagnetnim talasima, uređaji mogu procijeniti sadržaj vode u tlu. Ovi uređaji se široko koriste u poljoprivredi, posebno za precizno upravljanje navodnjavanjem, jer omogućavaju precizna, brza i kontinuirana mjerenja vlažnosti tla bez potrebe za složenim održavanjem.

Vrste urađaja koji koriste elektromagnetni metod:

- Vremenska reflektometrija - *Time Domain Reflectometry* (TDR): Ova tehnologija koristi impulse u obliku elektromagnetnih talasa koji se odbijaju od tla. Vrijeme povratka signala se koristi za procjenu vlažnosti tla.
- *Frequency Domain Reflectometry* (FDR): Ovaj metod koristi radiofrekvencije za mjerenje promjena u kapacitivnosti tla, što se povezuje s količinom vode u tlu.
- Kapacitivni senzori - *Capacitance senzori*: Koriste promjenu kapaciteta između dvije elektrode kako bi se odredila vlažnost tla.

TDR – Time Domain Reflectometry (vremenska reflektometrija)

TDR koristi brzinu elektromagnetnog signala koja zavisi od dielektričnih svojstava materijala kroz koji prolazi. Princip rada TDR senzora zasniva se na slanju pulsnog signala (*step pulse signal*) kroz čelične šipke ili vodiče ukopane u tlo. Signal se reflektuje od kraja vodiča i vraća nazad do kontrolne jedinice. Vrijeme potrebno da se signal vrati zavisi od dielektričnih svojstava tla, koja su direktno povezana sa njegovim sadržajem vode.

Tehnika TDR mjeri vrijeme potrebno za širenje elektromagnetnog impulsa duž šipki u zemljištu. Budući da voda ima visoku dielektričnu konstantu, povećanje sadržaja vode usporava prolazak signala, što omogućava tačnu procjenu vlažnosti tla. Ovaj metod je poznat po tome što daje pouzdane rezultate, čak i bez potrebe za opsežnom kalibracijom za različite tipove tla.

TDR uređaji vlažnost tla prikazuju u vol. %, cbar ili pF vrijednostima. Interval mjerenja je od 0 do 4,2 pF, odnosno od zasićenosti do VTV.

Uređaji koriste metalne sonde (šipke) ili valne vodiče koji se postavljaju direktno u tlo (slika 34). Šipke mogu biti različite dužine, ovisno o dubini tla koja se prati. Senzori se obično postavljaju na različitim dubinama, kako bi se mjerila vlažnost tla na različitim zonama. TDR senzori su povezani sa kontrolnom jedinicom, koja prikuplja podatke i po potrebi ih šalje na centralizirani server ili kontrolni sistem putem žičane ili bežične mreže. TDR uređaji mogu raditi na baterije, solarno napajanje ili uz mrežno napajanje, zavisno o specifičnim potrebama i lokaciji. Ovi senzori su pouzdani za precizno praćenje vlažnosti tla i široko se koriste u poljoprivredi, naučnim istraživanjima i sistemima za automatsko navodnjavanje.



Slika 34. Primjeri TDR senzora za mjerenje vlažnosti tla

TDR senzori mogu se koristiti za dinamična mjerenja na različitim lokacijama ili za dugoročna, statična mjerenja na jednom definiranom mjestu. Postoje dvije glavne konfiguracije ovih senzora, ovisno o namjeni i trajanju mjerenja:

Pokretni TDR uređaji za površinsku upotrebu: Ovi senzori su dizajnirani za jednostavno zabijanje u tlo sa površine, što omogućava brza, trenutna mjerenja vlažnosti tla. Najčešće se koriste za kontrolu travnatih površina kao što su fudbalski stadioni ili golf tereni, gdje je potrebna česta provjera stanja vlage. Uređaji su kompaktni, lagani i idealni za brzu provjeru na terenu bez potrebe za dugotrajnim instalacijama.

Senzori sa dugim sondama (šipkama) za dubinska mjerenja: Za dublje i dugoročne mjerenja vlažnosti tla, TDR senzori mogu biti opremljeni sondama različitih dužina, od 10 cm do 50 cm, koje se zabadaju u tlo na potrebnu dubinu. Ako se mjerenja vrše povremeno, senzor se može jednostavno zabosti u tlo, izvršiti mjerenje, i potom ukloniti. Za dugoročna mjerenja, postupak je nešto složeniji. Potrebno je iskopati rupu do željene dubine, te senzor postaviti horizontalno u zid rupe. Nakon što je senzor na mjestu, rupa se pažljivo zatrpava kako bi se tlo vratilo u svoje prirodno stanje, osiguravajući preciznost mjerenja. Kablovi koji povezuju senzor sa kontrolnim sistemom moraju biti postavljeni tako da ne ometaju normalne procese u tlu i da spriječe prodiranje vode niz kabl do senzora.

FDR – Frequency Domain Reflectometry (Kapacitivni senzori - Capacitance soil probes)

Ovi senzori mjere dielektrični kapacitet tla između dvije elektrode, pri čemu tlo funkcioniše kao električni kondenzator. Kapacitet senzora mijenja se s količinom vode u tlu, a rezultat je mjerenje frekvencije koja varira zavisno od dielektričnih svojstava tla, odnosno njegovog sadržaja vode.

Senzor se ponaša kao kondenzator promjenljivog kapaciteta povezan sa oscilatornim kolom, koje na izlazu generiše impulse. Broj impulsa je obrnuto proporcionalan vlažnosti tla. Impulsi se zatim šalju na brojač impulsa, povezan sa računarom, gdje se vrši proračun vlažnosti tla. Ovi podaci prikazuju se na monitoru i mogu generisati upravljačke signale za automatizaciju navodnjavanja, uključujući kontrolu pumpi. Prenos podataka može se vršiti koaksijalnim kablom na udaljenosti do 5 km, ali je potrebno pojačanje signala na ulazu i izlazu sistema. Postoje i bežične verzije ovog uređaja (slika 35).

FDR senzori obično rade u opsegu od zasićenog tla ($pF=0$) do vrlo suhog tla ($pF>4$), omogućavajući precizno mjerenje vlažnosti tla. Njihov radni dijapazon može se prilagoditi različitim tipovima tla, pod uslovom da je senzor kalibriran za specifične uslove tla. Vlažnost tla obično prikazuju u vol. %.

Senzori se obično ukopavaju u tlo na različitim dubinama, zavisno od zone korijena biljke koja se nadgleda. Važno je pravilno postaviti senzore kako bi se dobili reprezentativni podaci o vlažnosti tla, izbjegavajući ekstremne uvjete previše suhog ili previše vlažnog tla.

FDR senzori se često koriste u pametnim sistemima za navodnjavanje jer omogućavaju kontinuirano praćenje vlažnosti tla i automatsko slanje podataka u kontrolne sisteme. Povezivanje može biti žično ili bežično, zavisno od infrastrukture, omogućavajući daljinsko upravljanje navodnjavanjem putem aplikacija. Na ovaj način se osigurava optimalno korištenje vode i prilagođavanje trenutnim uslovima tla.



Slika 35. Primjeri FDR senzora za mjerenje vlage tla

FDR senzori nemaju mehaničke dijelove koji bi se mogli pokvariti ili degradirati s vremenom. To ih čini pouzdanijima i dugotrajnijima u teškim uslovima, ne moraju se redovno servisirati i dopunjavati vodom, te zahtijevaju minimalno održavanje nakon instalacije. Ovo ih čini veoma praktičnim za dugotrajna mjerenja u terenu ili automatske sisteme za navodnjavanje. FDR senzori su jeftiniji od TDR senzora. Lakše se instaliraju i zahtijevaju manje specijaliziranog znanja za rad. Međutim, oni mogu biti osjetljivi na promjene u zaslanjenosti tla (elektrokonduktivitetu), što može utjecati na točnost u različitim uvjetima saliniteta.

Velika prednost ovih senzora jeste što često dolaze zajedno sa sensorima za temperaturu i elektrokonduktivitet tla, što su veoma važni parametri u sistemima pametne poljoprivrede.

Radiacioni uređaji

U okviru ove grupe uređaja primjenjuju se dva pristupa: neutronska sonda i uređaji koji rade na gama zračenje. Prednosti ovih pristupa su precizna mjerenja na više dubina i dublje u tlu u odnosu na druge senzore. Glavni nedostatak je kompleksnost upotrebe i visoka cijena koštanja.

Neutronske sonde koriste emisiju brzih neutrona, koji gube energiju kada se sudare s vodikom u vodi. Detektor unutar sonde mjeri broj sporih neutrona, a na osnovu tog broja se procjenjuje sadržaj vode u tlu. Kako je vodik dominantno prisutan u vodi, mjerenje broja sudara s vodikom direktno korelira sa vlažnošću tla.

Neutronska sonda (slika 36) obično se postavlja u unaprijed pripremljene cijevi, koje omogućavaju mjerenje vlažnosti tla na različitim dubinama. Uređaj se spušta unutar cijevi do željene dubine, gdje detektor očitava podatke. Mogu se koristiti za statična, dugoročna mjerenja, ali zbog relativno složenog postavljanja i sigurnosnih aspekata, neutronske sonde se manje koriste za svakodnevna poljoprivredna mjerenja. Za njihovo korištenje potrebna je obučena osoba koja ima dozvolu od strane

organa uprave. Oprema je jako skupa i postoje ograničenja korištenja zbog zakonske regulative za radioaktivno zračenje. Također, neutronske nisu tako praktične za direktnu integraciju u pametne sisteme navodnjavanja, jer zahtijevaju specifične procedure i često ručno očitavanje podataka. Zbog visoke preciznosti, mogu se koristiti u specijalizovanim poljoprivrednim istraživanjima ili za kalibraciju drugih senzora.

Uređaji sa gama zračenjem su reletivno nova rješenja. Gama zračenje prolazi kroz tlo, a njegov intenzitet opada kako nailazi na materijale s većom gustoćom, poput vode. Mjerenje količine apsorbiranog gama zračenja omogućava procjenu sadržaja vlage. Metoda je bazirana na cijevima postavljenim u tlu, gdje se sonda spušta i mjeri apsorpciju zračenja (slika 36).



Slika 36. Primjeri neutronske sonde i uređaja na bazi gama zračenja

Pored navedenih pristupa, mjerenje vlažnosti tla može biti obavljeno i uređajima koji se baziraju na dielektričnoj metodi odnosno mikrovalovima, i optičkim senzorima na bazi infracrvene svjetlosti (IR). Međutim, u usporedbi sa TDR, FDR i tenziometrima, ove metode se manje koriste za svakodnevno praćenje vlažnosti tla u poljoprivredi, ali mogu biti veoma korisne u istraživačkim i visoko specijalizovanim poljoprivrednim projektima.

Način postavljanja senzora za vlagu tla

Način postavljanja prije svega zavisi od vrste senzora ali i vrste sistema za navodnjavanje i osobina tla. Uz svaki senzor dolaze i preporuke proizvođača vezna za način postavljanja. Generalno gledana postoje određena pravila koje je potrebno primijeniti. Lokacija postavljanja ima svoju horizontalnu i vertikalnu dimenziju.

U vertikalnom smislu, to jeste u tlo, preporučuje se postavljanje više od jednog senzora na jednoj lokaciji, i to na različitim dubinama tla. Jedan senzor u gornjem dijelu efektivnog korenovog sistema biljke (10 – 30 cm), a drugi senzor dublje (30 – 60 cm). Dubina postavljanja drugog senzora zavisi od karakteristika tla i prisustva podzemne vode u tlu. Na taj način se može pratiti površinska vlažnost tla koja može biti rezultat padavina i navodnjavanja, kao i stanje vlažnosti tla u dubljim slojevima

Moguće je i posmatrati i proces infiltriranja vode u tlo obzirom da će dublji senzor, također registrovati promjene u vlažnosti nakon određenog vremena, u odnosu na senzor koji je postavljen pliće.

Broj ovakvih lokacija sa senzorima zavisi od osobina same parcele, agrotehnike, uzgajanih kultura, mikroklimatskih uslova, reljefa, nagiba, ekspozicije i drugo. U slučaju homogene parcele, gdje se gaji monokultura na ravnoj površini potreban je manji broj mjernih lokacija.

Kod navodnjavanja kišenjem voćarskih kultura senzori se postavljaju u prostor između stabala uz adekvatnu zaštitu od oštećenja. Kod povrtlarskih i ratarskih kultura, senzori se postavljaju direktno u redove biljaka. Kod “Centar Pivot” sistema postavljaju se na 4-5 lokacija duž obrtne tačke. Praktikuje se postavljanje i dodatnih senzora na lokacije na kojima se voda duže zadržava (manja infiltracija) ili se razlikuju u plodnosti, a kako bi se dobila jasnija slika situacije na parceli.

Kod lokalnog navodnjavanja, kao što je “kap po kap”, mikrokišenja ili mikrocvjevastog navodnjavanja, senzori se moraju postaviti na vlažnu zonu. Kod “kap po kap” emitira ili kapala, ovo je otprilike 20-30 cm od kapala, u težim tlima dalje, u lakšim bliže kapalu. Kod mikro-kišenja, najbolje je oko 40-90 cm.

Dubina postavljanja senzora zavisi od dubine korijenovog sistema biljaka, ali i tip i mehanički sastav tla mogu imati veliki uticaj. Kod povrtlarskih kultura plićeg korijena dovoljno je postaviti jedan senzor u zoni tla do 30 cm. Kod kultura koje imaju korijen koji se razvija dublje od 30 cm (žita, vinova loze i voće) potrebno je mjerenje vlažnosti tla na više dubina.

Kalibracija (baždarenje) senzora za vlagu tla

Kalibracija senzora za mjerenje vlažnosti tla je ključna za osiguranje preciznosti mjerenja u različitim tipovima tla. Prije korištenja elektrometrijskih senora, tenziometara, ali i FDR i TDR senzora, potrebno je obaviti laboratorijsku kalibraciju. Moderniji senzori posebno u okviru grupe TDR i FDR nude i elektronsku kalibraciju vrijednosti ili odabir tipa tla za koji se koristi, a što poboljšava preciznost mjerenja vlažnosti tla.

Precizna metoda kalibracije ovih uređaja podrazumijeva nekoliko koraka. Prvi je uzimanje uzorka tla sa površine na kojoj se planira postaviti ili koristiti određeni uređaj. Uzorak tla treba da bude čist od kamena i krupnog organskog materijala.

Na ovom uzorku tla se laboratorijskim standardnim metodama odrede vrijednosti vodnih konstanti: MVK, PVK i VTV u volumetrijskim procentima (vol %). Ovako definirane vrijednosti predstavljaju referentne tačke kalibracije. Dalje je potrebno pripremiti posude (poznatog volumena) sa tlom u kojem će biti testiran određeni senzor ili više njih. Tlo se suši na zraku 2-3 dana, do higroskopne vlažnosti. Prilikom punjenja posude, tlo se ne smije previše nabijati niti rahliti, odnosno njegove osobine moraju predstavljati stanje na lokaciji uzimanja uzorka. Dalje, senzori se postavljaju u posude sa tako pripremljenim tlom a prema uputstvima proizvođača, vodeći računa o dubini i orijentaciji sonde (žica, ploča).

Obzirom da su referentne tačke poznate, kao i volumen vode koji tlo pri ovim stanjima vlažnosti može da sadrži, postepenim dodavanjem adekvatne količine vode moguće je tlo zasititi prije svega do VTV, a zatim i do PVK te do potpune saturacije ili MKV. Zavisno od tipa senzora, proces može trajati nekoliko sati. Tokom procesa senzori mjere vlažnost tla, a podaci sa senzora se bilježe. Od dobivenih podataka moguće je izraditi kalibracionu krivu, kreiranjem grafikon na kojem x-os predstavlja očitavanja sa senzora, a y-os stvarne vrijednosti vlažnosti tla. Kalibracijska krivulja će pomoći u preciznijem interpretiranju podataka sa senzora.

Najvažnije je precizno definirati očitavanja sa senzora pri referentnim tačkama VTV, PVK i MVK. Odnosno, nakon završetka, poređenjem očitanih vrijednosti za ove referente tačke sa stvarnim vrijednostima volumetrijske vlažnosti, dobivaju se razlike koje mogu biti pozitivne ili negativne. U oba slučaja ova razlika predstavlja grešku koja se uzima u obzir prilikom interpretacije očitavanja sa senzora.

Digitalni senzori posebno FDR i TDR imaju mogućnosti unosa ove greške i direktne kalibracije uređaja (*data logger*) koji se koristi za očitavanja vrijednosti. Kod ostalih uređaja greška se računa prilikom tumačenja rezultata očitavanja.

Kada je jedan senzor određene vrste kalibriran, moguće je provjeriti set istih senzora poređenjem vrijednosti očitavanja u istim uslovima vlažnosti. Ako su variranja na senzorima manja od 2% vol. kalibracija nije potrebna.

Senzori za kišu

Poznati i kao “kišni prekidači”, ovi senzori služe za zaustavljanje planiranog ciklusa automatskih sistema za navodnjavanje, kada dođe do određenog nivoa padavina (slika 37). U nekim aridnim i semi-aridnim područjima postavljanje ovakvih senzora u okviru automatskih sistema za navodnjavanje čak je i zakonska obaveza.

Senzor se kalibrira da reagira na određenu količinu efektivnih padavina (obično između 5-20 mm). Kada količina padavina dosegne ovu vrijednost, senzor automatski isključuje ili odgađa rad sistema za navodnjavanje.

Principi rada senzora:

1. Prikupljanje i vaganje vode. Ovaj princip se temelji na prikupljanju padavina i njihovom vaganju. Kada prikupljena voda dostigne određenu težinu, senzor signalizira isključivanje sistema.
2. Mjerenje nivoa vode pomoću elektroda. Senzor koristi set elektroda za mjerenje nivoa vode. Međutim, glavni nedostatak ovakvih sistema je da osim vode, nečistoće poput prašine ili prisustvo ptica mogu lažno aktivirati senzor i isključiti sistem, iako nema stvarnih padavina.
3. Higroskopnost. Ovaj princip je najčešće u upotrebi. Zasniva se na svojstvu određenog higroskopnog materijala koji se širi kada apsorbira vodu. Kada materijal (higroskopni disk) upije dovoljno vode i raširi se do određenog nivoa, senzor isključuje sistem za navodnjavanje. Kako se disk suši i ponovno skuplja, sistem može biti ponovo uključen (slika 37).

Granica isključivanja sistema može se podešavati, a senzori obično nude mogućnosti postavljanja na različite nivoe padavina: 3, 6, 13, 19 ili 25 mm. Vrijeme sušenja senzora, odnosno vraćanja u stanje koje omogućava ponovno pokretanje navodnjavanja, zavisi od vremenskih uslova. Za prilagodbu sušenja senzora tlu koje se navodnjava, senzor ima uređaj koji kontrolira brzinu sušenja. Zatvaranjem ovog uređaja, senzor se sporije suši. Prema istraživanjima, vrijeme potrebno za sušenje senzora varira od 6 do 100 sati, ali najčešće iznosi između 12 i 30 sati, u zavisnosti od količine padavina i vremenskih uslova.

Senzor treba biti postavljen na mjestu koje ima slične uslove (izloženost suncu i vjetru) kao i površina koja se navodnjava, ali ne unutar zone koja je direktno pod navodnjavanjem kako bi se izbjegle lažne aktivacije.



Slika 37. Senzor za kišu

Bespilotne letjelice – dronovi i daljinsko istraživanje

Prije nego pojasnimo ulogu bespilotnih letjelica ili dronova u navodnjavanju potrebno je definirati fotogrametriju, nauku na kojoj se bazira ovaj pristup. Fotogrametrija je nauka, ali i tehnika mjerenja, pomoću koje se iz fotogrametrijskih mjernih snimaka dobivaju oblik, veličina i položaj snimljenog predmeta (NJDOT, 1998) i smatra se granom polja geodezije. Princip fotogrametrije počiva na refleksiji prirodne svjetlosti (sunčevo zračenje) ili vještačkog zračenja (radari, zvuk) od pojedinih objekata (Jurišić & Plašćak, 2009).


Fotogrametrija omogućava rekonstrukciju objekata i utvrđivanje njihovih karakteristika bez direktnog kontakta. Fotogrametrija može biti terestička i aerofotogrametrija. Ako se kamera za fotogrametrijsko snimanje nalazi na tlu onda je to terestička, a ako je kamera u zraku, nošena nekom vrstom letjelice, kao što je dron, radi se o aerofotogrametriji (Kraus, 2006). Taj način dobivanja informacija naziva se daljinsko istraživanje (eng. *remote sensing*), pristup koji ima široku primjenu u različitim disciplinama i naučnim poljima.

Daljinsko istraživanje je praksa dobivanja informacija o kopnenim i vodenim površinama pomoću slika dobivenih iz nadzemne perspektive, primjenom elektromagnetnog zračenja u jednom ili više područja elektromagnetskog spektra, reflektovanog ili emitovanog sa Zemljine površine. Fokusira se na prikupljanje podataka sa udaljenosti u svrhu analize i procjene specifičnih stanja ili fenomena. U literaturi se mogu naći i termini daljinska detekcija, daljinsko osmatranje i daljinsko istraživanje. Iako su svi ovi pojmovi međusobno povezani i koriste slične tehnologije, razlike su u njihovom fokusu: detekcija se bavi prepoznavanjem, osmatranje kontinuiranim praćenjem, ispitivanje analizom specifičnih karakteristika.

Podaci prikupljeni zračnim (dron) i svemirskim (satelit) letjelicama mogu imati veličinu od nekoliko centimetara pa do nekoliko hiljada kilometara (Jurišić & Plašćak, 2009). Glavne prednosti daljinskih istraživanja pri istraživanju Zemlje i njenih resursa nad drugim metodama su sinoptički pregled (pregled svih dijelova složene cjeline istovremeno), aspekt izvođenja, ušteda vremena i novaca, multidisciplinarna primjena, te nepresušan izvor podataka i informacija (Oluić, 2001).


Stereofotogrametrija podrazumijeva snimanje iste površine ili objekata sa dva snimka sa dva različita mjesta. Ovako načinjeni snimci čine stereo par (slika 38). Na osnovu ovakvih snimaka aerotriangulacijom je omogućeno određivanje trodimenzionalnih koordinata snimljenih tačaka u odabranom koordinatnom sistemu, a što predstavlja osnovu za izradu digitalnog modela reljefa

(DEM). Također, aerotriangulacija omogućava kreiranje trodimenzionalnih digitalnih modela objekata od interesa.



Slika 38. Postupak dobivanja stereofotogrametrijskog snimka

Za potrebe daljinskih istraživanja koriste se različite vrste snimaka: fotografske, termalne, radarske, itd. (Donassy, 1983). Dobiveni snimci najviše se koriste za izradu topografskih podloga, 3D modela objekata i terena (slika 39), ortofoto karata i digitalnog modela reljefa (DEM). DEM sadrži informacije o obliku, veličini, položaju i načinu korištenja površine terena, te se može na različite načine obrađivati u Geografskim informacionim sistemima - GIS (Kraus, 2006).



Slika 39. Visinski model zgrade Poljoprivredno-prehrambenog fakulteta, Univerziteta u Sarajevu

Uz DEM i ortofoto karte iz podataka fotogrametrijskih snimaka moguće je izraditi i brojne druge kartografske prikaze, kao što su planimetrijske, topografske, te tematske karte (Wolf, 1984).


Mogućnost upotrebe aerofotogrametrijskih snimki su velike. Za geodetske svrhe koriste se kao osnova za katastarsku izmjeru, prikupljanje podataka za DEM, kreiranje digitalnog ortofota različitog mjerila, izradu topografskih karata. Digitalni ortofoto plan je poseban oblik predstavljanja Zemljine površine. Po izgledu je fotografski, a po geometrijskim karakteristikama podudaran sa klasičnim geodetskim planovima, veoma je koristan kao dopuna podlogama koje se koriste u projektovanju (Žurovec, 2016).

Pored geodezije, fotogrametrija se koristi u rudarstvu, ekologiji, medicini, meteorologiji, geologiji, pedologiji, hidrologiji, poljoprivredi, šumarstvu, zaštiti okoliša, prostornom planiranju i arheologiji (Kraus, 2006; Niranjana *et al.*, 2007), a koriste je i osiguravajuće kuće za procjenu šteta.

Aerofotogrametrijski snimci kreirani u svrhu daljinskog istraživanja postavljeni su na različite letjelice kao što su sateliti, avioni sa ljudskom posadom, bespilotne letjelice (dronovi), fiksnih krila ili multi-rotor. Prednosti satelita su velika pokrivenost i široka spektralna mogućnost, dok su nedostaci relativno mala rezolucija (10 m x 10 m), prikupljanje podataka u ciklusima i prepreke snimanju (oblaci, magla, smog i sl.).

Najviše korišteni sateliti za daljinsko istraživanje su sateliti serije Landsat i Sentinel. Landsat je serija američkih satelita koje zajednički pokreću NASA i američki centar za geološka istraživanja. Misija Landsat započela je 23. jula 1972. godine, kada je lansiran prvi satelit, Landsat 1, a zadnji satelit Landsat 9 lansiran je 2021. godine. Ovi sateliti pružaju visokokvalitetne podatke o Zemljinoj površini već decenijama. Rezolucija dobivenih snimaka kreće se od 30 i više kvadratnih metara po pikselu, a snimci su dostupni svakih 16 dana. Snimci se mogu koristiti za praćenje promjena u šumama, poljoprivrednim zemljištima, urbanizaciji, vodnim resursima, te stanju tla i vegetacije.

Sentinel serija satelita (slika 40) je pokrenuta od strane Evropske svemirske agencije (ESA) kroz program Copernicus. Ovi sateliti su ključni za monitoring Zemljine površine i pružanje podataka za različite naučne oblasti. Sentinel-2 serija se sastoji od dva satelita Sentinel 2A i 2B. Ovi sateliti lete u tandemu, jedan iza drugoga (50 minuta razlike). Za jedan krug oko Zemlje potrebno im je 90 do 100 minuta, a snimci svakog dijela Zemljine kugle dostupni su svakih 5 dana. Dobiveni snimci su visoke prostorne rezolucije (10-60 m² po pikselu), sa 13 opsega u vidljivom, bliskom infracrvenom (NIR) i kratkotalasnom infracrvenom (IR) dijelu spektra. Satelitima misije Sentinel-2A i Sentinel-2B pridružio se u orbiti treći, Sentinel-2C. Koriste se za praćenje okolišnih promjena, vegetacije, vodnih resursa, atmosfere i promjena u zemljišnom pokrovu. Koristi se i u poljoprivredi, urbanom planiranju, te za detekciju katastrofa. Kad je u pitanju poljoprivreda, između ostalog, koriste se za determinaciju različitih biljno-vegetacijskih indeksa (VI), kao što su indeksi hlorofila i sadržaja vode u listovima, a mogu se koristiti i za efikasno praćenje vlažnosti tla, razvoja usjeva, pojave biljnih bolesti i predviđanje prinosa.



Slika 40. Sentinel-2 satelit u orbiti (izvor: <https://www.esa.int/>)

Za razliku od satelita, avioni sa ljudskom posadom imaju veliku pokrivenost, ali i veliku preciznost. Međutim, kao i kod satelita oblaci mogu biti smetnja, te se radi o jako skupom načinu prikupljanja fotogrametrijskih snimaka.

Bespilotne letjelice - dronovi

Bespilotna letjelica (Dron, eng. *Unmanned Aerial Vehicle* – UAV) je letjelica ili avion bez posade, koji se može nadzirati na daljinu ili letjeti samostalno upotrebom unaprijed programiranog plana leta (FAO, 2018). UAV fotogrametrija ili blizupredmetna aerofotogrametrija je tehnika fotogrametrijskog mjerenja upotrebom bespilotnih letjelica. Ovakav oblik fotogrametrije je značajan u slučaju da je objekat koji se mjeri nepristupačan, potrebno je njegovo detaljno snimanje ili je u vremenu geometrijski promjenjiv (Medić, 2015), kao što je to slučaj sa poljoprivrednim usjevima i vegetacijom uopšte.

Jako su korisne u slučajevima kada nije isplativo obaviti klasično aerofotogrametrijsko snimanje. Također, spram klasične aerofotogrametrije i satelitskih snimaka, ove letjelice daju realniji prikaz stvarnog stanja na terenu (Grača *et al.*, 2014). Mala relativna visina leta eliminira negativni uticaj atmosferskih prilika, kao što su oblaci i magla, te omogućuje brzu reakciju i trenutno prikupljanje podataka (Biočić, 2014).

Za razliku od satelitskih snimki, kartiranje pomoću bespilotne letjelice se vrši za specifično područje u specifičnom trenutku kada je potrebno prikupiti dovoljno podataka u određenom vremenskom periodu.

Upotreba bespilotnih letjelica (dronova) ima izuzetan potencijal za rješavanje nekih od neznčajnih problema sa kojima se susreće poljoprivreda u smislu pravovremenog pristupa kvalitetnim podacima. Bespilotne letjelice nude novu generaciju tehnologije nadziranja i mogućnost prikupljanja prostornih podataka sa terena, koji su jako brzo nakon ili čak tokom prikupljanja dostupni za obradu i analizu. Ova metoda je pogotovo korisna za veće površine, kao i za nepristupačna i udaljena područja (Sito *et al.*, 2015). Primjena bespilotnih letjelica predstavlja jedno od najkvalitetnijih mogućih rješenja u modernoj poljoprivrednoj proizvodnji (Sito *et al.*, 2016).

Mogućnost razumijevanja uslova u kojima se biljka nalazi i njenog stanja zavisi od fenološke faze u kojoj je, a što zahtijeva UAV snimanja više puta tokom vegetacije (Richardson *et al.*, 2009). Zbog dinamičnosti vegetacije, odnosno specifičnosti istraživanja u okviru poljoprivrede, UAV fotogrametrija predstavlja jedinstven alat koji može na jednostavan način zadovoljiti mnoge potrebe istraživača ali poljoprivrednih proizvođača u ovom sektoru.

Osnovna prednost ove tehnologije jeste mogućnost brzog posmatranja usjeva iz zraka što omogućava dobivanje sveobuhvatnije slike stanja vegetacije u veoma kratkom vremenskom periodu, kao i kroz kompjutersku analizu dobivanje informacije koje se golim okom ne mogu primijetiti. Klasični način praćenja stanja poljoprivrednih usjeva je neefikasan i traje veoma dugo, uz sve to, na većim parcelama neke površine su u potpunosti nedostupne. Stalan nadzor proizvodnih površina i usjeva ključni je faktor u planiranju i provedbi većine agrotehničkih zahvata. Detaljna i redovito ažurirana dokumentacija pridonosi boljem planiranju radnih operacija, uštedi radnih sredstava i vremena, poboljšanoj kvaliteti proizvoda, te smanjenju opterećenja okoliša (Krevh, 2018).

Precizna poljoprivreda kombinira senzorske podatke i fotografije sa analizama u realnom vremenu, kako bi se poboljšala produktivnost poljoprivrednog gazdinstva, i to kroz mapiranje


prostorne varijabilnosti u parceli. Fotografije koje prikuplja bespilotna letjelica, obezbjeđuju veliki broj različitih podataka potrebnih za primjenu analitičkih modela u poljoprivredi. Kao podrška u preciznoj poljoprivredi, bespilotne letjelice mogu prikupiti informacije o osobinama tla, pratiti zdravlje usjeva, pomagati u planiranju navodnjavanja, primjeni đubriva, procjeni prinosa i dati vrijedne podatke za analizu vremenskih uslova (FAO, 2018). Pored bespilotnih letjelica kojima se obavljaju fotogrametrijska snimanja, postoje i one koji vrše određene mehaničke – agrotehničke radnje u poljoprivredi, te su takve letjelice dizajnirane za primjenu tekućih pesticida i đubriva.

Većina bespilotnih letjelica koje se danas mogu naći na tržištu imaju ograničenu dužinu leta od 20 do 60 minuta po jednom punjenju baterije. Zavisno od visine leta i gustine (preklapanja) snimaka, potrebno je potrošiti i nekoliko baterija kako bi se snimila određena površina. Također, ograničena je i udaljenost letjelice od pilota, odnosno u slučaju manuelne kontrole letjelica mora biti u blizini pilota (do nekoliko kilometara). Prema tome, primjenom ovakvih bespilotnih letjelica moguće je obaviti precizna istraživanja na površinama do 200 ha.

Za kreiranje fotogrametrijskih snimaka u poljoprivredne svrhe uglavnom se koriste dvije vrste bespilotnih letjelica: Multirotor i avioni s fiksnim krilima (*eng. Fixed wing*).

Obje zračne platforme imaju nekoliko prednosti i ograničenja. Iako multirotor bespilotne letjelice imaju složenije sisteme leta, one mogu letjeti nisko, mogu imati veoma veliku preciznost (<1 cm po pikselu), imaju sposobnost održavanja stabilnog položaja u letu i malu brzinu leta. Međutim, one se također mogu kretati u bilo kojim smjeru i nemaju posebne zahtjeve za polijetanje i slijetanje, što je ponekad veoma bitno na standardnim poljoprivrednim površinama. Avioni sa fiksnim krilima nude jednostavnije sisteme leta i letovi mogu duže trajati čime povećavaju svoj kapacitet za pokrivanje širih područja. Međutim, visina leta im je veća, što smanjuje rezoluciju – preciznost snimaka (2,5 cm >). Pored toga, nisu u stanju da lebde i zahtijevaju određene piste za slijetanje.

Proces prikupljanja fotogrametrijskih podataka korištenjem bespilotnih letjelica podrazumijeva nekoliko koraka. Prije svega je plan leta, zatim fotogrametrijsku obradu prikupljenih snimaka, objektnu analizu slike i kreiranje mapa (slika 41).




Slika 41. Proces prikupljanja i obrade fotogrametrijskih podataka

Plan snimanja vrši se na pametnim uređajima ili integrisanim displejima u okviru bespilotne letjelice, korištenjem namjenski aplikacija (*eng. drone flight app*). Iako je moguće obaviti slobodni let bez plana, za poljoprivredne svrhe definira se plan leta. Plan leta podrazumijeva definiranje granica površine koja se snima, polazne i završne tačke (*home*), visine, putanje-smjera i brzine kretanja drona te nivoa preklapanja snimaka. Zavisno od plana leta i ishranjenosti baterije aplikacija procjenjuje vrijeme leta i eventualnu potrebu za zamjenom baterije. Na istoj aplikaciji moguće je pratiti kretanje drona tokom samog leta. Rezultat ovog snimanja je niz fotogrametrijskih snimaka. Dalje, ovi snimci se preko računarskih aplikacija ili online servisa baziranih na cloud pristupu, povezuju u jedan zajednički snimak koji se naziva ortomozaik. Također, ovom obradom dobivaju se digitalni modeli površine tla (DSM – *eng. Digital surface model*) odnosno Digitalni model terena (DTM – *eng. Digital terrain model*).

Naredni korak je objektna analiza slike, koja se također obavlja u različitim aplikacijama koje nude različite alate za analizu fotogrametrijskog snimka. U poljoprivrednom smislu aplikacije mogu nuditi alate za definiranje površina, volumena, nadmorske visine, visine vegetacije, određivanje broja biljaka, analize vegetacijskih indeksa (VI), definiranje specifičnih zona i dr., odnosno alate za mapiranje i prikaz rezultata ili predikcija. U posljednje vrijeme alati se zasnivaju i na primjeni umjetne inteligencije, posebno za prepoznavanje biljnih vrsta, šteta i drugih definiranih karakteristika po potrebi.


Izuzetno praktičan metod za razlikovanje i ocjenu stanja poljoprivrednog usjeva je vegetacijski indeks (VI), koji je bezdimenzionalna veličina izračunata na osnovu refleksije elektromagnetnog zračenja u različitim dijelovima spektra (Krevh, 2018).

Postoji veliki broj različitih vegetacijskih indeksa koji se dobivaju upotrebom senzora (kamera) osjetljivih na specifične dijelove elektromagnetnog spektra. Vegetacijski indeks normalizovane razlike – NDVI (*eng. Normalized Difference Vegetation Index*) je najčešće korišten. Na NDVI mapama može se razlikovati tlo od vegetacije (trava ili šuma), utvrditi biljke pod stresom kao i razlikovati biljne vrste i njihove faza razvoja. Vrijednosti NDVI se kreću od 0 do 1, gdje su niže vrijednosti definirane kao površine bez vegetacije, sa jako oskudnom vegetacijom ili vegetacijom pod stresom. Na mapama su obično predstavljene crvenom bojom (slika 42).




Slika 42. Razlika između RGB snimka i NDVI

Postoje jake korelacije između ostvarenih prinosa i NDVI podataka mjerenih u određenim fazama rasta usjeva (Huang *et al.*, 2013). Prema tome, praćenje rasta usjeva u ključnim fazama može pomoći za preciznu procjenu prinosa ali i preventivno djelovanje kad je u pitanju biljni stres.



Slika 43. NDVI prikaz stanja travnjaka stadiona „Asim Ferhatović Hase“ u Sarajevu

Dronovi opremljeni kamerama sa infracrvenim (IR) multispektralnim senzorima, mogu veoma precizno analizirati zdravlje usjeva i stanje tla. NDVI podaci u kombinaciji sa drugim indeksima kao što je indeks vodnog stresa – CWSI (*eng. Crop-Water Stress Index*) i indeks sadržaja hlorofila – CCCI (*eng. Canopy-Chlorophyll Content Index*) mogu pružiti izrazito vrijedan uvid u stanje vegetacije nekog područja. Osnovni princip NDVI-a se oslanja na činjenicu da lišće reflektuje mnogo svjetla u bliskom infracrvenom području - NIR (*eng. Near Infrared*), talasne dužine (λ) od 0,7 μm do 1,4 μm . Kada je biljka pod određenim stresom (temperatura, voda, biljne bolesti) njeno lišće reflektuje manje NIR svjetlosti, ali istu količinu u vidljivom dijelu spektra (slika 44).



Slika 44. Refleksija elektromagnetnog zračenja od strane biljaka i tla

(Izvor: <http://hummingbirdaerialsurveys.com>)

Kombiniranjem ove dvije refleksije moguće je razlikovati biljku od ostalog prostora ili zdravu biljku od nezdrave (FAO, 2018). NDVI se određuje iz odnosa NIR i svjetlosti koju biljka absorbira – crvene svjetlosti (Red) po formuli:

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$$

Velik je broj vegetacijskih indeksa koji se koriste za različite namjene. Neki se također koriste za određivanje vodnog stresa kod biljaka ili stanja vlažnosti tla. U nastavku će biti navedeni neki od njih.

Visible Atmospherically Resistant Index (VARI) je dizajniran za rad sa RGB (crveno, zeleno i plavo svjetlo), a ne sa infracrvenim (NIR) podacima, što omogućava širu upotrebu i njegovo korištenje i sa bespilotnim letjelicama koji imaju obične RGB kamere. Suština je da VARI pokazuje “koliko je slika zelena”, te na taj način detektuje zdravu vegetaciju. Računa se po formuli:

$$VARI = \frac{(Green - Red)}{(Green + Red - Blue)}$$

Gdje je:

Green - vrijednosti piksela iz zelenog spektra

Red - vrijednosti piksela iz crvenog spektra

Blue - vrijednosti piksela iz plavog spektra.

Soil Adjusted Vegetation Index (SAVI) koristi korekcijski faktor boje tla kako bi analizirao dijelove usjeva koji nisu prekriveni vegetacijom, gdje je površina tla izložena. SAVI indeks omogućava tačniju analizu vegetacije u područjima gdje tlo ima značajan utjecaj na refleksiju svjetlosti, čime se smanjuje utjecaj tla na mjeru vegetacijskog pokrova. SAVI se računa po formuli:

$$SAVI = \frac{(NIR - Red) \times (1 + L)}{(NIR + Rred + L)}$$

Gdje je:

NIR – Blizu infracrveno zračenje

Red – Crveno zračenje

L – Koeficijent

Optimized Soil Adjusted Vegetation Index (OSAVI) je varijacija SAVI indeksa, ali s nižim faktorom kalibracije. Korištenjem OSAVI indeksa, postoji veća varijacija u refleksiji tla u poređenju sa SAVI, ali je istovremeno osjetljiviji na vegetaciju. Ovaj indeks je koristan u situacijama kada želimo preciznije pratiti stanje vegetacije, posebno u poljoprivrednim područjima gdje tlo ima značajan utjecaj.

Normalized Difference Red Edge Index (NDRE) mjeri količinu hlorofila u biljci. Niska količina hlorofila ukazuje na probleme u usjevu (bolest, štetnici, vodni stres). Najbolje vrijeme za primjenu NDRE indeksa je sredina do kasna faza rasta kada su biljke zrele i spremne za berbu. U tom trenutku, drugi indeksi bi bili manje efikasni za korištenje. Računa se po formuli:

$$NDRE = \frac{(NIR - RE)}{(NIR + RE)}$$

Gdje je:

NIR – Blizu infracrveno zračenje

RE – *Red Edge* (granica crvenog zračenja)

Leaf Water Content Index (LWCI) se koristi za prikazivanje stanje vlažnosti zelenih dijelova biljke. Može se dobiti iz podataka sa Lendsat ili Sentinel satelita. Za njegov proračun potrebni su podaci o refleksiji pri NIR (0,8-1,4 µm) i pri kratkotalasnom infracrvenom zračenju (*eng. Short Wavelength Infrared*) - SWIR (1,4-3µm).

Enhanced Vegetation Index (EVI) je rezultat integracije SAVI i ARVI vegetacijskih indeksa, stoga je EVI otporniji na utjecaj atmosferskog sastava aerosola i različite boje tla. EVI se koristi kao prikaz zelenila kod biljaka, a povezan je sa sadržajem hlorofila. Biljke koje nisu zdrave ili su pod nekim stresom odmah smanjuju sadržaj hlorofila i vode. Za njegov proračun potrebni su podaci o refleksiji pri NIR, Red i Blue talasnim dužinama.

Moisture Stress Index (MSI) mjeri refleksiju koja je rezultat povećanje sadržaja vode u listovima. Kako se sadržaj vode u lišću povećava, povećava se snaga apsorpcije na oko 1599 nm (SWIR). Sa druge strane, promjena sadržaja vode gotovo ne utiče na apsorpciju pri 819 nm (NIR), pa se ova vrijednost koristi kao referenca.

Ovaj indeks se koristi za analizu vodnog stresa zelenih dijelova biljke, predviđanje i modeliranje produktivnosti, analizu stanja opasnosti od požara i različita istraživanja iz oblasti fiziologije ekosistema. MSI je obrnut u odnosu na druge VI; veće vrijednosti ukazuju na veći vodeni stres i manji sadržaj vode. Vrijednost ovog indeksa kreće se od 0 do više od 3. Uobičajeni raspon zelene vegetacije je 0,4 do 2.

Kad je u pitanju praćenje vlažnosti tla najpreciznija tehnologija podrazumijeva korištenje *Synthetic aperture radara* (SAR). Ovo je radar postavljen na pokretnoj platformi poput satelita ili aviona, koji sam generira energiju i bilježi refleksiju te energije s površine Zemlje. Koristi duže valne duljine (od centimetra do metra), što omogućava prikupljanje podataka kroz oblake i noću. SAR je posebno koristan za procjenu vlažnosti tla, hrapavosti površine i drugih svojstava tla. Podaci su dragocjeni za upravljanje vodnim resursima, prognozu poplava, praćenje suša i održivu poljoprivredu. Najtačniji rezultati postižu se na ravnim područjima bez vegetacije. SAR tehnologija koristi se na satelitima poput Landsat i Sentinel-1.

LITERATURA:

- 1) Allen, R. G., Pereira, L., Raes, D., & Smith, M. (1998). Crop evapotranspiration: Guidelines for computing crop water requirements. Rome: United Nations FAO.
- 2) Biočić, M. (2014). Prikupljanje podatka novim i pristupačnim metodama izmjere korištenjem letjelica. (Bachelor), Sveučilište u Zagrebu, Zagreb.
- 3) Cadro, S., Markovic, M., Hadzic, A., Hadzic, A., & Zurovec, O. (2024). Assessing the impact of climate change on extreme hydrological events in Bosnia and Herzegovina using SPEI. *Journal of Central European Agriculture*, 25(2), 531-541. doi:10.5513/Jcea01/25.2.4183
- 4) Čadro, S., Cherni-Čadro, S., Marković, M., & Žurovec, J. (2019a). A reference evapotranspiration map for Bosnia and Herzegovina. *International Soil and Water Conservation Research*, 7(1), 89-101. doi:10.1016/j.iswcr.2018.11.002
- 5) Čadro, S., Uzunovic, M., Cherni-Čadro, S., & Žurovec, J. (2019b). Changes in the Water Balance of Bosnia and Herzegovina as a Result of Climate Change. *Agriculture and Forestry*, 65(3). Retrieved from https://web.archive.org/web/20200208072304id_/http://www.agricultforest.ac.me/data/20190930-02%20Cadro%20et%20al.pdf
- 6) Dingman, S. L. (2002). Physical hydrology [book + electronic resource] (2nd ed.). Upper Saddle River, N.J.: Prentice Hall.
- 7) Donassy, V. (1983). Fotografija, fotografski i nefotografski postupci snimanja u fotogrametriji i daljinskom istraživanju. Geodetski Fakultet, Sveučilište u Zagrebu.
- 8) FAO. (2018). E-Agriculture in Action: Drones for agriculture. Bangkok: Food and Agriculture Organization of United Nations.
- 9) FNC. (2021). Fourth National Communication of Bosnia and Herzegovina Under the United Nations Framework Convention on Climate Change (UNDP Ed.): UNDP. Retrieved from https://unfccc.int/sites/default/files/resource/FNC%20BiH_ENG%20fin.pdf
- 10) Gebbers, R., & Adamchuk, V. I. (2010). Precision Agriculture and Food Security. *Science*, 327(5967), 828-831. doi:10.1126/science.1183899
- 11) Giugliano, R. P., Ruff, C. T., Braunwald, E., Murphy, S. A., Wiviott, S. D., Halperin, J. L., . . . Duprat, C. (2013). Edoxaban versus Warfarin in Patients with Atrial Fibrillation. *New England Journal of Medicine*, 369(22), 2093-2104. doi:10.1056/Nejmoa1310907
- 12) Graça, N., Mitishita, E., & Gonçalves, J. (2014). Photogrammetric Mapping Using Unmanned Aerial Vehicle. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1.
- 13) Hargreaves, G. H., & Samani, Z. A. (1985). Reference crop evapotranspiration from temperature. *Transaction of ASAE*, 1(2), 96-99. Retrieved from [https://www.scirp.org/\(S\(i43dyn45teexjx455qlt3d2q\)\)/reference/referencespapers.aspx?referenceid=1225457](https://www.scirp.org/(S(i43dyn45teexjx455qlt3d2q))/reference/referencespapers.aspx?referenceid=1225457)
- 14) Huang, J. F., Wang, X. Z., Li, X. X., Tian, H. Q., & Pan, Z. K. (2013). Remotely Sensed Rice Yield Prediction Using Multi-Temporal NDVI Data Derived from NOAA's-AVHRR. *Plos One*, 8(8). doi:ARTN e70816 10.1371/journal.pone.0070816
- 15) Ingo, S. (2018). Irrigation in 3rd Millennium Southern Mesopotamia: Cuneiform Evidence from the Early Dynastie Illb City-State of Lagash (2475-2315 BC) (Vol. 53). Berlin: Berlin Studies of the Ancient World.

- 16) Jurišić, M., & Plašćak, I. (2009). Geoinformacijski sustav - GIS u poljoprivredi i zaštiti okoliša. Poljoprivredni fakultet Osijek.
- 17) Karleuša, B. (2007). Suvremene metode upravljanjima sustavima za navodnjavanje. Građevinski fakultet Sveučilišta u Rijeci, 287-319.
- 18) Kraus, K. (2006). Fotogrametrija (Vol. 1). Zagreb: Synopsis d.o.o.
- 19) Krevh, V. (2018). Primjena bespilotnih letjelica u poljoprivredi. (Bachelor'), Sveučilište u Zagrebu, Agronomski Fakultet, Zagreb.
- 20) Liu, Y., Teixeira, J. L., Zhang, H. J., & Pereira, L. S. (1998). Model validation and crop coefficients for irrigation scheduling in the North China plain. *Agricultural Water Management*, 36(3), 233-246. doi:Doi 10.1016/S0378-3774(97)00051-6
- 21) McCabe, G. J., & Markstrom, S. L. (2007). A monthly water-balance model driven by a graphical user interface. Reston, Virginia: U.S. Geological Survey.
- 22) Medić, T. (2015). Izmjera nepristupačnih područja pomoću bespilotnih letjelica. (Bachelor), Sveučilište u Zagrebu, Zagreb.
- 23) Niranjana, S., Gupta, G., Sharma, N., Mangal, M., & Singh, V. (2007). Initial Efforts toward Mission-specific Imaging Surveys from Aerial Exploring Platforms: UAV, In: GIS development. Paper presented at the Map World Forum, Hyderabad, India.
- 24) NJDOT. (1998). Minimum Guidelines for Aerial Photogrammetric Mapping. New Jersey: State of New Jersey, Department of Transportation.
- 25) Oluić, M. (2001). Snimanje i istraživanje Zemlje iz Svemira: sateliti, senzori, primjena. Hrvatska akademija znanosti i umjetnosti, Zagreb.
- 26) Penman, H. L. (1963). *Vegetation and hydrology*. Farnham Royal (Bucks.): Commonwealth Agricultural Bureaux.
- 27) Pereira, L. C., Teodoro, P. R., Rodrigues, P. N., & Teixeira, J. (2003). Irrigation scheduling simulation: The model ISAREG Tools for Drought Mitigation in Mediterranean Regions (pp. 161 - 180). Dordrecht: Kluwer Academic publisher.
- 28) Pereira, L. S., Allen, R. G., Smith, M., & Raes, D. (2015). Crop evapotranspiration estimation with FAO56: Past and future. *Agricultural Water Management*, 147, 4-20. doi:10.1016/j.agwat.2014.07.031
- 29) Raes, D., Steduto, P., Hsiao, T. C., & Fereres, E. (2009). AquaCrop-The FAO Crop Model to Simulate Yield Response to Water: II. Main Algorithms and Software Description. *Agronomy Journal*, 101(3), 438-447. doi:10.2134/agronj2008.0140s
- 30) Ran, H., Kang, S. Z., Li, F. S., Tong, L., Ding, R. S., Du, T. S., . . . Zhang, X. T. (2017). Performance of AquaCrop and SIMDualKc models in evapotranspiration partitioning on full and deficit irrigated maize for seed production under plastic film-mulch in an arid region of China. *Agricultural Systems*, 151, 20-32. doi:10.1016/j.agry.2016.11.001
- 31) Rao, A. S., & Saxton, K. E. (1995). Analysis of Soil-Water and Water-Stress for Pearl-Millet in an Indian Arid Region Using the Spaw Model. *Journal of Arid Environments*, 29(2), 155-167. doi:Doi 10.1016/S0140-1963(05)80086-2
- 32) Richardson, A. D., Braswell, B. H., Hollinger, D. Y., Jenkins, J. P., & Ollinger, S. V. (2009). Near-surface remote sensing of spatial and temporal variation in canopy phenology. *Ecological Applications*, 19(6), 1417-1428. doi:Doi 10.1890/08-2022.1

- 33) Sito, S., Kovačić, K., Krznarić, K., Bilandžija, N., Džaja, V., Škret, B., & Grubor, M. (2016). Primjena bespilotnih sustava u hortikulturnoj proizvodnji. Paper presented at the 51st Croatian and 11th International Symposium on Agriculture, Opatija, Hrvatska.
- 34) Sito, S., Kovačić, K., Škret, B., Šimunović, V., Grubor, M., & Koren, M. (2015). Primjena bespilotnih sustava u zaštiti trajnih nasada. *Glasnik zaštite bilja*, 4(15), 39-50.
- 35) Smith, M. (1992). CROPWAT: A computer program for irrigation planning and management. Rome: FAO land and Water Development Division.
- 36) Steduto, P., Hsiao, T. C., Raes, D., & Fereres, E. (2009). AquaCrop-The FAO Crop Model to Simulate Yield Response to Water: I. Concepts and Underlying Principles. *Agronomy Journal*, 101(3), 426-437. doi:10.2134/agronj2008.0139s
- 37) Thornthwaite, C. W. (1948). An Approach toward a Rational Classification of Climate. *The Geographical Review*, 38, 55-94.
- 38) Turc, L. (1961). Evaluation des besoins en eau d'irrigation, evapotranspiration potentielle, formule climatique simplifiée et mise a jour. *Annales Agronomique*, 12(1), 13-49.
- 39) Vanuytrecht, E., Raes, D., Steduto, P., Hsiao, T. C., Heng, L. K., Vila, M. G., . . . Moreno, P. M. (2014). AquaCrop: FAO's crop water productivity and yield response model. *Environmental Modelling & Software*, 62, 351-360. doi:10.1016/j.envsoft.2014.08.005
- 40) Vukadinović, V. (2017). Budućnost poljoprivrede [Press release]
- 41) Wolf, P. (1984). Elements of photogrammetry. SAD: McGraw-Hill Education.
- 42) Zarco-Tejada, J., Hubbard, N., & Loudjan, P. (2014). Precision agriculture: an opportunity for EU farmers - potential support with the cap 2014 - 2020 (Vol. B). Brussels: European Parliament.
- 43) Žurovec, J. (2012). Melioracije i uređenje poljoprivrednog zemljišta. Sarajevo: Univerzitet u Sarajevu, Poljoprivredno-prehrambeni fakultet.
- 44) Žurovec, J. (2016). Osnovi geodezije za agronome. Sarajevo: Poljoprivredno-prehrambeni Fakultet Univerziteta u Sarajevu.
- 45) Žurovec, O., Čadro, S., & Sitaula, B. K. (2017). Quantitative Assessment of Vulnerability to Climate Change in Rural Municipalities of Bosnia and Herzegovina. *Sustainability*, 9(1208), 18. doi:10.3390/su9071208.

SAVREMENI PRISTUPI U ZAŠTITI BILJAKA

Arnela Okić

Zaštita biljaka od bolesti i štetočina se u 21. stoljeću stavlja pred ogroman izazov. Izazovi se ogledaju kako u promjeni populacije patogenih organizama i štetočina, mogućnosti introdukcije novih štetnih organizama u određena geografska područja, klimatskih promjena, tako i u izmjeni legislative koja se odnosi na fitofarmaceutska sredstva.

Štete na usjevima uzrokovane štetnicima i bolestima dovode do velikih gubitaka prinosa, ljudskog gladovanja, pa čak i društvenih nemira (Chen i Wu, 2024.). Kroz historiju je zabilježeno nekoliko primjera koji pokazuju kompletne razmjere koje može poprimiti pojava određenog biljnog oboljenja ili štetnika. Najpoznatiji historijski primjer, a ujedno i inicijatorski događaj razvijanja naučne discipline fitopatologije, je Velika Irska glad iz sredine 19. stoljeća. Irska glad je bila uvjetovana pojavom plamenjače krompira (*Phytophthora infestans*), a historičari procjenjuju da je rezultirala smrću oko milijun ljudi i emigracijom 1,5 milijuna ljudi u Ameriku (Agrios, 2005). Pomenuti historijski događaj ima snažno socijalno-političko obilježje, karakteristično za doba u kojem je nastalo i tadašnji društveni poredak, ali katalizator događaja su bile nepovoljne vremenske prilike u dvije uzastopne vegetacijske sezone. Klimatski faktori igraju važnu ulogu u procesu nastanka i razvoja biljnih bolesti, ali isto tako i pojave štetnika.

Prema podacima Organizacije za hranu i poljoprivredu Ujedinjenih naroda (*Food and Agriculture Organization of the United Nations*, FAO), svake godine se zbog pojave biljnih štetnika i bolesti izgubi do 40% svjetskih usjeva. Nadalje, oko 25% požnjevenih žitarica kontaminirano je mikotoksinima, što otežava njihovo skladištenje i naknadnu potrošnja (Chen i Wu, 2024.). Imajući u vidu sve navedeno, procjenjuje se da godišnji gubitak poljoprivrednih dobara na globalnom nivou premašuju 220 milijardi USD.

Kako bi se smanjili gubici i zaštitile biljke od štetnih organizama, razvijene su različite mjere i metode zaštite koje su kasnije inkorporirane u specifične poljoprivredne koncepte, poput konvencionalne, integralne i biološke zaštite. Kako je na početku već naglašeno, jedan od izazova sa kojima se susreće zaštita biljaka u 21. stoljeću leži u klimatskim promjenama. Klimatski faktori (posebno temperatura i vlažnost) igraju važnu ulogu u procesu nastanka i razvoja biljnih bolesti, ali isto tako i pojave štetnika, i određuju intenzitet pojave (infekcijski pritisak) istih i dinamičnost širenja. Na primjer, povoljni vremenski uslovi za razvoj fitopatogene gljive *Phytophthora infestans*, uzročnika plamenjače krompira i paradajza, su visoka vlažnost zraka (> 90%) i niske temperature (16 °C) popraćene kišama (Janiszewska et al, 2021). Optimalna temperatura za sporulaciju je 12 do 18°C, ali sporangiji mogu preživjeti na temperaturama od 3 do 30 °C pri visokoj vlažnosti zraka, jer ključni faktor za preživljavanje spora je vlažnost (Modesto et al, 2016). Dakle, sušni periodi smanjuju održivost spora. Isto tako, sunčeva svjetlost negativno utječe na proces sporulacije; posebno ultraljubičasto zračenje oštećuje spore (Pacilly et al, 2016). Globalno, prosječne temperature su porasle posljednjih godina, a uočene su promjene u sadržaju atmosferske vlage, s porastom suše u mnogim regijama (Janiszewska et al, 2021). Sve ove klimatske promjene utječu na strukturu populacije *P. infestans*, preživljavanje genotipova u uzastopnim godinama i stopu razvoja bolesti plamenjače u vegetacijskoj sezoni. Međutim, biljni patogeni imaju sposobnost da se adaptiraju lokalnim uslovima putem mutacija (Desai et al, 2007) ili preko regulacije transkripcije gena, što se izražava interakcijom genotipa i okoliša (Linder et al, 2008). U slučaju *P. infestans*, Mariette et al, 2016) su, uspoređujući

tri osobine agresivnosti (latentno razdoblje, rast lezija i proizvodnju spora) navedenog patogena iz različitih klimatskih zona u Europi, pronašli da postoji specifična adaptacija genotipova na temperaturu i poveznica sa osobinama agresivnosti patogena. Dakle, populacije patogena mogu se prilagoditi novim klimatskim promjenama uz promjene njihove agresivnosti prema biljci domaćinu. Također, usljed promjene klimatskih prilika na jednom geografskom području moguće je da dođe do promjena u populaciji štetnih organizama (promjena ciklusa razvoja, povećan broj generacija u jednoj vegetacijskoj sezoni, promjene u simptomatološkoj ekspresiji), ali isto tako je povećan rizik od pojave novih štetnih organizama ukoliko novi klimatski uslovi to omogućavaju. Važno je istaknuti kako je postoji sve veći interes naučne zajednice prema razumijevanju utjecaja globalnog zatopljenja na buduće epidemije biljnih bolesti i proizvodnju hrane (Wu et al, 2022; Ristaino et al, 2021; Burdon & Zhan, 2020), ali da svi mehanizmi nisu još uvijek upotpunosti razriješeni. Smatra se da bi uticaj klimatskih promjena mogao zavisiti od samog kompleksa interakcije biljke domaćina-patogena sa njihovom sredinom (Wu et al, 2022).

Navedeno znači da se i princip zaštite biljaka mora prilagoditi novim uslovima i mogućim novim štetnicima. Promjenjivi vremenski uslovi kakvi vladaju u Bosni i Hercegovini posljednjih godina, sa obiljem kiše i potom sušnim periodima u kasnim ljetnjim mjesecima, su idealni uslovi za razvoj mikoza (bolesti uvjetovane infekcijom od strane gljiva i pseudogljiva), a ključni alat u spriječavanju istih su fitofarmaceutska sredstva, tačnije fungicidi (Moreira i sar. 2023). Pod pojmom fitofarmaceutskih sredstava važeća zakonska regulativa Bosne i Hercegovine (Zakon o fitofarmaceutskim sredstvima, Sl. Glasnik BiH, 49/2004), podrazumijeva u konačnom obliku aktivne materije i preparati, namijenjeni za: 1) zaštitu biljaka, odnosno biljnih proizvoda od štetnih organizama, odnosno za sprečavanje djelovanja štetnih organizama; 2) uticaj na životne procese biljaka, drukčije nego s hranjivima; 3) održavanje biljnih proizvoda, ako nisu predmet drugih propisa; 4) suzbijanje neželjenih biljaka, dijelova biljaka, zadržavanje ili sprečavanje nepoželjnog rasta biljaka. Sredstva koja se u zaštiti bilja koriste za suzbijanje štetnih organizama se tradicionalno nazivaju pesticidima, a nadalje se kategoriziraju na temelju ciljanog štetnog organizma kojeg suzbijaju, tako da se razlikuju sredstva za suzbijanje korova (herbicidi), sredstva za suzbijanje štetnih insekata (insekticidi) i sredstva za suzbijanje fitopatogenih gljiva (fungicidi). Dakle, fungicidi predstavljaju jedan tip fitofarmaceutskih sredstava koji su namijenjeni za suzbijanje fitopatogenih gljiva, uzročnika mikoza na biljkama. O tome koliko su zaista važni fungicidi za poljoprivredni sektor govori podatak da je u svijetu samo u 2020. godine prodano oko 605.986 tona fungicida, od čega je 31% prodano u Europi (FAOSTAT, 2020.). Navedeno čini fungicide drugom najprodavanijom klasom poljoprivrednih pesticida na globalnom nivou (23% prodaje pesticida) (FAOSTAT, 2020.).

Međutim, i u pogledu upotrebe pesticida postoji niz izazova. Veliki broj fitofarmaceutskih sredstava, na koje se i bosanskohercegovački proizvođači oslanjaju, se povlače sa tržištu zbog njihovog štetnog djelovanja na ljude, životinje i okoliš (Oerke, 2006), ali i zbog mogućnosti pojave rezistentnosti (Aktar et al, 2009). Cilj Evropske Unije (EU) je smanjenje upotrebe pesticida za 50%, a sve do 2030. godine (*Direktiva 2009/128/EC*). Postavlja se pitanje kako odgovoriti na ove ubrzane promjene u legislativi i kako prilagoditi sistem zaštite biljaka novim režimima?

Novi sistem zaštite biljaka treba da zadovolji nekoliko ključnih kriterija: da je ekološki prihvatljiv, da je održiv, da može osigurati prinos i prihod, a da je pored toga jednostavan za primijeniti.

Savremeni načini zaštite biljaka, prema Vinay i Singh (2023) obuhvataju:

1. Preciznu poljoprivredu,
2. Obradu podataka i vještačku inteligenciju,
3. Biotehnologiju i genetski inženjering,
4. Biopesticidi,
5. Nanopesticidi.

Precizna poljoprivredna je u prethodnim poglavljima već detaljno definisana, kao upotreba vještačke inteligencije i pametnih sistema uzgoja. U ovom poglavlju će se kod navedenih savremenih pristupa samo dati aspekt zaštite biljaka.

Precizna poljoprivreda

Kada je riječ o preciznoj poljoprivredi u ulozi zaštite biljaka misli se na upotrebu naprednih tehnologija preko senzora, dronova i analitike podataka za monitoring u upravljanje usjevima ili zasadima (Sishodia et al., 2020). Navedeno omogućava ciljanu aplikaciju fitofarmaceutskih sredstava ili blagovremeno otkrivanje pojave štetnog organizma. Najbolji primjeri precizne poljoprivrede su senzori, dronovi i agrometeorološke stanice. Senzorske tehnologije igraju ključnu ulogu u modernoj poljoprivredi pružajući podatke o zdravlju biljaka i uvjetima okoliša u stvarnom vremenu. Ovi senzori mogu mjeriti čimbenike poput vlage u tlu, razine hranjivih tvari i atmosferskih uvjeta, omogućujući poljoprivrednicima donošenje pravovremenih odluka o navodnjavanju, gnojidbi i suzbijanju štetnika (Adeyemi et al., 2017.). Navedeni senzori se inkorporiraju u agrometeorološke stanice i kombinuju sa informacijsko-komunikacijskim tehnologijama i analizom podataka kako bi pružili sveobuhvatni izvještajno-prognozni model. O navedenom će detaljnije govora u narednom potpoglavljju.

Korištenje dronova i bespilotnih letjelica (UAV) revolucioniralo je preciznu poljoprivredu. Opremljeni raznim senzorima i kamerama, dronovi mogu brzo pregledati velika polja, snimajući slike visoke rezolucije. Poljoprivrednici koriste ove podatke za identifikaciju stresa usjeva, zaraze štetnicima ili nedostatka hranjivih tvari (Mukherjee et al., 2019.) Često sinonimno se koristi pojam digitalne poljoprivrede.

Analiza podataka i vještačka inteligencija

Pod segmentom analize podataka i vještačke inteligencije u službi zaštite biljaka misli se na obradu velikih setova podataka, posebno procesuiranja informacija dobivenih od različitih senzora, u svrhu identifikacije i predikcije rizika od pojave štetnog organizma. Svaki štetni organizam ima svoje specifične zahtjeve prema ekološkim činiocima, što određuje dužinu pojedinih faza njegovog razvoja. Poznavanje navedenih pragova, prvenstveno temperaturnih, moguće je predvidjeti period pojave određenog štetnog organizma (npr. preko inkubacijskog perioda gljivičnih bolesti ili perioda razvoja od larve do imaga kod određenog insekta). Analizirajući velike skupove podataka koji dolaze sa različitih senzora, algoritmi vještačke inteligencije ili tzv machine learning, može da identificira specifične obrasce kod pojedinih stadija zaraze biljnim bolestima i tako omogućiti blagovremeno otkrivanje infekcije (Nong et al, 2023). Ovakav prediktativni pristup, koji je utemeljen na stvarnim podacima sa senzora u kombinaciji sa biološkim podacima o temperaturnim zahtjevima štetnog organizma, ujedno doprinosi ujedno i smanjenju upotrebe pesticida.

Biotehnologiju i genetski inženjering

U svim mjerama zaštite biljaka, neovisno da li se radi o organskoj ili integralnoj poljoprivrednoj proizvodnji, poseban akcenat se stavlja na otpornost biljke. Biotehnologija i genetski inženjering u službi zaštite biljaka nastoje stvoriti nove, tolerantnije ili rezistentnije genotipove na biljne bolesti, sušu ili druge ciljane karakteristike. Istraživači koriste biotehnološke pristupe za poboljšanje imuniteta biljaka, razvijajući genotipove s poboljšanom otpornošću (Bigini et al, 2021.) Također se na ovaj način utiče na smanjenje upotrebe pesticida, doprinosi ekološkoj osvještenosti i održivosti.

Biopesticidi

Ekološki najprihvatljiviji način suzbijanja štetnih organizama na biljkama su biopesticidi. Pod pojmom biopesticida misli se na prirodne proizvode za zaštitu zdravlja bilja koji se sastoje od živog organizma (insekti, gljive, bakterije) ili nekog prirodnog derivata dobivenog od biljaka ili mikroorganizama. Najpoznatiji biopesticid jeste NEEM ulje, koji se dobiva iz sjemenki biljke neem (*Azadirachta indica*) i koristi se za suzbijanje lisnih uši (*Aphididae*). Drugi poznatiji biopesticid, tačnije bioinsekticid, je na bazi bakterije *Bacillus thuringiensis*. Dobra pesticidna svojstva pokazuju i eterična ulja, a njihova primjena je usklađena sa potražnjom za održivom poljoprivredom i ciljem smanjenja korištenja sintetičkih preparata (Vinay i Singh, 2023). Međutim, još uvijek postoje izazovi u pogledu formulacije i standardizacije kod navedenih pripravaka, pogotovo kod onih namijenjenih za suzbijanje fitopatogenih gljiva. Ipak je važno istaknuti kako se pojedini biopesticidi pronalaze na BiH tržištu, uključujući i korisne insekte (bubamare, zlatooke, bogomoljke) za suzbijanje štetnih organizama, ali da je njihova primjena među poljoprivrednim proizvođačima još uvijek sporadična.

Nanopesticidi

Nanopesticidi predstavljaju novi segment unutar fitofarmacije i svojevrsnu revoluciju u zaštiti biljaka u pogledu preciznosti i održivosti. U ovom slučaju razlikujemo dva segmenta trenutnih istraživanja naučne zajednice: nanoenkapsulacije i nanosenzore. Nanoenkapsulacije podrazumijevaju tvorbu posebnih čestica unutar kojih se nalazi određena aktivna materija, zaštićena i sa produženim djelovanjem. Ovakvi materijali, odnosno tzv nanonosači omogućuju precizno i kontrolirano oslobađanje pesticida, smanjujući utjecaj na okoliš i povećavajući učinkovitost. Pomenuti materijalu mogu kapsulirati aktivne sastojke, štiteći ih od razgradnje i osiguravajući optimalnu dostavu ciljanim štetnicima (Khandelwal et al., 2016.). S druge strane, nanosenzori, predstavljaju sasvim novo područje istraživanja. Riječ je o malim uređajima namijenjenim za monitoring. Nanosenzori mjere parametre poput razine hranjivih tvari, sadržaja vlage i markera bolesti, omogućujući poljoprivrednicima donošenje proaktivnih odluka za optimalno upravljanje usjevima (Mahesho et al., 2023.).

U nizu svih navedenih pristupa, za Bosnu i Hercegovinu na njenom putu prema većoj ekološkoj svijesti i održivosti u segmentu zaštite biljaka, najprihvatljiviji jeste snažnija inkorporacija izvještajno-prognoznih sistema pod okriljem precizne ili digitalne poljoprivrede. Odnosno, jačanje mreže agrometeoroloških stanica i njihove upotrebe od strane poljoprivrednih proizvođača.

Izvještajno-prognozni sistemi i agrometeorološke stanice

Zaštita biljaka je kompleksna i dinamična, pogotovo kada se u obzir uzmu klimatske promjene. Zbog uticaja klime, ne samo da se mijenja režim primjene različitih zaštitnih mjera nad biljkama, nego dolazi i do promjene u populaciji štetnih organizama – povećava se broj generacija patogena i

štetnika, dolazi do pojavljivanja novih biljnih bolesti, potiskuju se druge biljne bolesti, a povećava se i mogućnost poprimanja epidemijskog karaktera kod pojedinih biljnih bolesti. Tačna prognoza pojave štetnih organizama je od iznimnog značaja za zaštitu prinosa poljoprivrednih kultura, ali i za zaštitu okoliša. Pod samim pojmom prognoze biljnih bolesti i štetnika podrazumijeva se predikcija pojave štetnog organizma upotrebom adekvatnih podataka i predstavlja proces koji je od iznimnog značaja za cjelokupan lanac snadbijevanja hranom (Liu et al, 2022). Pod adekvatnim podacima se ovdje misle na dvije ključne kategorije podataka: biološke i klimatske. Biološki podaci predstavljaju podatke o samom štetnom organizmu; njegovoj biologiji, epidemiologiji, i prvenstveno njegovim temperaturnim pragovima za rast i razvoj. Klimatski podaci se odnose na prikupljene podatke o temperaturi, vlažnosti zraka i zemljišta, vjetru i sl, dobivenih sa različitih senzora. Ovi podaci se skupljaju pravovremeno i kombiniraju se preko računarskih algoritama sa biološkim podacima i na taj način se vrši predikcija pojave. Jednostavnije rečeno, na temelju stvarnih podataka o klimatskim uslovima na jednom lokalitetu se vrši predviđanje o riziku pojave određenog štetnog organizma na datom području. Samim tim, navedeni sistem radi na sličan način kao vremenska prognoza, ali je posebno dizajniran za predviđanje izbijanja biljnih bolesti (Sangeetha et al, 2025). Ovaj sistem omogućuje procjenju vjerovatnoće pojave biljne bolesti ili insekta, kao i njegovu lokaciju pojave, a ujedno pomaže poljoprivrednim proizvođačima određivanje pravovremenog momenta zaštite poljoprivrednih kultura.

Prednosti primjene izvještajno-prognoznih sistema u zaštiti biljaka se ogledaju u pravovremenoj aplikaciji tretmana protiv štetnih organizama, ali i u mogućnosti smanjenja broja tretmana, što se oslikava i u ekološkoj i ekonomskoj sferi. Naime, pravovremenom aplikacijom pesticida na temelju procjene rizika pojave baziranoj na stvarnim biološkim i klimatskim podacima, moguće je smanjiti broj tretmana (Okić et al, 2015). U Bosni i Hercegovini je primjena izvještajno-prognoznih sistema testirana na primjeru zaštite zasada jabuke od fitopatogene gljivice *Venturia inaequalis* i od savijača jabuke (*Cydia pomonella*), gdje su rezultati pokazali tačnost korištenih prognoznih modela i smanjenje broja tretiranja (Okić et al, 2015).

U ovom pogledu je neophodno razlikovati dva ključna pojma: prognozne modele i agrometeorološku stanicu.

Krenut ćemo od same agrometeorološke stanice. Agrometeorološka stanica je skup senzora za prikupljanje različitih klimatskih parametara i digitalnih elemenata, koja se postavlja na poljoprivrednoj parceli ili u neposrednoj blizini zasada, a pokriva radijus od 15 km. Uobičajeno se sastoji od senzora za praćenje klimatskih parametara, data log uređaja, napojne jedinice (solarni paneli), komunikacijskog sistema i ekrana ili kontrolne jedinice. Za zaštitu biljaka od pojave biljnih bolesti, najvažniji senzor je tzv vještački list koji mjeri dužinu trajanja vlaženja lista, parametar koji je presudan za proces nastanka i razvoja bolesti kod velikog broja fitopatogenih gljiva. Svi podaci koji se prikupljaju na stanici se preko mrežnog sistema šalju na određenu platformu kojoj korisnik može pristupiti preko računara ili mobilnog uređaja. Dakle, agrometeorološka stanica je uređaj koji vrši prikupljanje klimatskih podataka i iste šalje na server ili platformu.

Prema Svjetskoj meteorološkoj organizaciji (WMO, 2010), agrometeorološke stanice se kategoriziraju u četiri skupine:

- Glavne agrometeorološke stanice – koje obezbjeđuju detaljne simultane meteorološke i biološke informacije i koje omogućavaju provođenje istraživanja. Instrumentalni kapaciteti, domet i učestalost posmatranja, kao i stručni kadar su takvi da se mogu sprovesti fundamentalna istraživanja iz oblasti agrometeorologije i zaštite poljoprivrednih kultura.

- Obične agrometeorološke stanice – one pružaju informacije na rutinskoj bazi, istovremeno biološke i meteorološke informacije. One su takođe opremljene da pomognu u istraživanju specifičnih problema.
- Pomoćne agrometeorološke stanice – također pružaju biološke i meteorološke informacije, ali u manjoj mjeri od agrometeoroloških stanica navedenih iznad. Meteorološke informacije uključuju stavke kao što su temperatura tla, vlaga tla, potencijalna evapotranspiracija, trajanje vegetativnog vlaženja i detaljna mjerenja u najnižem sloju atmosfere. Biološke informacije mogu obuhvatiti fenologiju, početak i širenje biljnih bolesti itd.
- Agrometeorološke stanice za specifičnu svrhu - to su stanice postavljene privremeno ili trajno za posmatranje jedne ili više varijabli i/ili specifičnih pojava.

Agrometeorološke stanice same po sebi samo prikupljaju određene podatke, ono što im daje značaj i praktičnu primjenu u zaštiti biljaka jeste njihovo kombiniranje sa prognoznim modelima i modernim informacijsko-komunikacijskim tehnologijama.

U prethodnom dijelu je već spomenuto kako svaki štetni organizam ima svoje određene pragove razvoja. Kombiniranje znanja o navedenim pragovima razvoja za određenog štetnog organizma sa historijskim statističkim podacima o klimatskim parametrima jedne regije ili pravovremenim podacima sa agrometeoroloških stanica moguće je kreirati matematičke modele prognoze rizika njihove pojave (Waggoner, 1981). Jedan od najpoznatijih prognoznih modela, a ujedno i najjednostavniji, jeste Millsov infekcijski kriterij za *V. Inaequalis* iz 1944. godine koji se bazirao na temperaturi i periodu vlaženja lista kod jabuke (MacHardy & Gadoury, 1988). Primjer Millsovog infekcijskog kriterija je dat u Tabeli 16., gdje je vidljivo da smanjenje temperature zahtjeva duži vremenski period vlaženja lista kako bi došlo do klijanja spora i uspostavljanja infekcije biljke domaćina. Navedeno znači da u sušnom periodu, postoji jako spore *V. inaequalis* neće klijeti, te ne postoji opravdanost provođenja tretmana fungicidima. Samo na ovom primjeru se može vidjeti kako upotreba prognoznih modela može da smanji broj tretmana, a samim tim i troškove zaštite poljoprivrednih kultura.

Tabela 16. Isječak iz Millsove tabele infekcijskog kriterija za *V. inaequalis*. (Prilagođeno iz Atlamaz et al. 2007 loc. cit Mills & LaPlante, 1954).

Temperatura (°C)	Dužina vlaženja lista (h)		
	Slaba infekcija	Srednja infekcija	Jaka infekcija
25.5	13	17	26
25	11	14	21
24.4	9.5	12	19
23.9-17.2	9	12	18
16.7	9	12	19
16.1	9.5	13	20
15.6	10	13	20
15	10	13	21

Noviji prognozni modeli su mnogo kompleksniji i imali su korist od napretka informacijsko-komunikacijskih tehnologija. U novije prognozne modele ulazi niz podataka, kako klimatskih tako i bioloških, i koriste specifične algoritme za predviđanje pojave. Nekoliko poznatijih modela

prognoze su: BLITECAST, SIMPHYT, BLIGHT PRO za *P. infestans*, EPIDEM, FAST i PLANT Plus za *Alternaria solani* na krompiru i paradajzu, EPIMAY i EPICORN za *Bipolaris maydis* na kukuruzu, EPIGRAM za *Blumeria graminis* f. sp. *hordei* na ječmu i dr. (Sangeetha et al, 2025).

Spajanjem prognoznih modela sa agrometeorološkim stanicama, kao i sa modernijim digitalnim sistemima, omogućeno je kreiranje posebnih platformi ili programa koji vizualno prikazuju i upozoravaju poljoprivredne proizvođače na mogućnost pojave štetnog organizma. Na taj način se poljoprivrednim proizvođačima pomaže pri donošenju odluke o pravovremenom momentu primjene zaštitnih mjera, na jedan veoma jednostavan način.

Važno je naglasiti kako svaki prognozni model, neovisno o kojem ciljanom štetnom organizmu se radi, mora proći validaciju tj. testiranje tačnosti prognoznog modela u stvarnim agroekološkim uslovima. S obzirom na mogućnosti promjena u populaciji patogena i štetnika i adaptaciji na lokalne ekološke uslove, preporučljivo je da se modeli testiraju za određene geografske regije. Također, za pojedine biljne bolesti nije moguće kreirati prognozne modele zbog njihovog veoma kompleksnog životnog ciklusa i prevelikog broja bioloških faktora koji utiču na isti.

LITERATURA:

1. Adeyemi O, Grove I, Peets S, Norton T. (2017) Advanced monitoring and management systems for improving sustainability in precision irrigation. Sustainability. 28;9(3):353.
2. Atlamaz, A.; Zeki, C, A. Uludag (2007) The importance of forecasting and warning systems in implementation of integrated pest management in apple orchards in Turkey, EPPO Bulletin 37, p. 295-299
3. Bigini V, Camerlengo F, Botticella E, Sestili F, Savatin DV. (2021) Biotechnological resources to increase disease resistance by improving plant immunity: A sustainable approach to save cereal crop production. Plants 10(6):1146
4. Burdon J.J., Zhan J. Climate change and disease in plant communities. (2020) PLoS Biol.;18:e3000949. doi: 10.1371/journal.pbio.3000949.
5. Charalampopoulos, I. (2021): Agrometeorological Conditions and Agroclimatic Trends for the Maize and Wheat Crops in the Balkan Region. Atmosphere 2021, 12, 671. <https://doi.org>
6. Chen, J, K, Wu (2024) New Plant Protection: New challenge and new opportunity for plant protection. New Plant Prot. 2024;1:e9 <https://doi.org/10.1002/npp2.9>
7. Desai M.M., Fisher D.S. (2007) Beneficial mutation selection balance and the effect of linkage on positive selection. Genetics. 2007;176:1759–1798. doi: 10.1534/genetics.106.067678
8. Janiszewska, M., Sobkowiak, S., Stefańczyk, E. et al. Population Structure of *Phytophthora infestans* from a Single Location in Poland Over a Long Period of Time in Context of Weather Conditions. Microb Ecol 81, 746–757 (2021). <https://doi.org/10.1007/s00248-020-01630-6>
9. Khandelwal N, Barbole RS, Banerjee SS, Chate GP, Biradar AV, Khandare JJ, et al. (2016) Budding trends in integrated pest management using advanced micro-and nano-materials: Challenges and perspectives. Journal of Environmental Management. 184:157-169.
10. Linder J.E., Owers K.A., Promislow D.E.L. The effects of temperature on host-pathogen interactions in *D. melanogaster*: Who benefits? (2008) J. Insect Physiol.;54:297–308. doi: 10.1016/j.jinsphys.2007.10.001.

11. Mahesha KN, Guddaraddi A, Reddy H, GV SK. (2023)Unleashing the Potential of Nanotechnology in Agriculture. *Advanced Innovative Technologies in Agricultural Engineering for Sustainable Agriculture*; . p. 97
12. Mariette N., Androdias A., Mabon R., Corbierem R., Marquer B., Montarry J., Andrivon D. (2016) Local adaptation to temperature in populations and clonal lineages of the Irish potato famine pathogen *Phytophthora infestans*. *Ecol. Evol.* 2016;6:6320–6331. doi: 10.1002/ece3.2282.
13. Mukherjee A, Misra S, Raghuwanshi NS. (2019)A survey of unmanned aerial sensing solutions in precision agriculture. *Journal of Network and Computer Applications.* ;148:102461.
14. Nong NB, Tarek M. (2023) Surveillance Approaches to Intrusion Detection, Crop Health, and Disease Prevention in Agriculture. *Quarterly Journal of Emerging Technologies and Innovations.*;8(3):1-17.
15. Okić A. Grahic J. Kurtovic M. Konjić A. Bajrić M. Kanlić K. Haseljic S. Gasi F. (2016) : First experiences on the open source technology platform VIPS in Bosnia and Herzegovina. *Faculty of Agriculture and Food Sciences University of Sarajevo.* 312-315.
16. Ristaino J.B., Anderson P.K., Bebber D.P., Brauman K.A., Cunniffe N.J., Fedoroff N.V., Finegold C., Garret K.A., Gilligan C.A., Jones C.M., et al. (2021)The persistent threat of emerging plant disease pandemics to global food security. *Proc. Natl. Acad. Sci. USA.* 2021;118
17. Sangeetha, B, , Adlin Pricilla Vasanti, Parveen, S. (2025). Plant disease forecasting: A comprehensive review. *International Journal of Horticultural Science and Technology*, 12(3), 821-834. doi: 10.22059/ijhst.2024.377298.858
18. Shaw M.W., Osborne T.M. (2011) Geographic distribution of plant pathogens in response to climate change. *Plant Pathol.* 2011;60:31–43. doi: 10.1111/j.1365-3059.2010.02407.x.
19. Sishodia RP, Ray RL, Singh SK. (2020) Applications of remote sensing in precision agriculture: A review. *Remote Sensing.* 12(19):3136.
20. Tatiana Moreira, Peter Groot Koerkamp, Arni Janssen, Tjeerd-Jan Stomph, Wopke van der Werf,Breaking the mould: Developing innovative crop protection strategies with Reflexive Interactive Design,*Agricultural Systems*,Volume 210,2023,103727,ISSN 0308-521X,https://doi.org/10.1016/j.agsy.2023.103727.
21. Vinay, P & G. Singh (2023)Innovations in safeguarding agriculture: An overview of emerging technologies for plant protection. *The Pharma Innovation Journal* SP-12(12): 132-135
22. Waggoner, P. E. (1981). Models of Plant Disease. *BioScience*, 31(4), 315–319. <https://doi.org/10.2307/1308149>
23. World Meteorological Organization (2010) Guide to Meteorological Instruments and Methods of Observation. Geneva, Switzerland, World Meteorological Organization, 1128pp. (WMO-No.8). DOI: <https://doi.org/10.25607/OBP-1533>
24. Wu EJ, Wang YP, Yang LN, Zhao MZ, Zhan J. Elevating Air Temperature May Enhance Future Epidemic Risk of the Plant Pathogen *Phytophthora infestans*. *J Fungi (Basel)*. 2022 Jul 30;8(8):808. doi: 10.3390/jof8080808. PMID: 36012796; PMCID: PMC9410326.

PRIMJENA PAMETNIH SISTEMA U VOĆARTVU

Osman Musić

Proizvođači voća trenutno se suočavaju sa mnogim izazovima, a kao najvažniji mogu se izdvojiti klimatske promjene, radna snaga i visoki zahtjevi potrošača. Opće je prihvaćena činjenica da se pod utjecajem promjena atmosferskih plinova klima mijenja (Moriondo i Bindi, 2007). Klimatske promjene manifestiraju se povećanom prosječnom temperaturom zraka, sve učestalijom pojavom sušnih perioda ili obilnih padavina (u vrlo kratkim vremenskim intervalima), toplijim zimama itd. Kao posljedica povećanih temperatura zraka, period vegetacije traje sve duže, dok se period zimskog mirovanja skraćuje. Raniji ulazak voćke u period vegetacije povećava rizik od izmrzavanja generativnih organa voćke. Također, u provom dijelu vegetacije zabilježene su promjene u trajanju određenih fenofaza.

S obzirom na to da je proizvodnja voća radno visoko intenzivna, u današnje vrijeme se sve više uočava problem u vezi s radnom snagom. Dostupnost, produktivnost i troškovi radne snage imaju ogroman uticaj na industriju voća, naročito kada je u pitanju globalna konkurentnost.


Pored navedenog, dodatni izazov proizvođačima voća nametnut je i od strane potrošača. Danas je, više nego ikad, na tržištu svježeg voća od presudnog značaja njegov kvalitet. Najznačajna svojstva kvaliteta voćnih plodova su vanjski izgled (boja, veličina, odsustvo oštećenja), karakterističan i svojstven okus, prijatna aroma i zdravstvena bezbjednost (odsustvo rezidua pesticida). Nedostatak bilo kojeg ključnog atributa kvaliteta ploda može umanjiti vrijednost proizvoda.

Zbog gore navedenog, proizvođači voća moraju se fokusirati na primjenu svih mogućih mjera pomoću kojih će prevazići navedene izazove. U tu svrhu moderni proizvođači voća sve više svoju proizvodnju baziraju na konceptu precizne poljoprivrede. Uloga precizne poljoprivrede je da poveća prinose i olakša donošenje upravljačkih odluka na farmama koristeći moderne, napredne tehnologije kao što su senzori, te mjerni i analitički alati. Proizvodnja bazirana na principima precizne poljoprivrede koristi veliki broj podataka i informacija u svrhu: efektivnog smanjenja rada, efikasnog upravljanja poljoprivrednim resursima i racionalnog korištenja inputa. Dakle, precizna poljoprivreda je pristup upravljanja proizvodnjom gdje se precizni inputi i prakse primjenjuju na preciznim lokacijama unutar voćnjaka s namjerom da „učine pravu stvar“ u „pravo vrijeme“ i „na pravi način“. Također, sve više proizvođača na svojim farmama uspješno primjenjuju informacione tehnologije, tako da i koncept digitalne poljoprivrede sve više dobija na značaju. Ova rješenja fokusiraju se na automatizaciji mašina (opreme) i procesa, uključujući dostignuća u oblasti vještačke inteligencije kao što su: mašinsko učenje, konvulzione i klasične neuronske mreže, te duboko učenje. S obzirom da će u određenim potpoglavljima primjena pametnih sistema u voćarstvu biti bazirana na upotrebi umjetne inteligencije, mašinskog i dubokog učenje postoji potreba za kratkim definisanjem navedenih termina.

Umjetna inteligencija (eng. *Artificial intelligence – AI*) je sposobnost nekog uređaja (kompjutera ili kompjuterski kontrolisanog robota) da obavlja aktivnosti koje su obično povezane sa pametnim bićima poput zaključivanja, učenja, planiranja i kreativnosti (Copeland, 2024). Umjetna inteligencija omogućava tehničkim sistemima percepciju okruženja, uzimanje u obzir onog što vide i rješavanje problema kako bi postigli neki cilj.

Mašinsko učenje (eng. *Machine learning – ML*) je podskup umjetne inteligencije. Ono podrazumijeva proces koji omogućava sistemima da automatski uče i unapređuju svoje znanje na osnovu prethodnog iskustva, bez potrebe za eksplicitnim programiranjem, tj. na osnovu generičkih algoritama dobijaju se informacije o nekom skupu podataka, bez pisanja programskog koda. Koristi se za upotrebu podataka i algoritama, kako bi se oponašao način na koji ljudi uče. Podatke je potrebno unijeti u generički algoritam, kako bi on izgradio sopstvenu logiku zasnovanu na unesenim podacima. Ne može se reći da jedan algoritam radi najbolje za svaki problem, jer pored mnogih drugih faktora, veličina i struktura podataka imaju svoj uticaj.

Duboko učenje (eng. *Deep learning – DL*) je podskup mašinskog učenja koji koristi neuronsku mrežu. Neuronska mreža je skup međusobno povezanih jednostavnih procesnih elemenata, jedinica ili čvorova (neuron), čija se funkcionalnost temelji na biološkom neuronu. Struktura neuronske mreže se razlikuje po broju slojeva. Prvi sloj se naziva ulazni, a posljednji izlazni, dok se slojevi između nazivaju skriveni slojevi. Najčešće ih ima tri. Prvi sloj, tj. ulazni je jedini sloj koji prima podatke iz spoljašnje sredine, naredni (skriveni) prosljeđuje relevantne podatke do trećeg (izlaznog) sloja. Na izlazu trećeg sloja dobija se konačan rezultat. Složenije neuronske mreže imaju više skrivenih slojeva. Slojevi su međusobno potpuno povezani. Slojevi komuniciraju tako što se izlaz svakog procesnog elementa prethodnog sloja povezuje sa ulazima svih procesnih elemenata narednog sloja. Znači, svaki procesni element ima nekoliko ulaza i jedan izlaz. Jačina veza kojom su procesni elementi povezani naziva se težinski faktor.



Slika 45. Hijerarhija umjetne inteligencije, mašinskog učenja i dubokog učenja (Gavrilova, 2020)

Uopšteno, tehnološka rješenja koja se temelje na senzorima, analitičkim i digitalnim instrumentima, automatizaciji, informacionim tehnologijama i umjetnoj inteligenciji mogu se smatrati elementima pametnog sistema upravljanja. U voćarstvu, pametni sistemi se mogu primjenjivati u periodu prije, tokom i nakon berbe plodova. S obzirom na to da je u okviru ovog udžbenika zasebno opisana primjena pametnih sistema iz oblasti koje su za uspješnu voćarsku proizvodnju od presudnog značaja (navodnjavanje, ishrana i zaštita biljaka, te mehanizacija), u okviru ovog poglavlja dat je prikaz primjene pametnih sistema u voćarstvu koji se ne odnosi na gore navedene oblasti.

U proizvodnji voća, pametni sistemi se također mogu primjenjivati u svrhu: procjene početka kretanja vegetacije, posmatranja fenofaza razvoja vegetativnih i generativnih organa, određivanja intenziteta cvjetanja, određivanja optimalnog opterećenja voćki, prorjeđivanja plodova, procjene prinosa voćaka, praćenja rasta ploda i određivanja momenta berbe.

Procjena početka kretanja vegetacije

Kod listopadnih, umjereno-kontinentalnih voćnih vrsta u toku godišnjeg ciklusa jasno su uočljiva dva perioda: period vegetacije i period mirovanja. Tokom perioda vegetacije voćka izgrađuje trajne i privremene organe. U periodu mirovanja listopadne voćne vrste su bez listova, ali se u njima odvijaju druge fiziološke funkcije značajne za život voćke. Ova dva perioda su fiziološki usko povezana, predstavljaju kontinuitet fizioloških procesa. Nepovoljni vremenski uslovi koji onemogućavaju normalno odvijanje fizioloških procesa u jednom ili drugom periodu dovode do poremećaja u životu voćke. Zbog toga je značajno poznavanje zahtjeva voćnih vrsta i sorti, prema ekološkim uslovima neophodnim za normalnu vegetaciju i mirovanje, posebno prema temperaturi. Listopadne, umjereno-kontinentalne voćne vrste u toku zimskog mirovanja moraju skupiti dovoljan broj hladnih jedinica (eng. *chilling units* ili CU, odnosno *chilling hours* ili CH) i jedinica prirasta (eng. *growing-degree hour* ili GDH), kako bi u proljeće mogle nastaviti normalno sa svojim razvojem.

Period mirovanja obično se sastoji iz dvije faze: unutarne ili fiziološko mirovanje i ekološko ili nametnuto mirovanje. Unutarnje mirovanje javlja se početkom zime zbog visoke razine inhibitora (abscisinske kiseline ili ABA) unutar pupoljaka. Koncentracija inhibitora smanjuje se nakon izloženosti pupoljaka niskim temperaturama ($<7,2^{\circ}\text{C}$). Tek kada je ispunjen uslov akumulacije potrebnih „niskih“ temperatura, razina inhibitora u korijenu je dovoljno niska da rast može započeti, ali tek kada uslovi budu prikladni za rast (nakon ekološkog mirovanja). Ekološko mirovanje obično počinje sredinom januara, nakon što su zadovoljene fiziološke potrebe voćke za „niskim“ temperaturama. Ovaj tip mirovanja smatra se nametnutim jer u umjereno-kontinentalnim i kontinentalnim klimatima period sa niskim i nepovoljnim temperaturama traje duže nego što su fiziološke potrebe voćke (Lučić *et al.*, 1996). Početak vegetacije nastupa kada voćka pored sakupljenih hladnih jedinica (u fazi unutarnjeg mirovanja), skupi i dovoljnu količinu jedinica prirasta (u fazi ekološkog mirovanja). Jedna jedinica prirasta odgovara jednom satu kada je temperatura bila jedan stepen iznad $4,5^{\circ}\text{C}$. Akumulacija jedinica prirasta ima linearan trend rasta do temperature od 25°C , jer je pretpostavka da u periodu mirovanja temperature iznad tog praga imaju biološki posmatrano isti uticaj.

Postoje različiti modeli kojima se pokušava procijeniti koja je to suma sati hlađenja potrebna za indukciju cvjetanja (tzv. termoperiodska vernalizacija). Najčešći modeli u upotrebi su: *Chilling hours*, Utah i dinamički model. Svi modeli zahtijevaju praćenje temperature zraka po satima. Za precizno prikupljanje podataka o temperaturama zraka na određenom lokalitetu (voćnjaku) koriste se agrometeorološke stanice.


Chilling hours model je najduže u upotrebi (Chandler, 1942). Prema ovom modelu, temperature između 0°C i 7,2°C imaju uticaj na hlađenje voćke. Svaki provedeni sat u ovom temperaturnom intervalu smatra se satom hlađenja. Sati hlađenja se akumuliraju tokom perioda mirovanja i na kraju zbrajaju (Luedeling, 2012).

Utah model razvijen je od strane Richardson *et al.* (1974). Navedeni autori smatraju da temperature između 0°C i 16°C pospješuju prekid mirovanja, dok temperature iznad 16°C poništavaju takav učinak. Maksimalna promocija prekida mirovanja događa se na 7 °C (1 h na 7 °C = 1 jedinica hađenja), a više i niže temperature u rasponu od 0 do 16°C su manje učinkovite. Model pretpostavlja da se akumulacija jedinica hlađenja događa unutar temperaturnog raspona od 1,4 i 12,5°C, a izvan ovog raspona akumulacija je nula ili negativna.

Tabela 16. Kalkulacija sume jedinica hlađenja prema Utah modelu (Richardson *et al.*, 1974)

Temperatura °C	Hladne jedinice (<i>Chill units</i>)
<1,4	0,0
1,4 – 2,4	0,5
2,5 – 9,1	1,0
9,2 – 12,4	0,5
12,5 – 15,9	0,0
16 – 18	-0,5
>18	-1,0


Ovaj model, daje dobre rezultate u hladnoj i umjerenj klimi, dok je u suptropskoj klimi njegova upotreba i primjena ograničena.



Slika 46. Grafički prikaz Utah modela.

Dinamički model razvijen je u Izraelu (Fishman, 1987). Na osnovu satnih temperatura model računa jedinice hlađenja u obliku „porcija hlađenja“. Ovaj model se sastoji od dvije faze (A-B i B-C). Prva reakcija A → B odvija se u temperaturnom intervalu od 0°C do 10-12°C, sa brzinom rasta do optimalne temperature hlađenja (6,8-7,2°C). Reverzibilna reakcija B → A stimulirana je temperaturama iznad 12-15°C. Tranzicija pupoljaka od stadija A do stadija B odvija se kao slijed

percepcije uticaja hlađenja (eng. *chilling perception*), dok rekonverzija iz stadija B u stadij A odvija se kao posljedica temperatura izvan temperaturnog intervala hlađenja (tj. od 0°C do 10-12°C), te se ovaj uticaj smatra negacijom uticaja hlađenja (eng. *chilling negation*). Konverzija pupoljaka iz faze B u fazu C posljedica je fiksiranog efekta hlađenja (eng. *chilling fixation*) koja se odvija kroz jedinične „porcije hlađenja“. Ovaj model daje dobre rezultate u klimatima sa toplijim zimama.



Slika 47. Grafički prikaz dinamičkog modela (Fichman *et al.*, 1987).

Važno je naglasiti da niti jedan model ne uzima u obzir temperature manje od 0 °C (neki ne manje od 1,4 °C) jer one ne doprinose mirovanju voćaka. Modeli, ukoliko se pravilno koriste imaju solidne prediktivne sposobnosti. Najveći problem kod primjene navedenih modela predstavlja određivanje vremena od kada treba računati akumulirane jedinice hlađenja. Kod umjerenih klimata preporučuje se da brojanje jedinica hlađenja krene nakon jednog dužeg hladnijeg razdoblja, što se obično dešava u oktobru. U klimatima gdje je blaga jesen, brojanje jedinica hlađenja treba započeti u trenutku kada voćke odbace 50% listova.

U Bosni i Hercegovini nema kalibriranih vrijednosti za sume jedinica hlađenja i jedinica prirasta po vrstama, sortama i regijama. U tabeli ispod navedene su potrebne vrijednosti jedinica hlađenja i jedinica prirasta koje voćke moraju prikupiti u toku od perioda mirovanja do početka cvjetanja.

Tabela 17. Zahtjevi sorti (određenih voćnih vrsta) za jedinicama hlađenja i jedinicama prirasta u periodu od početka mirovanja do početka cvjetanja (Sansevini *et al.*, 2012)

Vrsta	Sorte	Jedinice hlađenja	Jedinice prirasta
Jabuka	Red Delicious	1.234	6.172
Kruška	Viljamovka	1.210	5.044
Trešnja	Bing	880	5.328
Breskva	Redhaven	870	4.174
Šljiva	Italian Prune	788	10.230
Kajsija	Titlon	720	3.533


Posmatranje fenofaza razvoja vegetativnih i generativnih organa

Fenologija je nauka o pojavnim oblicima životinja i biljaka koji su uslovljeni godišnjim dobima. Ovisno o predmetu posmatranja, razlikuje se fitofenologija (fenologija biljaka) i zoofenologija (fenologija životinja). Dakle, fitofenologija se bavi proučavanjem pojedinih faza razvića biljaka tokom vegetacionog perioda, s ciljem utvrđivanja dinamike i trajanje određenih pojava (tzv. fenofaze), kao i njihovu ovisnost o faktorima spoljne sredine. Fenofaza (grč- *phaino*=sjajiti, pojaviti se + *phasis* = pojavljivanje, mijena) je razdoblje u godišnjem ciklusu organizma. Fenofaze su karakteristične za svaku biljnu vrstu, s tim što trenutak pojave određene fenofaze ovisi od više faktora, kao npr: sorta, vremenske prilike (prvenstveno temperatura, padavine i insolacija), nadmorska visina, ekspozicije terena, primjenjenih agrotehničkih zahvata itd.

Fenološka praćenja imaju veliki značaj u proizvodnji voća, jer su sve agrotehničke i pomotehničke mjere koje se primjenjuju u voćnjaku usko povezane sa fenofazama rasta vegetativnih i generativnih pupoljka. Na osnovu fenoloških osmatranja mogu/može se:


- odrediti optimalni rokovi primjene sredstava za zaštitu biljaka i đubriva,
- odrediti termini navodnjavanja (uz praćenja stanja vlage u zemljištu),
- optimizirati oplodnja, odabirom odgovarajućih sorti oparašivača sličnog perioda cvatnje,
- pravovremeno primjeniti bioregulatori rasta u cilju: prorjeđivanja plodova u prvom dijelu vegetacije, smanjenja bujnosti mladara, poboljšanja obojenosti plodova, izduživanja ploda, sprečavanja opadanja plodova pred berbu, te poboljšanja skladišne sposobnosti plodova,
- odrediti optimalni rok ljetne rezidbe, te
- odrediti orijentacioni trenutak berbe na osnovu veličine i boje ploda.

Fenofaze se mogu pratiti korištenjem različitih metoda. Ovisno o prostornoj razmjeri one se mogu posmatrati na na individualnom, regionalnom i globalnom nivou (slika 48.).



Slika 48. Metode fenoloških posmatranja (Individualni nivo: PL-početak listanja, RL-rast listova, OL-opadanje listova, PoC-početak cvjetanja, PuC-puno cvjetanje, PC-precvjetavanje, ZP-zametanje plodova, RP-rast ploda, SP-sazrijevanje plodova; Plot-regionalni nivo: PV-početak vegetacije, KV-kraj vegetacije, DV-dužina vegetacije, L-listanje, C-cvjetanje, SL-senescencija listova (promjena boja)) (Jose *et al.*, 2023).


Satelitsko praćenje je najnepreciznija metoda posmatranja fenofaza. Primjenjuje se na nivou regiona ili globalno, a na osnovu snimaka moguće je samo utvrditi početak, kraj i dužinu vegetacije.



Slika 49. Satelitski prikaz zasada jabuke i trešnje. Prva kolona prikazuje Google Earth sliku; od druge do pete kolone prikane su Sentinel-2 slike navedenih zasada u proljeće, ljeto, jesen i zimu (Zhu, 2020)

Razvojem digitalnih kamera i sofvera za obradu fotografija omogućeno je praćenje fenofaza na nivou pojedinačnih zasada, a i šire. U engleskoj literaturi ovaj metod posmatranja fenoloških faza naziva se „*Land Surface Phenology- LSP*“. Za prikupljanje podataka blizu iznad površine zemlje obično se koriste digitalne kamere, kao što su fenokamere i kamere nošene ili integrisane u bespilotne letjelice (dronove).

Fenokamere su digitalne kamere pozicionirane na tornju (nosaču) iznad krošnje (Richardson *et al.*, 2007; 2009). Mreže digitalnih kamera uključujući PhenoCam (<https://phenocam.nau.edu/webcam/>), evropsku fenološku mrežu (<https://european-webcam-network.net/>) i mrežu fenološke oči (<http://www.pheno-eye.org/>) već pokrivaju širok spektar ekosistema širom svijeta (Richardson *et al.*, 2013). Kvantifikacijom crvenog, zelenog i plavog (RGB) kanala boje fenokamerama je moguće detektovati fenološke stadije razvoja lista (listanje, senescenciju i opadanje listova) i cvjetanje. Ukoliko su na fotografiji obuhvaćena stabla različitih sorti, moguće je obilježavanjem regije od interesa (ROI) zasebno posmatrati navedene fenofaze razvoja obilježene grupe stabala. Detaljne informacije o automatskom praćenju fenologije upotrebom fenokamera moguće je pronaći u protokolu razvijenom od Wingate *et al.* (2015).



Slika 50. Ilustracija osnovnih komponenti fenokamere-lijevo (Shajahan, 2016); fenokamera u zasadu masline-desno (izvor: <https://rslab.gr/phenocams.html>).

Pored stacionarnih kamera, za praćenje fenofaza razvoja biljaka mogu se upotrebljavati i **bespilotne letjelice - dronovi** (Thapa, 2021). Uz pomoć standardnih ili multispektralnih kamera dronovi u toku leta iznad krošnje prave fotografije visokih rezolucija. U poređenju sa konvencionalnim letjelicama, dronovi mogu operirati po zanemarivo niskim cijenama, čime je omogućena frekventnija praćenja. Upotrebom fotogrametrijskih tehnika na dronskim fotografijama ostvaren je značajan napredak u onosu na fotografije sa tornja (mjesto gdje se postavljaju fotokamere). Ortomozaici ili orto slike simuliraju neiskrivljenu perspektivu krošnje, sa dosljednom prostornom rezolucijom u odnosu na pejzaž, čime se omogućava identifikacija i analiza pojedinačnih stabala. S tim u vezi, dronovi se u voćarstvu mnogo češće koriste za procjenu intenziteta cvjetanja, praćenje rasta ploda, predviđanje prinosa, praćenje rasta krošnje, detekciju bolesti, aplikaciju fitofarmaceutuskih sredstava, procjenu potreba za navodnjavanjem, i dr. Detaljni podaci o tipovima dronova, njihovim karakteristikama, dizajnu putanje dronova, neuronskim mrežama (serije, konfiguracije i funkcije), softverima, skupu podataka, statističkim indikatorima učinka, te novi trendovi upotrebe dronova u voćarskoj proizvodnji navedeni su u preglednom radu Popescu *et al.* (2023).

Važno je napomenuti da za korištenje satelitskih snimaka, fenokamera ili dronova u voćarstvu, zasad mora biti pod „otvorenim nebom“, tj. ne može se iznad krošnje nalaziti folija ili protivgradna mreža. Navedena činjenica predstavlja ogromnu manu pomenutih metoda, s obzirom da je sistem protivgradnih mreža sve više u upotrebi, naročito kada se radi o intenzivnim i visokointenzivnim voćnjacima.

Do sada najzastupljeniji metod praćenja fenofaza rasta u voćarstvu baziran je na **ljudskoj observaciji**. Fenološki podaci u Bosni i Hercegovini prikupljaju se od 1961. godine. Fenološki godišnjaci publikuju se na stranici Federalnog hidrometeorološkog zavoda (<https://www.fhmzbih.gov.ba/latinica/FENO/godisnjaci.php>). Podaci iz fenoloških godišnjaka mogu imati značajnu vrijednost prilikom podizanja novih zasada, naročito kada je u pitanju odabir vrste i sortiment. Pored toga, moguće je izvršiti procjenu rizika određene proizvodnje na datom lokalitetu ukoliko se fenološki podaci kombiniraju sa klimatskim podacima, a naročito sa podacima o frekveniciji pojave mraza ili grada u određenim fenofazama.

Kako bi donosili pravovremene odluke o provedbi određenih agrotehničkih i pomotehničkih mjera profesionalni voćari primorani su svakodnevno pratiti trenutnu fenofazu razvoja vegetativnih i generativnih organa. Najzastupljenija praksa u Bosni i Hercegovini podrazumijeva svakodnevni odlazak u voćnjak (naročito u periodu od fenofaze početka cvjetanja do nakon prorjeđivanja – veličina plodova cca. 25-30 mm).

U voćarski razvijenim zemljama, u svrhu praćenja fenofaza, sve više su u upotrebi kamere koje se postavljaju unutar zasada (blizu krošnje). To su obično sistemi kamera sa integrisanom elektornikom (kamera, modem, izvor napajanja sa solarnim panelom). Postoje više varijacija kamera, a osnovna razlika ogleda se u broju i preformasama objektiva (broj megapiksela i vrsti sočiva).

Kamera se u voćnjaku obično postavlja u unutaredni prostor sa okrenutim objektivnom u red nasuprot (udaljenost od objekta slikanja iznosi oko 3-3,5 m). Sa tehničkog aspekta važno je navesti da kamera u trenucima slikanja ne smije biti okrenuta u pravcu sunca.



Slika 51. Izgled postavljene kamere u sklopu meteorološke stanice – lijevo; izgled kadra (široki ugao) – desno (izvor: <https://metos.global/en/cropview/>).

Kompanije koje su lideri u proizvodnji kamera za poljoprivredne svrhe obično nude i druge proizvode pametnih sistema (meteorološke stanice, senzore, dendrometre, itd.) te obično imaju razvijene platforme (aplikacije) na kojima je moguće vizualizirati i analizirati sve prikupljene podatke.

U svrhu praćenja fenofaza rasta mogu se koristiti i niskobudžetne kamere sa solarnim napajanjem, koje se obično koriste u nadzorne svrhe, s tim što iste obično nemaju prikladno razvijene aplikacije.

Određivanje optimalnog opterećenja voćaka

Wünsche i Ferguson (2005) opterećenost voćke izražavaju na osnovu količine (broja ili težine) plodova po stablu. U engleskoj literaturi se često koristi i termin „*yield efficiency*“ tj. efektivnost prinosa, gdje se opterećenost iskazuje kao prinos po cm² poprečnog presjeka debla, prinos po jedinici ukupne površine lista, te prinos po zapremini krošnje. U naučnoj literaturi opterećenost stabla se najčešće izražava brojem plodova po cm² poprečnog presjeka debla (eng. *Trunk cross saction area ili TCSA*). Da bi se odredio TSCA neophodno je izmjeriti diameter debla na visini od 30 cm iznad spojnog mjesta. Dosadašnja praksa mjerenja diametera debla zasnivala se na upotrebi digitalnih šublera, a potom bi se na osnovu formule izračunao poprečni presjek debla prema formuli:

$$TCSA = (\text{diameter debla}/2)^2$$

Osim navedene metode, optimalno opterećenja mladih stabala jabuke može se odrediti upotrebom šablona (*Valent/Cornell Young Apple Thinning Gauge*).

Za kontinuirano mjerenje prečnika debla mogu se koristiti i električni dendrometri. Ovi uređaji primarno se koriste za detekciju vodenih stresova jer kontinuirano prate skupljanje i rast debla. Izbor dendrometra zavisi od diametera debla, a s obzirom da je upotreba ovog uređaja relativno skupo rješenje za prećenje prečnika debla, njihova je upotreba u ovu svrhu praktično vrlo malo zastupljena.




Slika 52. Mjerenje prečnika debla uz pomoć digitalnog šublera (lijevo), šablona (sredina) i dendrometra (desno)

Primjena vještačke inteligencije u mjerenju prečnika debla još je u eksperimentalnoj fazi. Nieto *et al.* (2023) su upotrebom „*Orchard Robotics visual system*“ određivali prečnik debla jabuke kod tri sorte (Gala, Honeycrisp i Fuji). Navedeni sistem razvijen je u saradnji sa Cornell Univerzitetom (SAD), a sastoji se od sistema sofisticiranih kamera (100 slika u sekundi) i softvera za obradu slika na bazi mašinskog učenja. „*Orchard Robotics visual system*“ fotografiše svako stablo unutar reda (od spojnog mjesta do prvih ramenih grana), a potom se vrijednosti TSCA izračunavaju pomoću softvera. Rezultati dobijeni korištenjem vještačke inteligencije pokazuju manje vrijednosti u odnosu na ručno mjerene vrijednosti, jer se upotrebom softvera TSCA određuje na srednjoj visini označenog debla, a ne na visini od 30 cm od spojnog mjesta (R^2 između 0,5 i 0,79).



Slika 53. Izgled sistema kamera „Orchard Robotics visual system“ i izgled slike sa vrijednostima TSCA nakon softverske obrade

Prema većem broju studija optimalan broj plodova jabuke po cm^2 poprečnog presjeka debla u formi vitkog vretena na M9 podlozi iznosi od 6 do 10, ovisno o starosti stabala kao i od toga da li su sitnoplodne ili krupnoplodne sorte.



Slika 54. Grafički prikaz promjene u veličini ploda i prinosu u zavisnosti od opterećenosti stabla sorte 'Gala', Kriva vrijednosti prinosa (označena zelenom bojom) ukazuje de je najveća vrijednost prinosa pri opterećenju od 8 do 9 plodova po cm^2 TCSA (Robinson *et al.*, 2013)

Na temelju ovih studija izrađena je tabela sa vrijednostima optimalnog broja plodova jabuke (vitko vreteno) za različite vrijednosti TSCA.

Tabela 18. Optimalan broj plodova po stablu ovisno o vrijednostima TSCA

Prečnik debla (mm)	Poprečni presjek debla - TSCA (cm ²)	Optimalni broj plodova / poprečnom presjeku debla (cm ²)						
		4	5	6	8	10	12	15
8	0,5	2	2	3	4	5	6	7
10	0,7	3	3	4	6	7	9	11
12	1,2	5	6	7	10	12	15	19
19	2,8	11	14	17	22	28	34	42
25	5	20	25	30	40	50	60	76
31	7	31	39	47	63	79	95	118
38	11	45	57	68	91	114	136	171
44	15	62	77	93	124	155	186	232
50	20	81	101	121	162	202	243	304
63	31	126	158	190	253	316	380	475
76	45	182	228	273	364	456	547	684
101	81	324	405	486	648	810	972	1216
Ciljani broj plodova			Stabla u rodu			Mlada stabla		
Standardne sorte			8-9			6-7		
Sitnoplodne sorte			8-10			6-8		
Krupnoplodne sorte			7-8			5-6		
Triploidne sorte			8-11			6-7		

Za očekivati je da će u narednom periodu vještačka inteligencija, u kombinaciji sa naprednim kamerama, omogućiti brzu procjenu optimalnog opterećenja stabala (u konačnici i ukupnog zasada). Navedena procjena može poslužiti kao osnova za određivanje intenziteta rezidbe kao i za procjenu intenziteta prorjeđivanja plodova.

Primjer sistema podrške proizvođačima u procesu prorjeđivanja plodova jabuke

Jedan od preduslova redovnog prinosa voćaka je adekvatan broj cvjetova po stablu, a samim tim i dovoljno formiranih generativnih pupoljaka u prethodnoj godini. To se može postići samo kada ne postoji pretjerano velik broj plodova po stablu. Fiziološko opadanje dovodi do redukcije broja plodova po stablu, ali je u najvećem broju slučajeva nedovoljno da garantuje plodove koji veličinom i kvalitetom zadovoljavaju potrebe tržišta (Bregoli *et al.*, 2007). Zbog toga je neophodno izvršiti vještačko regulisanje rodosti. Ono se postiže zimskom rezidbom, prorjeđivanjem pupoljaka, prorjeđivanjem cvjetova ili plodova, kao i sprečavanjem diferencijacije generativnih pupoljaka. Zimska rezidba se smatra prvim korakom u kontroli rodosti voćaka, ali kod nekih voćnih vrsta (jabuka, kruška, breskva) ona je nedovoljna za postizanje neophodnog kvaliteta ploda i redovne rodosti, tako da je prorjeđivanje plodova u cilju optimalnog opterećenja stabala plodovima neophodna pomotehnička mjera (Bregoli *et al.*, 2007).

Prorjeđivanje plodova može da se obavlja ručno ili upotrebom hemijskih preparata. Ručno prorjeđivanje se izvodi relativno sporo i predstavlja skupu mjeru zbog upotrebe velikog broja radnika. Ručno prorjeđivanje plodova koje se primjenjuje kasno (nakon janskog opadanja) može obezbijediti povećanje krupnoće plodova, ali ne i redukciju alternativne rodosti (Maas, 2006). Hemijski način prorjeđivanja je najefikasnija metoda, s obzirom da je najisplativija, relativno brza, može se obaviti

u najkritičnijem trenutku i ima najveći pozitivan efekat na diferenciranje generativnih pupoljaka (Greene i Costa, 2013).

Međutim, da bi se adekvatno obavilo hemijsko prorjeđivanje plodova, neophodno je razmotriti veliki broj faktora koji mogu imati uticaj na djelovanje preparata. Najznačajniji faktori koji djeluju na rezultat primjene bioregulatora kao sredstva za hemijsko prorjeđivanje su: vrsta, sorta, meteorološki uslovi (prije, tokom i nakon aplikacije), snaga rasta i opterećenost voćke, veličina plodova u momentu aplikacije preparata, metod aplikacije preparata (koncentracija, količina vode, korištenje okvašivača), kao i prisustvo protivgradne mreže (Dussi, 2011; Robinson i Lakso, 2004).

Zbog utica velikog broja faktora, a naročito klimatskih, smatra se da je prorjeđivanje plodova za većinu proizvođača najzahtjevnija i najstresnija pomotehnička mjera koja se primjenjuje u toku procesa proizvodnje. Za razliku od Evrope gdje ne postoji sistem podrške proizvođačima za ovu namjenu, u Sjedinjenim Američkim državama podrška proizvođačima ne izostaje i ona je na izrazito visokom nivou. U cilju ostvarivanja što boljih rezultata prorjeđivanja, od proizvođača se zahtijeva ispunjavanje određenih preduslova, kao što su:

- određivanje optimalnog broja plodova po cm^2 TCSA ili određivanje ciljanog broja plodova na osnovu željenog prinosa,
- prilagođavanje broja cvjetnih pupoljaka na osnovu optimalnog/ciljanog broja plodova,
- odrediti neophodan % zametanja na osnovu ukupnog broja cvasti/cvjetova na stablu kako bi se ostvario optimalni/ciljani prinos.

Dakle, prvi korak koji trebaju poduzeti proizvođači u cilju preciznog prorjeđivanja plodova ogleda se u određivanju optimalnog/ciljanog broja plodova po stablu. Optimalno opterećenje određuje se na osnovu broja plodova po cm^2 TCSA (viditi prethodno poglavlje).

U slučaju da proizvođači određuju ciljani broj plodova na osnovu ukupnog prinosa po jedinici površine, za proračun su neophodni slijedeći podaci: gustina sklopa (broj biljaka po jedinici površine), ciljani prinos i ciljana veličina ploda.

U nastavku je prikazan izgled proračuna na primjeru gdje je gustina sklopa 2857 stabala po hektaru (1 m x 3,5m), ciljani prinos iznosi 60 t/ha, a ciljana veličina ploda je 180 gr

$$\text{Broj plodova po hektaru} = 60.000 / 0,18 = 333.333 \text{ plodova/ha}$$

$$\text{Broj plodova po stablu} = 333.333 / 2857 = 116$$

Nakon određivanja optimalnog/ciljanog broja plodova po stablu, proizvođači bi trebali prilagoditi optimalan broj cvjetnih pupoljaka po stablu. Prema Robinson *et al.* (2013), optimalan broj cvjetnih pupoljaka po stablu treba biti za pola vrijednosti veći u odnosu na optimalni/ciljani broj plodova po stablu. U prethodno navedenom primjeru optimalan broj cvjetnih pupoljaka bi iznosio odnosno 174 (116 x 1,5).

Nakon navedenog, na osnovu broja cvasti i optimalnog/ciljanog broja plodova ,određuje se neophodan % zametnutih plodova kako bi se osvario optimalni/ciljani prinos. Poznavanje potrebnog procenta zametnutih plodova u svrhu postizanja očekivanog prinosa vrlo je važan podatak kod određivanja strategije prorjeđivanja plodova. Da bi se izračunao % zametanja, neophodno je utvrditi koliko u prosjeku jedna cvast sadrži cvjetova. Prosječan broj cvjetova u cvasti određuje se metodom brojanja na uzorku od 100 cvasti. Nakon utvđivanja prosječnog broja cvjetova u cvasti, određuje se potencijalni broj plodova po stablu. Potencijalni broj plodova po stablu računa se kao umnožak

ciljanog/optimalnog broja plodova po stablu i prosječnog broja cvjetova po stablu. Na primjer, prebrojavanjem 100 cvasti utvrđeno je da kod sorte Golden Delicious jedna cvast u prosjeku sadrži 5 cvjetova. Ukoliko se za primjer uzme da je 120 plodova ciljani broj plodova po stablu, onda je broj potencijalnih plodova po stablu 600 (120 x 5). Neophodan % zemetanja se određuje na osnovu formule:

$$\text{Neophodan \% zemetanja} = (\text{otimalni/ciljani broj plodova/potencijalni broj plodova}) \times 100$$

U prethodno navedenom slučaju neophodno je da se zametne 20% plodova kako bi se postigao optimalan/ciljani prinos, tj. prorjeđivanjem je potrebno ukloniti 80% potencijalnih plodova. Neophodni procenat zemetanja može se odrediti i na na stablima kod kojih se nije provela optimizacija broja cvjetnih pupoljaka. U tom slučaju potrebno je prebrojati broj cvasti po stablu i na osnovu ciljanog broja plodova određuje se % zemetanja.

S obzirom da aktivnost prebrojavanja cvasti/cvjetova iziskuje mnogo vremena, naročito kada se uzgaja više sorti u zasadu, određeni broj istraživača ispitivali su mogućnost upotrebe vještačke inteligencije u tu svrhu (Xia *et al.*, 2023; Lee *et al.*, 2022; Sun *et al.*, 2021; Tian *et al.*, 2020; Ma *et al.*, 2018; Dias *et al.*, 2018). Detekcija cvasti/cvjetova bazirana je na tehnici neuronskih mreža, a u radovima najviše su se koristili slijedeći algoritmi: konvolucijske neuronske mreže (CNN) + support vektor mehanizam – SMV model (Dias *et al.*, 2018), unaprijeđen mask R-CNN (Tian *et al.*, 2020), YOLOv5 (Lee *et al.*, 2022), MTYLOX (Xia *et al.*, 2023), ShuffleNetV2 (Ma *et al.*, 2018), CenterNet2, Retina Net, SDD itd.



Slika 55. Izgled uređaja za prikupljanje podataka (lijevo) i izgled snapshot video detekcije sa brojevima cvasti po stablu (desno) upotrebom YOLOv5 algoritma (Lee, 2022)

Upotrebom neuronskih mreža ostvaruje se preciznost procjene broja cvjetova na stablima jabuke od 86 % (Mu *et al.*, 2023; Bjattarai *et al.*, 2020). Detaljniji opis primjene konvolucijskih neuronskih mreža u svrhu detekcije objekata (cvjetova, plodova) dat je u narednom potpoglavlju „Procjena prinosa upotrebom vještačke inteligencije“.

Nakon obavljanja preduslovnih aktivnosti koje se odnose na određivanje početnog opterećenja i procjenu neophodnog zamlaganja plodova, neophodno je odrediti optimalni trenutak za hemijsko prorjeđivanje. Prorjeđivanje plodova može se izvršiti u relativno širokom vremenskom periodu, a on prvenstveno zavisi od tipa bioregulatora koji se koristi za tu namjeru i vremenskih uslova. Normalan okvir za uspješno prorjeđivanje smatra se od momenta cvjetanja pa sve dok centralni plodovi (eng. *king fruit*) u cvasti ne postignu promjer Ø16 mm (Steven i John, 2012), odnosno promjer Ø18 mm (Greene i Costa, 2013). Također, vremenske prilike, naročito temperatura, intenzitet svjetlosti i vlažnost zraka (Kolaric i Stopar, 2013) imaju ključnu ulogu u određivanju termina aplikacije.

Vremenske prilike u toku i nakon tretmana, utiču na reakciju voćke (Greene i Costa, 2013). Ukoliko vremenski uslovi nakon aplikacije preparata nisu odgovarajući, postoji velika mogućnost da u potpunosti izostane željena reakcija voćke tj. neće se desiti prorjeđivanje plodova ili može doći do prekomjernog opadanja plodova. Nizak nivo svjetlosti i povećana temperatura vazduha favorizuje redukciju nivoa ugljikohidrata u biljci, što u konačnici rezultira većim intenzitetom opadanja plodova (Fallahi i Greene, 2010). Zbog variranja u efikasnosti sredstava za prorjeđivanje između godina, kao i tokom godine, veoma je teško precizno odrediti optimalnu dozu i trenutak aplikacije.

U tu svrhu može se koristiti „*Apple Carbohydrate Thinning Model*“. Alen Lasko sa Cornell Univerziteta razvio je pojednostavljen matematički model koji automatski procjenjuje fotosintetsku aktivnost stabla jabuke, disanje i rast plodova, listova, korijena i drvenih struktura (Lasko *et al.*, 2006; 2007). Model koristi prognozne podatke o dnevnim maksimalnim i minimalnim temperaturama i vrijednosti predviđene insolacije, na osnovu kojih kalkuliše jedinice porasta (eng. *growing degree days*), te proizvodnju i potrošnju ugljikohidrata tj. procjenjuje balans ugljikohidrata za naredna 4-7 dana. Poznavanje balansa ugljikohidrata od velikog je značaja za proizvođače, jer se optimalna koncentracija preparata za prorjeđivanje prilagođava procijenjenom balansu.

Tabela 19. Prilagođavanje koncentracije preparata na osnovu četverodnevnog balansa ugljikohidrata prema „*Apple Carbohydrate Thinning Model*“


Balans ugljikohidrata za naredna 4 dana	Preporuke proizvođačima
+20 do +40 g dan ⁻¹	Povećati koncentraciju preparata za prorjeđivanja za 30%
+20 do 0 g dan ⁻¹	Povećati koncentraciju preparata za prorjeđivanja za 15%
0 do -20 g dan ⁻¹	Primjeniti standardnu koncentraciju preparata za prorjeđivanje
-20 do -40 g dan ⁻¹	Smanjiti koncentraciju preparata za prorjeđivanja za 10%
-40 do -60 g dan ⁻¹	Smanjiti koncentraciju preparata za prorjeđivanja za 20%
-60 do -80 g dan ⁻¹	Smanjiti koncentraciju preparata za prorjeđivanja za 30%
< -80 g dan ⁻¹	Ne primjenjivati prorjeđivanje plodova

Model je trenutno dostupan na NEWA (*Network for Environment and Weather Applications*) platformi. Da bi proizvođači pristupili podacima „*Apple Carbohydrate Thinning Model*“ moraju unijeti datum početka fenofaza „mišije uši“ i cvjetanja, te odabrati najbližu meteorološku stanicu sa koje će model prikupljati podatke (temperatura i insolacija).

Za hemijsko prorjeđivanje plodova mogu se koristiti različite vrste hemikalija: đubriva, sredstva za zaštitu bilja, herbicidi i bioregulatori (Bound, 2010), koji pokazuju efikasnost ako se primijene u cvjetanju ili neposredno nakon zemetanja plodova. Najviše su u upotrebi sredstva koja spadaju u jedinjenja pod nazivom bioregulatori. Biljni bioregulatori su fitohormoni (prirodni biljni hormoni) ili fitohormonima slične supstance (sintetski spojevi) koje u vrlo niskim koncentracijama podstiču, inhibiraju ili utiču na biološke ili biohemijske procese u biljkama. Od bioregulatora, za prorjeđivanje plodova najviše se koriste preparati sa aktivnim materijama iz grupe auksina (naftilsirćetna kiselina-NAA, amid aftilsirćetne kiseline-NAD) i citokinina (benziladenin-BA). Pored bioregulatora za prorjeđivanje plodova često se koriste selektivni herbicid Mamitron i insekticid Karbaril.

Period nakon izvršenog prorjeđivanja plodova može biti izuzetno stresan za proizvođače voća. Proizvođači u prosjeku tek nakon 10 dana mogu uočiti vidljive promjene na plodovima koji će otpasti. U slučaju da je izostala reakcija voćke, prorjeđivanje se treba ponoviti. Međutim, zbog dugog perioda evaluacije u nekim slučajevima plodovi mogu premašiti veličinu unutar koje bioregulatori mogu imati djelovanje na prorjeđivanje (većina bioregulatora se primjenjuje do 16 mm). Da bi se prevazišao ovaj problem razvijen je „Predicting Fruitset Model“. Model je razvijen od strane Duene Greene, a u Excel format pretvoren je od strane Philip Schwallier (dokument je dostupan na stranici <https://ag.umass.edu/fruit/fact-sheets/hrt-recipe-predicting-fruit-set-using-fruitlet-growth-rate-model>). Da bi se model pokrenuo neophodno je izvršiti mjerenje prečnika plodova u dva intervala. Kao reprezentativan uzorak smatra se 5 stabala, a na svakom stablu mjeri se prečnik plodova sa 14 cvasti (ukupno 70 cvasti). Vrijednosti prečnika plodova unose se u program (nije potrebno obilježavanje plodova unutar cvasti) gdje se automatski preračunava intenzitet rasta. Model će izračunati efekat prorjeđivanja na osnovu hipoteze: plod je predodređen da otpadne ukoliko je intenzitet rasta ploda manji za 50% u odnosu na intenzitet „brzorastućih“ plodova.

Od 2019. godine „Apple Carbohydrate Thinning Model“ i „Predicting Fruitset Model“ integrisani su u mobilnu aplikaciju MaluSim (*Malus Simulation*).



Slika 56. Prikaz „Apple Carbohydrate Thinning Model“ i „Predicting Fruitset Model“ u MaluSim mobilnoj aplikaciji (izvor: <https://gorges.us/cases/malusim>)

Učinak prorjeđivanja se određuje na osnovu razlike u veličini plodova brzog intenziteta rasta, u odnosu na veličinu plodova sporog intenziteta rasta. Plodovi koji imaju intenzitet rasta manji za 50% ili više u odnosu na plodove brzog intenziteta rasta, predodređeni su za opadanje. Potrebno je dakle izvršiti dva mjerenja sa razmakom od 3-5 dana da bi se izvršila procjena. Prvo mjerenje bi se trebao izvršiti tri dana nakon tretmana ili ne prije faze kada su plodovi veličine 6 mm. Nakon drugog mjerenja model kalkuliše vrijednost porasta i predviđa procenat opadanja. Ukoliko postoje podaci o optimalnom broju cvasti i željenom broju plodova po stablu, onda se procenat opadanja može porediti sa vrijednostima neophodnog procenta zametnutih plodova. Ukoliko je neophodno dodatno smanjiti broj plodova kako bi se postigao optimalni/ciljani prinos, pristupa se dodatnom tretmanu prorjeđivanja.

Procjena prinosa upotrebom vještačke inteligencije

Tačno predviđanje prinosa prije berbe ima značajnu ulogu kod preciznog upravljanja voćnjacima. Tačnim predviđanjem prinosa uzgajivači mogu na vrijeme kvantitativno odgovoriti na fiziološke potrebe svakog stabla (rezidba, navodnjavanje, ishrana itd.), te izvršiti pripreme koje se odnose na organizaciju berbe i skladištenje plodova (radna snaga, boks palete, ambalaža, pakovanje, logistika, skladišni kapaciteti i sl.). Dosadašnja praksa procjene prinosa bazirala se na odabiru reprezentativih stabala, zatim ručnom prebrojavanju plodova, te se na osnovu predviđene prosječne mase plodova i ukupnog broja stabala u zasadu. Navedena predviđanja su neprecizna, zahtijevaju stručnu osobu koja će izvršiti observaciju i neophodno je puno vremena da se izvrši procjena. Kako bi se prevazišli navedeni problemi, u posljednje vrijeme, naučnici rade na kreiranju pametnih sistema za procjenu prinosa voćki zasnovanim na umjetnoj inteligenciji.

Procjena prinosa ML tehnikom

S obzirom da ML mijenja napor koji trebala uložiti „ljudska inteligencija“, ova tehnika je sve značajnija u svijetu informacionih tehnologija. U preciznoj poljoprivredi (eng. *Precision agriculture* – *PA*), ML je jedna od najrasprostanjenijih tehnika koja se koristi za donošenje odluka vezanih za procjenu prinosa, upravljanje zemljištem, upravljanje bolestima, itd. U posljednjih 10 godina, urađena su mnoga istaživanja o upotrebi ML tehnike za procjenu prinosa voćaka. Na osnovu rezultata rada Trentin *et al.* (2024) najveći broj istraživanja provedeno je na stablima jabuka (22,4%) i citrusa (13,8%). Studije sa limitiranim brojem podataka za učenje koriste jednostavnije modele kao što su linearna regresija, dok one sa većim brojem podataka koriste složenije modele kao što su ansambl metode, DL i hiperparametrijsko podešavanje.

Od ML algoritama za procjenu prinosa voćaka dominantno se koristi *Random Forest* (RF). RF spada u ansambl metodu ML. RF je samo jedan od mnogobrojnih algoritama mašinskog učenja, pokazao se kao fleksibilan i jednostavan za korišćenje kod velikog broja problema. Šuma koju algoritam gradi, je skup stabla odlučivanja, koja se obučava metodom pakovanja. Kombinacijom modela učenja (klasifikatora) povećava se ukupan rezultat. *Random Forest* ili *Random Decision Forest Algorithm* je namijenjen za rješavanje problema klasifikacije i regresije, koji funkcionišu tako, što se formira mnoštvo stabala odluka u periodu učenja (treninga).


Preciznost procjene prinosa voćaka upotrebom ML tehnike varira od 50 do 99% (Trentin, 2024). ML tehnikama se postižu relativno dobri rezultati kada je detekcija plodova u pitanju. Međutim,

kod procjena prinosa na većim površinama rezultati su relativno loši. Zbog Mslabe sposobnosti generalizacije, tehnike se teško uklapaju u model (Zhao *et al.*, 2016). Efikasnost primjene ML u svrhu procjene prinosa zavisi i od strategije prikupljanja podataka. Integracijom različitih podataka, kao što su meteorološki, te podaci o tlu i biljakama, poboljšavaju pouzdanost i primjenu modela.

Procjena prinosa DL tehnikom

DL su hijerarhijske arhitekture mašinskog učenja koje spajaju mnogo višeslojnih neuronskih mreža. DL je naprednija tehnika od ML jer se zasniva na algoritmima koji su u stanju da automatski uče karakteristike iz sirovih podataka (npr. slike), bez prethodno definisanih pravila. U tehnikama ML, prije obuke (treninga), neophodno je izvojiti karakteristike iz sirovih podataka, što može biti zamoran i dugotrajan proces (Kamilaris i Prenafeta-Boldu, 2018). Postoje različite arhitekture DL, a izbor određene arhitekture ovisi od namjene. Konvolucijske neuronske mreže (CNN) su specijalizirani tip arhitekture koji se koristi za preprocesiranje nestrukturiranih podataka, posebno vezanih za slike (Džomba, 2018). Osnovni elementi konvolucijske neuronske mreže su:

- ulazni sloj,
- konvolucijski sloj,
- aktivacijska funkcija je uglavnom ReLU,
- sloj sažimanja djeluje,
- potpuno povezani slojevi.



Slika 57. Arhitektura konvolucione neuronske mreže

(izvor: <https://nafizshahriar.medium.com/what-is-convolutional-neural-network-cnn-deep-learning-b3921bdd82d5>)

Ulazni sloj predstavlja ulaznu sliku i čuva vrijednost piksela. Konvolucijski sloj uzima sliku iz prethodnog sloja te ju konvoluiru s određenim brojem filtera, kako bi kreirao izlaznu sliku zvanu mapa karakteristika (značajki). Nakon izvršavanje konvolucije, provodi se aktivacijska funkcija. To je uglavnom ReLu (eng. *Rectified Linear Unit*) funkcija. Njena uloga je dodavanje nelinearnosti


u skrivene slojeve mreže. Također, ReLU funkcija djeluje pozitivno na uklanjanje zasićenosti gradijenta za pozitivne ulazne vrijednosti. Dimenzija izlaznog volumena nakon primjene ReLU funkcije se ne mijenja. Kako bi se smanjila složenost računanja, vrši se sažimanje slojeva. Sloj sažimanja djeluje na 2D aktivacijske mape tako da ih sažima, te one poprimaju manju visinu i širinu, no dubina aktivacijske mape ostaje očuvana. Na kraju, najmanje jedan potpuno povezan (spojen) sloj se koristi za obezbjeđivanje guste mape karakteristika. Potpuno povezani slojevi sadrže neurone kao i klasična neuronska mreža. Svaki neuron povezan je sa svim neuronima iz prethodnog sloja. Na izlazu neuronske mreže najčešće se upotrebljava *softmax* sloj koji ima ulogu klasifikatora. U protekloj deceniji razvijene su različite CNN arhitekture, a najpoznatije su: AlexNet (Krizhevsky *et al.*, 2012), ZFNet (Zeiler i Fergus, 2014), Visual Geometry Group16 (VGG16), VGG19 (Simonyan i Zisserman, 2015), ResNet (He *et al.*, 2015), GoogLeNet (Szegedy *et al.*, 2015), DenseNet (Huang *et al.*, 2016) i SqueezeNet (Iandola *et al.*, 2016). Svaka arhitektura se razlikuje u smislu broja konvolucijskih slojeva, funkcija nelinearnosti, vrste operacije udruživanja koja se koristi, itd.

Pored detekcije plodova, u posljednjih nekoliko godina CNN je našao primjenu i u drugim sektorima poljoprivrede kao što su detekcija bolesti i insekata, te u predikciji sadržaja organske materije u tlu (Xu *et al.*, 2019). Torres *et al.* (2020), na osnovu pregleda različitih CNN arhitektura za detekciju, klasifikaciju, sortiranje i kvalitet voća (AlexNet, VGG16 i GoogLeNet) zaključuje da je potrebno povećati broj filera i slojeva ukoliko se želi unaprijediti izdvajanje karakteristika, naročito u slučajevima kada je zadatak kompleksan. Wang i Chen (2020) predlažu metod za kategorizaciju plodova upotrebom dubokog CNN. Njihova se arhitektura saastoji od 8 slojeva CNN i ostvaruje preciznost od 95,49%. Važno je naglasiti da usješnost DL arhitekture zavisi od količine podataka za obuku, tj. što je količina podataka za obuku veća, time se pouzdanost arhitekture poboljšava. S obzirom da dodatno prikupljanje i označavanje slika za obuku može biti zamoran posao, Rahmemonfar i Sheppard (2017) predlažu simuliranu metodu učenja, u kojoj se za obuku koriste sintetičke slike, a testiranje je rađeno na podacima u realnom vremenu. Autori su koristili modifikovani *ResNet-Inception* model za obuku sintetičkih slika, a rezultati su prikazali tačnost obuke od 93% i testiranja od 91%.

Iako je na osnovu radova (Wang *et al.*, 2013; Bargoti and Underwood, 2017; Rahmemonfar and Sheppard, 2017; Sun *et al.*, 2018; Torres *et al.*, 2020) moguće kontatovati da se upotrebom DL tehnike postižu dobri rezultati u svrhu detekcije plodova, ova tehnika ipak ima ograničenja sa aspekta niže prostorne rezolucije praćene operacijom sažimanja, što u konačnici rezultira lošom lokalizacijom objekata prisutnih u određenom kadru. Dakle, da bi se poboljšala predikcija prinosa, neophodno je unaprijediti određivanje tačnih položaja (lokacije) plodova. U tu svrhu danas se široko primjenjuje arhitektura semantičke segmentacije zasnovane na DL (Tu *et al.*, 2018).


Pametna procjene prinosa voćaka

Da bi se razvio pametan sistem procjene prinosa voćnjaka neophodno je ispuniti nekoliko preduslova, kao što su: uzorkovanje stabala, prikupljanje podataka upotrebom različitih tehnologija, augmentacija podataka, detekcija plodova, procjena broja plodova i prinosa na osnovu DL arhitekture semantičke segmentacije i evaluacija performanse (Maheswari *et al.*, 2021).



Slika 58. Šematski prikaz dizajna pametnog sistema procjene prinosa

Uzorkovanje stabala: Prvi korak u procjeni prinosa podrazumijeva određivanja broja reprezentativnog uzorka (stabala). Veličina obabranog uzorka mora biti zadovoljavajuća, jer u konačnici ona predstavlja cijelu populaciju voćnjaka. Na osnovu istraživanja, za uzorkovanje se koriste dva pristupa, i to pristup na osnovu dizajna i na bazi modela (slika 59).



Slika 59. Vizualno poređenje pristupa uzorkovanja na osnovu dizajna i na osnovu modela. Gornji red prikazuje uzorkovanja na osnovu dizajna. Jedna fiksna populacija sa 9 jedinki unutar populacije i tri slučajna uzorka sa 4 lokacije (zaokružene tačke prikazuju uzorke). Vrijednost odgovora na svakoj lokaciji je fiksna. Donji red predstavlja pristup uzorkovanja na osnovu modela. Tri realizacije istog procesa generiranja podataka uzorkovane na 4 iste lokacije. Vrijednost odgovora na svakoj lokaciji je nasumičan (Dumelle, 2022).

Različite procedure uzorkovanja za pristupe na bazi dizajna i modela uključuju jednostavno nasumično uzorkovanje, sistemsko uzorkovanje, uzorkovanje s vjerovatnošću proporcionalnom veličini, stratifikovano uzorkovanje, itd. (Wulfsohn *et al.*, 2010). U komparativnoj studiji Uribeetxebarria *et al.* (2018), upoređivana je efikasnost uzorkovanja (jednostavnog slučajnog uzorka i stratifikovanog) na procjenu prinosa voćaka. Za stratifikovano uzorkovanje autori su koristili kao kriterijum parametre normalizirana razlika vegetacionog indeksa (eng. *Normalized Difference Vegetation Index* – NDVI) i prividnu električnu provodljivost (*Electrical Conductivity* – ECa). Kao rezultat dobijeno je smanjenje veličine uzorkovanog plota za 17% u poređenju sa slučajnim načinom uzorkovanja, što je poboljšalo preciznost procjene prinosa.

Prikupljanje podataka različitim tehnologijama: Primarni sistem za detekciju plodova je senzorski sistem. Trebalo bi da uhvati fokusirane slike u terenskim uslovima rješavajući izazovne situacije kao što su promjenljivi uslovi osvjetljenja i rezolucija. Slika prikazuje različite modele kamera koji su trenutno dostupni na tržištu sa različitim karakteristikama (tj. crno-bijele, RGB, termalne, itd.) (slika 60).



Crno-bijela kamera (Leica Q3)

<https://leica-camera.com/en-GB/photography/cameras/q/q3-43-black/shop-now>



Hiperspektralna kamera (SPECIM GX17)

<https://www.specim.com/hyperspectral-cameras/>



RGB kamera (Sony A6100)

<https://www.3dtarget.it/eu/en/uav/uav-products/camere-rgb/sony-a6100-detail.html>



Termalna kamera (Hikmicro SP 60)

<https://www.pass-thermal.co.uk/hikmicro-sp60-ultra-high-resolution-thermal-camera-choice-of-lens>



Multispektralna kamera (AGx710)


<https://sentera.shop/products/double-4k-skyport>

Slika 60. Različiti modeli kamera za prikupljanje slika

U ranijim istraživanjima za otkrivanje (detekciju) plodova korištene su crno-bijele kamere. Prepoznavanje plodova u krošnji vršeno je na osnovu karakteristika ploda. Nakon razvoja senzora u boji, RGB kamere su se uglavnom koristile u svim sistemima detekcije (za hvatanje boje), što je olakšalo proces detekcije. Komplementarni metal-oksid-poluprovodnici (CMOS) i uređaji sa naelektrisanjem (CCD) su preovlađujuće tehnologije koje se koriste kao senzori boja i široko se koriste u svim sistemima mašinskog vida. CCD senzori rade tako što istovremeno snimaju cijeli kadar, dok CMOS pravi sliku piksel po piksel. Termalno snimanje je također korišteno u nekim radovima za detekciju plodova voćka (Gongal *et al.*, 2015). Ovdje se osobina svakog objekta (tj. list, zelen plod, itd.) otkriva na osnovu temperature, jer plodovi ima višu temperaturu u odnosu na pozadinske objekte. Trenutno su u upotrebi spektralne kamere zadnje generacije (multispektralni i hiperspektralni senzori). Navedeni tip kamere pruža informacije vezane za spektralne detalje (u svakom prostoru boja) zajedno sa karakteristikama boja. Čak i ako je boja ploda isti, detekcija ploda se može izvesti pomoću spektralnih informacija (Feng *et al.*, 2019).


Feng *et al.* (2019) su predložili metodu za detekciju jabuka pomoću multispektralne dinamičke slike. Slike su snimljene na veoma visokom nivou kontrasta između pozadine i plodova, čime se preciznost prepoznavanja povećala za 92%. Okamoto i Lee (2009) su razvili metodu za identifikaciju zelenog citrusa pomoću hiperspektralnog snimanja. Autori su koristili spektralnu talasnu dužinu od 369–1042 nm za snimanje slika, a tačnost detekcije se kretala od 70–85%.

Augmentacija (povećanje broja) podataka je korisna tehnika u sistemima zasnovanim na neuronskim mrežama, s obzirom da je za DL potrebna velika količina podataka. Kada se radi sa malim skupom podataka, sistem ne daje tačne rezultate u fazi testiranja. Kako bi se povećao raspoloživi skup podataka, kroz proces augmentacije vrše se razne forme transformacije (rotacija, dodavanje šuma, rezanje i sl.), što u konačnici poboljšava sposobnost mreže za duboko učenje karakteristika prisutnih u podacima (Zheng *et al.*, 2020).



Slika 61. Primjeri načina augmentacije podataka: a) rezanje, zaokretanje i mijenjanje saturacije; b) mijenjanje posvjetljenja i kontrasta; c) rezanje i zaokretanje; d) rezanje i mijenjanje saturacije; e) zaokretanje

Semantička segmenetacija u kombinaciji sa DL arhitekturom postiže najbolje rezultate predikcije, naročito u domenu procjene prinosa. Osnovni cilj istraživača je da na osnovu ove kombinacije (semantička segmentacija i DL) ostvare savršeno brojanje plodova, što određuje preciznost procjene prinosa određenog voćnjaka, naročito u izazovnim situacijama gdje su zastupljena preklapanja, varijacije u osvjetljenju i skriveni objekti (Guo *et al.*, 2019). U osnovi, plodovi se detektuju na osnovu snimljenih fotografskih podataka koje se transformiraju u mnogo detaljniji prostor koji naglašava svaki piksel prikazan na fotografiji. DL na bazi arhitekture semantičke segmentacija podijeljen je u tri grupe: predikcija na osnovu CNN i piksela, potpuna konvolucijska predikcija i regionalna predikcija. Prva grupa kao input dobiva podatke u obliku fotografskih isječaka (*eng. image patch*) i svaki piksel klasifikuje u određenu grupu na osnovu vektorskih rezultata. Druga grupa obrađuje cijelu fotografiju, a predikcija se vrši na osnovu bodovnih mapa. U trećoj grupi, regioni se izdvajaju iz ulazne fotografije i koriste se kao input za arhitekturu. Na osnovu vektorskih rezultata svaka regija se označava kao „plod“ ili „nije plod“ regija. Zatim se vrši naknadna obrada segmentiranih piksela, tj. susjedni pikseli se grupiraju na osnovu čega se ukazuje čitav plod prisutan na određenoj fotografiji.



Slika 62. Prikaz shema različitih tehnologija dubokog učenja zasnovanih na semantičkoj segmentaciji za detekciju i označavanje plodova (Maheswari, 2021)

Evaluacija performanse segmentacije vrši se upoređivanjem rezultata na terenu, a najčešće se izražava se koeficijentom determinacije (R^2), F1 učinkom, recall i piksel preciznošću. Efektivnost ovih mjerenja zavisi od broja piksela klasifikovanih kao tačno pozitivni, tačno negativni, lažno pozitivni i lažno negativni (Yu *et al.*, 2018).


Praćenje rasta ploda

Praćenje i mjerenje dimenzija plodova predstavlja uobičajnu aktivnost i nakon perioda prorjeđivanja, s obzirom da je upravo veličina ploda jedan od osnovnih tržišnih standarda kvaliteta. Mjerenje rasta ploda na dnevnoj osnovi i prećenje krivulje rasta plodova omogućeno je razvojem digitalnih dendrometara. Postoji više kompanija koje se bave izradom dendrometara za mjerenje dimenzija ploda, a osnovna razlika se ogleda u rješenjima vizualizacije i obrade podataka. Dendrometri za mjerenje dimenzije plodova prave se u različitim veličinama (postoje varijacije u intervalu mjerenja zavisno od proizvođača), ovisno od krupnoće plodova. Za plodove voćnih vrsta koje imaju sitne plodove primjenjuju se dendrometri čiji interval mjerenja iznosi od 7 do 45 mm, za srednje krupne plodove od 15 do 90 mm, dok se za krupne plodove koriste dendrometri sa intervalom mjerenja od 30 do 160 mm.




Slika 63. Izgled različitih tipova dendrometra za mjerenje promjera ploda (izvori: <https://www.phytech.com/post/the-art-of-controlling-fruit-size> i <https://ecomatik.de/en/products/growth-and-plant-water-status-dendrometer/fruit-df/>)

Određene kompanije koje se bave prodajom dendrometara, pružaju usluge izrade očekivane krivulje rasta na osnovu podataka kao što su: sorta, ciljane veličine ploda i očekivani datum berbe. Krivulja se modifikuje spram meteorološkim prognoznim modelima. Pored krivulje kreirane na osnovu predikcijskog modeliranja, u aplikaciji se prikazuje i krivulja dendrometrom izmjerih vrijednosti dimenzije ploda. Na osnovu navedene dvije krivulje pojednostavljeno je donošenje agrotehničkih odluka u smislu navodnjavanja i ishrane voćaka, posebno ukoliko se proizvodnja zasniva na više proizvodnih tabli (plotova).



Slika 64. Izgled predviđene krivulje rasta plodova i krivulja rasta kreirana upotrebom dendrometra (izvor: <https://www.phytech.com/post/unlock-the-power-of-fruit-maps-view-your-fruit-data-in-specific-plots-filtered-by-variety>)

Pored navedene metode, rast ploda može se pratiti i na osnovu vještačke inteligencije (mašinsko učenje). Neke kompanije koje proizvode kamere za praćenje fenofaza razvile su i pametan sistem praćenja rasta plodova jabuke.



Slika 65. Izgled fotografije sa prikazanim vrijednostima dimenzije plodova
(izvor: <https://metos.global/en/cropview/>)

LITERATURA:

- 1) Bargoti, S., Underwood, J. P. (2017). Image segmentation for fruit detection and yield estimation in apple orchards. *J. Field Rob.* 34, 1039–1060. doi: 10.1002/rob.21699
- 2) Bhattarai, U., Bhusal, S., Majeed, Y., & Karkee, M. (2020). Automatic blossom detection in apple trees using deep learning. *IFAC-PapersOnLine*, 53(2), 15810-15815.
- 3) Bound, S. (2010). Alternate Thinning Chemicals for Apples. *Acta horticulturae journal*, 884, 229-236
- 4) Bregoli, A. M., Fabbioni, C., Raimondi, V., Brunner, P., & Costa, G. (2007). 6-BA and NAA effect on ‘Galaxy’ fruit growth, abscission and quality: a comparison between the Po Valley and the South Tyrol producing areas. *Erwerbs-Obstbau*, 49(3), 97-100.
- 5) Chandler, W. H. (1942). *Deciduous orchards*. Philadelphia, USA: Lea & Febiger, pp: 438.
- 6) Copeland, B.J. (2024). History of Artificial Intelligence (AI). <https://www.britannica.com/science/history-of-artificial-intelligence>
- 7) Dias, P. A., Tabb, A., & Medeiros, H. (2018). Apple flower detection using deep convolutional networks. *Computers in Industry*, 99, 17-28.
- 8) Dumelle, M., Higham, M., Ver Hoef, J.M., Olsen, A.R., Madsen, L. (2022). A comparison of design-based and model-based approaches for finite population spatial sampling and inference, *Methods in Ecology and Evolution*, Volume 13, Issue 9 p. 2018-2029. doi.org/10.1111/2041-210X.13919
- 9) Dussi, M.C. (2011). Sustainable use of plant bioregulators in pear production. *Acta Hortic.* 909, 353-367 doi: 10.17660/ActaHortic.2011.909.40
- 10) Džomba, K. (2018). Konvolucijske neuronske mreže (Diplomski rad). Zagreb: Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet. Preuzeto s <https://urn.nsk.hr/urn:nbn:hr:217:020017>
- 11) Fallahi, E., & Greene, D. W. (2009). The impact of blossom and postbloom thinners on fruit set and fruit quality in apples and stone fruits. In *XI International Symposium on Plant Bioregulators in Fruit Production* 884 (pp. 179-187).
- 12) Feng, J., Zeng, L., and He, L. (2019). Apple fruit recognition algorithm based on multi-spectral dynamic image analysis. *Sensors* 19:949. doi: 10.3390/s19040949
- 13) Fishman, S., Erez, A., Couvillon, G. A. (1987). The temperature dependence of dormancy breaking in plants computer simulation of processes studied under controlled temperatures. *J. Theor. Biol.* 126: 309-321.
- 14) Fu, L., Feng, Y., Majeed, Y., Zhang, X., Zhang, J., Karkee, M., *et al.* (2018). Kiwifruit detection in field images using faster R-CNN with ZFNet. *IFAC PapersOnLine* 51, 45–50. doi: 10.1016/j.ifacol.2018.08.059
- 15) Garvilova, Y. (2020). Artificial Intelligence vs. Machine Learning vs. Deep Learning: Essentials. <https://serokell.io/blog/ai-ml-dl-difference>
- 16) Gongal, A., Amatya, S., Karkee, M., Zhang, Q., and Lewis, K. (2015). Sensors and systems for fruit detection and localization: a review. *Comput. Electron. Agric.* 116, 8–19. doi: 10.1016/j.compag.2015.05.021

- 17) Greene, D., Costa, G. (2013). Fruit thinning in pome-and stone-fruit: State of the art. In EUFRIN Thinning Working Group Symposia; Acta Horticulturae 998; International Society for Horticultural Science: Leuven, Belgium, pp. 93–102.
- 18) Guo, S., Jin, Q., Wang, H., Wang, X., Wang, Y., & Xiang, S. (2019). Learnable gated convolutional neural network for semantic segmentation in remote-sensing images. *Remote Sensing*, 11(16), 1922.
- 19) He, K., Zhang, X., Ren, S., and Sun, J. (2015). “Deep residual learning for image recognition,” in Proceedings of the Computer Vision and Pattern Recognition, Las Vegas.
- 20) Huang, G., Liu, Z., and Weinberger, K. Q. (2016). “Densely connected convolutional networks,” in Proceedings of the Computer Vision and Pattern Recognition, Honolulu.
- 21) Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., and Keutzer, K. (2016). “SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size,” in Proceedings of the Computer Vision and Pattern Recognition, Toulon.
- 22) Jose, K., Chaturvedi, R. K., Jeganathan, C., Behera, M. D., & Singh, C. P. (2023). Plugging the Gaps in the Global PhenoCam Monitoring of Forests—The Need for a PhenoCam Network across Indian Forests. *Remote Sensing*, 15(24), 5642. <https://doi.org/10.3390/rs15245642>
- 23) Kamilaris, A., Prenafeta-Boldú, F.X. (2018). Deep Learning in Agriculture: A Survey. *Computers and Electronics in Agriculture*, 147, 70-90. doi.org/10.1016/j.compag.2018.02.016
- 24) Kolaric, J., & Stopar, M. (2012). Role of ethylene related genes in apple (*Malus domestica* Borkh.) fruitlet abscission after plant growth regulator application or shading. In EUFRIN Thinning Working Group Symposia 998 (pp. 67-75).
- 25) Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). “ImageNet classification with deep convolutional neural networks,” in Proceedings of the 25th International Conference on Neural Information Processing Systems, NIPS’12, Vol. 1, (Red Hook, NY: Curran Associates Inc.), 1097–1105.
- 26) Lakso, A.N., Robinson, T.L. and Greene, D.W. (2006). Integration of environment, physiology, and fruit abscission via carbon balance modeling – Implications for understanding growth regulator response. *Acta Hort.* 727:321-326.
- 27) Lakso, A.N., Robinson, T.L. and Greene, D.W. (2007). Using an apple tree carbohydrate model to understand thinning responses to weather and chemical thinners. *NY Fruit Quarterly* 15(3):17-20.
- 28) Lee, J., Gadsden, S. A., Biglarbegian, M., & Cline, J. A. (2022). Smart agriculture: A fruit flower cluster detection strategy in apple orchards using machine vision and learning. *Applied Sciences*, 12(22), 11420.
- 29) Lučić, P., Đurić, G., Mičić, N. (1996). Voćarstvo I: biologija voćaka, rasadnička proizvodnja, pomotehnika, podizanje i održavanje voćnjaka. Institut za istraživanje u poljoprivredi Srbije. Nolit-Pantenon, Beograd
- 30) Ma, N., Zhang, X., Zheng, H., & Sun, J. (2018). ShuffleNet V2: Practical Guidelines for Efficient CNN Architecture Design. ArXiv, abs/1807.11164.
- 31) Maheswari, P., Raja. P., Apolo, O., E., and Pérez-Ruiz, M. (2021). Intelligent Fruit Yield Estimation for Orchards Using Deep Learning Based Semantic Segmentation Techniques—A Review. *Front. Plant Sci.* 12:684328.

- 32) Moriondo, M., Bindi, M. (2027). Impact of climate change on phenology of typical Mediterranean crops. *Italian Journal of Agrometeorology* 5 – 12 (3)
- 33) Mu, X., He, L., Heinemann, P., Schupp, J., Karkee, M. (2023). Mask R-CNN based apple flower detection and king flower identification for precision pollination, *Smart Agricultural Technology*, Volume 4, 100151, ISSN 2772-3755, <https://doi.org/10.1016/j.atech.2022.100151>.
- 34) Nieto, G.L., Wallis, A., Clements, J., Miranda Sazo, M., Kahlke, C., Kon, T.M., Robinson, T.L. (2023). Evaluation of Computer Vision Systems and Applications to Estimate Trunk Cross-Sectional Area, Flower Cluster Number, Thinning Efficacy and Yield of Apple. *Horticulturae*, 9, 880.
- 35) Okamoto, H., Lee, W.S. (2009). Green citrus detection using hyperspectral imaging, *Computers and Electronics in Agriculture*, Volume 66, Issue 2, 201-208, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2009.02.004>.
- 36) Popescu, D., Ichim, L., Stoican, F. (2023). Orchard monitoring based on unmanned aerial vehicles and image processing by artificial neural networks: a systematic review. *Front. Plant Sci.* 14:1237695. doi: 10.3389/fpls.2023.1237695
- 37) Rahnemounfar, M., and Sheppard, C. (2017). Deep count: fruit counting based on deep simulated learning. *Sensors* 17:905. doi: 10.3390/s17040905
- 38) Richardson, A.D., Jenkins, J.P., Braswell, B.H. et al. (2007). Use of digital webcam images to track spring green-up in a deciduous broadleaf forest. *Oecologia* 152, 323–334. <https://doi.org/10.1007/s00442-006-0657-z>
- 39) Richardson, A. D., Braswell, B. H., Hollinger, D. Y., Jenkins, J. P., and Ollinger, S. V. (2009). Near-surface remote sensing of spatial and temporal variation in canopy phenology. *Ecol. Appl.* 19, 1417–1428. doi: 10.1890/08-2022.1
- 40) Richardson, A. D., Keenan, T. F., Migliavacca, M., Ryu, Y., Sonnentag, O., and Toomey, M. (2013). Climate change, phenology, and phenological control of vegetation feedbacks to the climate system. *Agric. Forest Meteorol.* 169, 156–173. doi: 10.1016/j.agrformet.2012.09.01
- 41) Richardson, E. A., Seeley, S. D. and Walker, D. R. (1974). A model for estimating the completion of rest for Redhaven and Elberta peach trees. *HortScience* 9: 331–332.
- 42) Robinson, T., Lakso, A., Greene, D., Hoying, S. (2013). Precision crop load management. *N. Y. Fruit Q.* 21, 445–468.
- 43) Robinson, T. L., Lakso, A. N. (2004). Variations between years and within years on chemical fruit thinning efficacy of apple during cool springs. *Acta Horticulture*, 636(636), 283–294.
- 44) Sansavini, S., Costa, G., Gucci, R., Inglese, P., Ramina, A., Xiolyannis, C. (2012). *Arboricoltura Generale*, Ed. Pàtron (Bologna), pp. 532.
- 45) Shajahan, S., Cannayen, I., Hendrickson, J. (2016). Monitoring plant phenology using phenocam: A review. In *2016 ASABE Annual International Meeting* (p. 1).
- 46) Simonyan, K., and Zisserman, A. (2015). “Very deep convolutional networks for large-scale image recognition,” in *Proceedings of the Computer Vision and Pattern Recognition*, San Diego.

- 47) Sun, J., He, X., Ge, X., Wu, X., Shen, J., and Song, Y. (2018). Detection of key organs in tomato based on deep migration learning in a complex background. *Agriculture* 8:196. doi: 10.3390/agriculture8120196
- 48) Sun, K., Wang, X., Liu, S., & Liu, C. (2021). Apple, peach, and pear flower detection using semantic segmentation network and shape constraint level set. *Computers and Electronics in Agriculture*, 185, 106150.
- 49) Szegedy, C., Liu, W., Jia, Y., Sermanet, P., and Reed, S. (2015). “Going deeper with convolutions,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (Boston, MA), 1–9. doi: 10.1109/CVPR.2015.7298594
- 50) Tian, Y., Yang, G., Wang, Z., Li, E., & Liang, Z. (2020). Instance segmentation of apple flowers using the improved mask R–CNN model. *Biosystems engineering*, 193, 264–278.
- 51) Thapa, S., Garcia Millan, V. E., & Eklundh, L. (2021). Assessing Forest Phenology: A Multi-Scale Comparison of Near-Surface (UAV, Spectral Reflectance Sensor, PhenoCam) and Satellite (MODIS, Sentinel-2) Remote Sensing. *Remote Sensing*, 13(8), 1597. <https://doi.org/10.3390/rs13081597>
- 52) Torres, J. N., Mora, M., Garcia, R. H., Barrientos, R. J., Fredes, C., and Valenzuela, A. (2020). A review of convolutional neural network applied to fruit image processing. *Appl. Sci.* 10:3443. doi: 10.3390/app10103443
- 53) Trentin, C., Ampatzidis Y., Lacerda C., Shiratsuchi L. (2024). Tree crop yield estimation and prediction using remote sensing and machine learning: A systematic review. *Smart Agricultural Technology*, volume 9, str. 100556. 10.1016/j.atech.2024.100556
- 54) Tu, S., Xue, Y., Zheng, C., Qi, Y., Wan, H., and Mao, L. (2018). Detection of passion fruits and maturity classification using red-green-blue depth images. *Biosyst. Eng.* 175, 156–167. doi: 10.1016/j.biosystemseng.2018.09.004
- 55) Uribeetxebarria, A., Martinez-Casasnovas, J. A., Escola, A., Rosell-Polo, J. R., and Arno, J. (2018). Stratified sampling in fruit orchards using cluster-based ancillary information maps: a comparative analysis to improve yield and quality estimates. *Precis. Agric.* 20, 179–192. doi: 10.1007/s11119-018-9619-9
- 56) Wang, Q., Nuske, S., Bergerman, M., and Singh, S. (2013). Automated crop yield estimation for apple orchards. *Exp. Rob.* 80, 745–748. doi: 10.1007/978-3-319-00065-7_
- 57) Wang, S. H., and Chen, Y. (2020). Fruit category classification via an eight-layer convolutional neural network with parametric rectified linear unit and dropout technique. *Multimed. Tools Appl.* 79, 15117–15133. doi: 10.1007/s11042-018-6661-6
- 58) Wignate, L., Cremonese, E., Migliavacca, M., Brown, T., D’Odorico, P., Peichl, M., Gielen, B., Hortnagl, L. (2015). Protocol – Phenocamera: automated phenology monitoring. Ecosystem Thematic Centre ICOS https://european-webcam-network.net/data/ICOS_Phenocamera_WG_Protocol_final.pdf
- 59) Wulfsohn, D., Sciortino, M., Aaslyng, J. M., and Garcia-Finana, M. (2010). Non-destructive, stereological estimation of canopy surface area. *Biometrics* 66, 159–168. doi: 10.1111/j.1541-0420.2009.01237.x

- 60) Wünsche, J.N., Ferguson, I.B. (2005). Crop load interaction in apple. *Horticultural reviews*, 231-290.
- 61) Xia, X., Chai, X., Li, Z., Zhang, N., Sun, T (2023). MTYOLOX: Multi-transformers-enabled YOLO for tree-level apple inflorescences detection and density mapping, *Computers and Electronics in Agriculture*, Volume 209, 107803, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2023.107803>
- 62) Xu, Z., Zhao, X., Guo, X., and Guo, J. (2019). Deep learning application for predicting soil organic matter content by VIS-NIR Spectroscopy. *Comput. Intell. Neurosci.* 2019:3563761. doi: 10.1155/2019/3563761
- 63) Yu, H., Yang, Z., Tan, L., Wang, Y., Sun, W., and Sun, M. (2018). Methods and datasets on semantic segmentation: a review. *Neurocomputing* 304, 82–103. doi: 10.1016/j.neucom.2018.03.037
- 64) Zeiler, M.D., Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. In European Conference on Computer Vision (ECCV). <https://cs.nyu.edu/~fergus/papers/zeilerECCV2014.pdf>
- 65) Zhang, K., Xu, G., Han, Z., Ma, K., Zheng, X., Chen, L., ... & Zhang, S. (2020). Data augmentation for motor imagery signal classification based on a hybrid neural network. *Sensors*, 20(16), 4485.
- 66) Zhao, K., Chu W. S., Zhang H. (2016). *Proceedings of the IEEE Conference on Computer Vision and Pattern (CVPR), pp. 3391-3399

PRIMJENA PAMETNIH SISTEMA U RATARSTVU

Teofil Gavrić, Mirha Đikić

Ratarske kulture su osnova prehrane ljudi i stoke, a također su sirovina za prehrambenu i laku industriju. Ove kulture zauzimaju najveći dio obradivih poljoprivrednih površina u svijetu. Samo žita zauzimaju 50% poljoprivrednih površina. U tabeli 20 su navedene površine vodećih ratarskih kultura u svijetu. U Bosni i Hercegovini kukuruz i pšenica također zauzimaju najveće obradive površine.

Tabela 20. Površine najvažnijih ratarskih kultura u svijetu (FAO, 2023)

Usjev	Površina, ha	Usjev	Površina, ha
Pšenica	219 153 830	Zob	9 508 645
Kukuruz	203 470 007	Šećerna repa	4 295 160
Riža	165 038 826	Raž	4 016 433
Soja	133 791 633	Tritikale	3 616 655
Ječam	47 147 005	Heljda	2 236 492
Pamuk	31 426 734	Suncokret	1 200 074
Sirak	40 762 472	Silažni kukuruz	1 105 213
Proso	29 855 214	Lan	256 540
Krompir	17 788 408	Kinoa	193 679

S druge strane, svjetska populacija raste. U posljednja dva desetljeća to povećanje iznosi 29%, s tim da je ruralno stanovništvo poraslo samo za 6%. Povećanje svjetske populacije vodi ka većoj potražnji za hranom, a to traži veća ulaganja u poljoprivredu. Osim toga, globalne klimatske promjene, kao i potreba za održivom poljoprivredom nameću ograničenja u proizvodnji dovoljnih količina kvalitetne hrane. Ovi izazovi potiču inovacije u poljoprivredi, gdje visoka tehnologija igra ključnu ulogu.

Biljna proizvodnja na otvorenom polju predstavlja rezultat složenih interakcija između biljke, zemljišta, klime i primijenjenih agrotehničkih mjera. Shodno navedenom, način donošenja odluka o primjeni neke mjere ključan je za održivost i produktivnost sistema. Preciznom poljoprivredom se nastoji proniknuti u zakonitosti djelovanja svih faktora koji posredno ili neposredno utiču na prinos na određenom lokalitetu. Tehnologijom precizne poljoprivrede se bolje objašnjavaju odnosi i porijeklo varijabilnosti u polju i daju se osnove za lokalno prilagodljiv koncept proizvodnje po principu: „broj pravilno donesenih odluka po jediničnoj površini u jedinici vremena dovodi do povećanja neto prihoda“ primjenom najsavremenije tehnologije i naučnih dostignuća. Precizna poljoprivreda se može opisati kraticom **4P**, tj. dati **Pravu stvar, na Pravo mjesto, u Pravo vrijeme i u Pravo količini**. Da bi sve biljke dale svoj maksimum u toku proizvodnog ciklusa, neophodno je obezbijediti optimum svih ključnih parametara, podjednako na svim dijelovima parcele (Kostić, 2021). Pravovremeno obavljanje poljoprivrednih radova uz visoku produktivnost, smanjen broj operacija, te minimalnu cijenu rada, karakteristike su precizne poljoprivrede. Sve to je moguće isključivo uz dostupnost velikoga broja informacija pri donošenju odluka.

Precizna poljoprivreda predstavlja tehnološki napredak koji omogućava poljoprivrednicima da efikasnije upravljaju svojim resursima, smanjujući pritom otpad i povećavajući produktivnost. Ovaj pristup koristi se za selektivnu obradu manjih površina unutar proizvodne parcele. Time se postiže veća preciznost u obradi zemljišta i brzi o biljnim kulturama. Korištenje informacijskih tehnologija, raznovrsnih senzora, satelitske navigacije i precizne analize uzoraka omogućuje detaljnije praćenje promjena na zemljištu i brzu reakciju na različite uvjete.

Ove tehnologije se mogu koristiti za sve poljoprivredne kulture, ali su posebno efikasne u ratarskoj i povrtlarskoj proizvodnji. Automatizacija procesa i pouzdana analiza uzoraka čine preciznu poljoprivredu sve popularnijom. Zahvaljujući mogućnosti praćenja rada u realnom vremenu, poljoprivrednici mogu donositi pravovremene odluke. To dovodi do veće sigurnosti u kvalitetu proizvoda i efikasnijeg korištenja resursa. Očekuje se da će se precizna poljoprivreda sve više usvajati širom svijeta, čime će se unaprijediti efikasnost i održivost poljoprivredne proizvodnje.


Sistemi za mjerenje otpora vuče

Mjerenje otpora vuče raonog pluga može biti potencijalno koristan alat za stalno mapiranje zemljišnih karakteristika kao što je zbijenost zemljišta, kao i za optimalno podešavanje rada pluga. Pravilno podešen plug je ključan preduslov za povećanje ekonomičnosti proizvodnje, odnosno smanjenje potrošnje energije tokom oranja. Prema različitim istraživanjima, oranje može činiti do 40% ukupnih energetske troškova u uzgoju usjeva (Khaliullin i sar., 2020). Mjerenje otpora vuče mašina za obradu zemljišta može se obavljati uz primjenu univerzalnih mjernih ramova, instrumentalizovanih priključnih mašina ili pomoću instrumentalizovanih traktora na svojim podiznim hidrauličnim polugama koji imaju postavljene davače sile (Mendušić i sar., 2017; Kostić, 2021). Svi nabrojani sistemi mjerenja otpora vuče imaju određene prednosti i nedostatke, te se općenito može reći da je mjerenje otpora najviše zastupljeno u naučnim istraživanjima.

Priprema tla u sistemu precizne poljoprivrede

Upravljanje radnim procesima obrade tla u poljoprivrednoj proizvodnji na prvi se pogled čini jednostavnim i većina ljudi misli da tu nije potrebna primjena sofisticiranih metoda rada. Međutim, ako se detaljno uđe u problematiku obrade tla i predstetvene pripreme, ili kako je još zovu dopunske obrade tla, tada se uočavaju pogreške koje rezultiraju neobrađenim trakama između dva prohoda stroja ili u preklapanju prohoda. Velikim strojevima radnog zahvata 6 m i više teško se upravlja bez pogrešaka. Tanjurače, gruberi, sjetvospremači i slični strojevi za pripremu tla u pravilu su širokog radnog zahvata i prilikom spajanja prohoda najčešći je slučaj da se dva prohoda preklapaju. Ovo preklapanje u pravilu iznosi 50-80 cm po danu, odnosno 60-100 cm noću. Zbog preklapanja se nepotrebno smanjuje učinak za 10-15%, a u istom odnosu se povećava trošak predstetvene pripreme tla. Drugi problem kod strojeva za predstetvenu pripremu tla jest slaba vidljivost između tretiranog i netretiranog tla u drugom prolazu, pa se vozač mora značajno naprezati i umarati kako bi bio siguran da kvalitetno spaja prohode. Ovaj problem je posebno izražen u noćnom radu. Primjenom preciznih GPS-a izravno se postiže ušteda 10-15% ukupnih troškova za predstetvenu pripremu tla. Dodatni efekti su još veći ako se radi noću, jer GPS i automatsko upravljanje traktora značajno olakšavaju rad vozačima traktora. Naime u područjima s aridnim uvjetima, noćna obrada tla i sjetva su korisne agronomske prakse. One pomažu očuvanju zemljišne vlage i poboljšavaju usvajanje vode, klijanje i nicanje sjemena. Vlažnost sjetvenog sloja ključan je faktor za uspješno nicanje

usjeva, posebno u aridnim područjima. Obradom tla tokom dana, uz visoke dnevne temperature i suhe vjetrove, dolazi do bržeg isušivanja sjetvenog sloja, što negativno utječe na klijavost i nicanje. Noćna obrada tla i sjetva imaju prednosti jer su srednje temperature sjetvenog sloja niže tokom noći, što smanjuje isparavanje i isušivanje tla, što sjemenu omogućuje da brže upije vlagu i ima veću energiju za klijanje (Lamichhane i Soltani, 2020). Obrada zemljišta i sjetva noću pozitivno utječu i na očuvanje biodiverziteta u tlu. Makro i mikro organizmi održavaju ravnotežu između mineralnih i organskih dijelova tla. Jedan od njihovih ključnih zadataka je razgradnja organskih ostataka u hranjiva dostupna biljkama. Ako se obrada i sjetva obavljaju danju, posebno u podnevnim satima, mnogi korisni mikroorganizmi trpe štetu zbog UV zraka. Također, tokom dnevne obrade, mnoge gliste, crvi i insekti stradaju od strane ptica ili dehidriraju pod utjecajem sunčeve svjetlosti. Noćna obrada smanjuje navedene gubitke jer ptice kao predatori nisu aktivne, a mikroorganizmi osjetljivi na sunčevu svjetlost imaju vremena da se premjeste dublje u tlo. Provođenje obrade tla noću može smanjiti broj fotosenzitivnih korova koji konkurišu gajenim usjevima (Juroszek, 2017). Ako se tlo obrađuje tokom dana, sunčeva svjetlost prodire u tlo i tako inicira klijanje sjemena korova koje se tamo nalazi u stadiju mirovanja. Obrada zemljišta i sjetva u noćnim terminima smanjuje zastupljenost širokolisnih korova kao što su štir, crna pomoćnica, poljska gorušica, loboda, ambrozija, poljski dvornik i sl. Na uskolisne korove ova praksa ima vrlo mali utjecaj.



Slika 66. Foto ilustracija prikaz precizne obrade tla

(Izvor:<https://autosteersystem.co.uk/products/f100-auto-steer-system-advanced-bundle>)

Noćni rad ima i svoje nedostatke. Prije svega, zbog slabije vidljivosti, noćni rad zahtijeva dodatno naprezanje traktorista, što zahtijeva kvalitetno umjetno osvjetljenje kako bi se smanjio broj preklapanja i neobrađenih površina. Instalacijom preciznih GPS sistema i automatskog upravljanja (autopilota) na postojeću mehanizaciju (traktore) ne samo da omogućuju direktnu uštedu prilikom pripreme tla tokom noći, već ovi sistemi značajno smanjuju opterećenje traktorista, poboljšavajući njihovu udobnost, sigurnost i produktivnost. Kao rezultat, traktoristi postižu veće zadovoljstvo poslom, održavaju bolju koncentraciju te efikasnije iskorištavaju radno vrijeme.



Slika 67. Autopilot instaliran na IMT 539

(Izvor:https://www.instagram.com/traktorskenavigacije/p/Cvsng1zsyNU/?img_index=5)

Dubina obrade zemljišta ima direktan utjecaj na energetska učinkovitost i prinos usjeva. Nepravilna dubina obrade može dovesti do zbijenosti tla, gubitaka vlage, neravnomjerne distribucije hranjiva u tlu, gubitka prinosa i prekomjernog trošenja energije. Kompanija Geoprospectors iz Austrije proizvela je komercijalno dostupno rješenje sistema za kontrolu oruđa za obradu zemljišta u realnom vremenu na osnovu očitavanja sa senzora elektromagnetne provodljivosti zemljišta (EC) i senzora mehaničkog otpora. Senzori evidentiraju promjene u tlu, te automatski podešavaju dubinu obrade na optimalanu vrijednost. Sistem se može koristiti dvojako, i to da mapira EC zemljišta tokom obavljanja bilo koje agrotehničke operacije, ili za kontrolu dubine u realnom vremenu tokom osnovne obrade zemljišta (Kostić, 2021). Korištenjem senzora i automatskih upravljačkih sistema za oruđa, poljoprivrednici mogu postići optimalnu obradu zemljišta uz minimalne gubitke resursa, što je ključno u uvjetima klimatskih promjena i rastućih troškova proizvodnje. Prikupljeni podaci sa senzora za obradu zemljišta se mapiraju zajedno sa drugim podacima i koriste za buduće agrotehničke zahvate.




Slika 68. Prikaz prikupljenih podataka za EC

(Izvor: <https://geopard.tech/blog/agte3p8ec1-analyze-geoprospectors-topsoilmapper-dat/#>).

Alati za određivanje optimalnih rokova sjetve

Vrijeme sjetve i sadnje usjeva ovisi o različitim faktorima, kao što su temperatura zraka, temperatura i vlažnost tla. Optimalno vrijeme za sjetvu omogućava usjevu najbolje uvjete za rast i razvoj tokom vegetacijskog ciklusa. Međutim, zbog varijabilnosti klimatskih uvjeta, datumi sjetve variraju iz godine u godinu. Klasični načini određivanje optimalnih rokova za sjetvu ponekad zahtijevaju dugotrajna poljska istraživanja na različitim lokacijama. U novije vrijeme za određivanje optimalnih datuma sjetve koriste se napredni matematički modeli, poznati kao "*crop models*" (modeli za simulaciju sjetve). Ovi modeli omogućuju simulaciju rasta biljaka u različitim klimatskim uvjetima, što pomaže poljoprivrednim proizvođačima da donesu odluke o najpovoljnijem roku sjetvu. Modeli obrađuju veliki broj podataka kao što su temperature zemljišta i zraka, količine oborina, vlažnost tla, plodnost tla, te genetska osnova biljaka. Na osnovu tih podataka, algoritmi proračunavaju kako će se usjev razvijati u određenim uvjetima, što omogućuje predviđanje optimalnog roka sjetve.

U praksi postoji više vrsta crop modela, koji se razlikuju po složenosti i primjeni. Neki od najpoznatijih su DSSAT (*Decision Support System for Agrotechnology Transfer*, <https://dssat.net/about/>) i APSIM (*Agricultural Production Systems Simulator*, <https://www.apsim.info/about-us/>). DSSAT je softverski paket koji radi na Windows operativnom sistemu. Sadrži modele za simulaciju rasta, razvoja i prinosa 45 različitih biljnih vrsta. Osim modela, DSSAT uključuje alate za upravljanje podacima o tlu, vremenu i agrotehničkim mjerama, kao i korisnim alatima za analizu učinaka različitih upravljačkih strategija u preciznoj i održivoj poljoprivredi. Modeli koriste dnevne meteorološke podatke, osobine tla, te plan agrotehničkih mjera, na osnovu čega se rezultati ažuriraju svakog dana dajući predviđanje stanja. DSSAT omogućuje brzu simulaciju dugoročnih učinaka bez potrebe za stvarnim eksperimentima, što ga čini korisnim alatom za istraživače, ali i poljoprivrednike. Od verzije 4.8.5 (2024) uključeni su alati za analizu ekonomskih i ekoloških rizika, uključujući utjecaj klimatskih promjena i preciznu poljoprivredu.



Slika 69. Snimka zaslona glavnog izbornika DSSAT v4.8.5 koja prikazuje odabir studije navodnjavanja s azotom u kukuruzu (Izvor: <https://dssat.net/about/>)

APSIM (*Agricultural Production Systems Simulator*) radi na sličnom principu kao i prethodni alat. Najčešće se koristi kao napredni simulacijski model razvijen za analizu poljoprivrednih sistema s posebnim fokusom na ekonomske i ekološke učinke upravljačkih praksi u uvjetima klimatskih rizika. Koristi se za pronalaženje rješenja u područjima sigurnosti hrane, prilagodbe klimatskim promjenama i smanjenje emisije CO₂. Razvijen je u Australiji, ali se danas koristi širom svijeta u naučnim, komercijalnim i političkim odlukama.

Primjena sistema precizne poljoprivrede u sjetvi

U tehnologiji precizne poljoprivrede upravljanje traktorima i oruđima kao što su prskalice, atomizeri, rasturači đubriva i sijačice je automatizovano i pod kontrolom je različitih softvera. Današnje moderne sijačice za sjetvu imaju za svaki red nezavisni pogonski elektromotor koji može prema nalogu centralnog procesora u bilo kojem trenutku sijati sjeme na željeni razmak. Takvi strojevi imaju i optičke senzore koji detektiraju svaku posijanu sjemenku i informaciju šalju u bazu podataka pa je moguće kasnije tačno vidjeti koliko je sjemenki u kojem redu i na kojem mjestu posijano. Za sjetvu se unaprijed pripreme karte sjetve i sijačica izvršava nalog prema tim podacima. Ukoliko je parcela koja se sije nepravilnog oblika, sijačica će posijati sjeme bez preklapanja uvijek na tačno definirani razmak. Na taj se način štedi sjeme i osiguravaju optimalni uvjeti za daljnji rast i razvoj biljaka. Promjenjivom normom sjetve moguće je smanjiti proizvodne troškove. Troškovi sjemenskog materijala su značajan izdatak, posebno kada se koristi visokokvalitetno

certificirano sjeme. Stoga je važno poznavati mogućnost smanjenja količine sjemena za usjev bez negativnog utjecaja na produktivnost. Smanjenje norme sjetve najčešće se primjenjuje na sušnim i manje plodnim zemljištima, dok se na plodnim i vlažnim zemljištima norma sjetve povećava. Sjetvu varijabilnom normom moguće je postići samo "preciznim" sijačicama koje su u kombinaciji s modernim softverskim rješenjima i bazama podataka (norme i rokovi sjetve, plodnost tla, vremenski uvjeti, satelitski snimci, itd.).



Slika 70. Šematski prikaz heterogenog polja i rada precizne sijačice

(Izvor: <https://soft.farm/en/blog/field-edata-portal-visualization-precision-planting-2020-shape-172>)

Bespilotne letjelice ili dronovi

Dronovi snimaju polja i prikupljaju neophodne podatke kao što su to: premjeravanje obradivog zemljišta i nivelacija, brojanje biljaka i analiza korova, analiza stresa i na kraju procjena prinosa. Cilj je sagledavanje stvarnog stanja parcela i usjeva čijom se daljom analizom mogu utvrditi odgovarajuće mjere koje će dovesti do povećanja prinosa i smanjenja troškova proizvodnje. Kada se posije kukuruz, već u fazi 3 lista, može se uraditi brojanje biljaka koje su nikle. Tako poljoprivrednik dobiva preciznu informaciju, na osnovu koje može da zna da li da presijava, može da uloži reklamaciju sjemenskoj kući, ili da provjeri mehanizaciju. Dron vidi svaki kvadratni metar parcele, ljudsko oko to ne može.

Biorazgradivi malč

Uvođenje plastične tehnologije četrdesetih godina prošlog vijeka izazvalo je pravu revoluciju u poljoprivredi. Jedna od primjena plastike je korištenje folija za malč kako bi se poboljšali prinosi i svojstva usjeva. Glavni ciljevi malčiranja su smanjenje gubitaka vode, regulisanje temperature tla, odnosno poboljšanje mikroklima, te suzbijanje korova. Kao rezultat pozitivnog učinka malčiranja je poboljšani rast usjeva što indirektno dovodi do većeg prinosa. Polietilen niske gustoće (PE) dobiven iz neobnovljivih izvora zbog niske cijene koštanja, jednostavne proizvodnje, dobrih proizvodnih rezultata i otpornosti na degradaciju tokom korištenja, uglavnom se koristi kao malč. Međutim,

ova vrsta malča ima određene ekološke i ekonomske nedostatke kao što su niska biorazgradivost, visoke troškove uklanjanja sa proizvodnih površina, transporta i odlaganja otpada. Zbog toga u posljednje vrijeme postoji sve veći interes za korištenje biorazgradivog malča kako bi se postigla veća održivost u poljoprivredi. Najčešće sirovine koje se koriste za proizvodnju biorazgradivog malča su škrob, polilaktična kiselina (PLA) i polihidroksialkanoat (PHA). Na primjer, papirnati malč, kao što je WeedGuardPlus®, potpuno je na bazi biomaterijala i izrađen je od celuloze.



Slika 71. Biorazgradivi malč film (Izvor: <https://green-paak.com/the-biodegradable-mulch-films-industry/>).

Biorazgradivi malč izrađen je od lako razgradivih materijala koji se nakon korištenja u poljoprivredi pretvaraju u prirodne spojeve sigurne za okoliš. Njegovom upotrebom postižu se iste prednosti kao i kod tradicionalnih malč folija, uz smanjenje zagađenja plastikom i podršku održivoj poljoprivredi.



Slika 72. Biorazgradivi malč papir (Izvor: <https://www.svz.com/news-and-blog/a-farmers-perspective-the-potential-benefits-of-biodegradable-mulching-paper/>).

Senzorsko mjerenje osobina usjeva

Vegetativni indeks se izračunava korišćenjem različitih spektralnih opsega reflektovane svjetlosti. Zdravstveno stanje biljke moguće je ispitati i provjeriti, snimiti, a zatim i procesuirati pomoću različitih indeksa kao što su: VI, NDVI, TNDVI, NDRE, VARI, SAVI, MSAVI2, TGI, SIPI2, LCI, BNDVI, GNDVI. Svaki indeks ima drugačiju upotrebu i drugačiji vizuelni izlaz. Njihova svrha je provjera trenutnog stanja biljke, potreba za vodom i različitim hranjivim materijama, ili čak utvrđuju prisustvo bolesti ili insekata na biljci. Vegetativni indeks normalizovane razlike, ili u široj literaturi kao NDVI (*Normalised Difference Vegetation Index*), koristi se za mjerenje aktivnosti hlorofila u biljkama, što je u direktnoj vezi sa obezbijedenošću biljaka azotnim hranivima i ukupnom vitalnošću. Dobar je pokazatelj aktivnosti fotosinteze, jer kada je zemljište bez još izniklih biljaka, on je bliži nuli, a sa njihovim rastom i povećanjem fotosinteze i vrijednost NDVI raste. Veće vrijednosti u početku mogu označavati brži rast usjeva, ali i korova, dok niže vrijednosti kasnije mogu označavati pojavu nekih bolesti, nedostatak vode ili hraniva. U slučaju strnih žita, zbog plitkog korijena, svaki nedostatak azota se drastično odražava na stanje usjeva, koje se može vrlo pouzdano detektovati NDVI indeksom. Osnovna svrha korišćenja vegetativnih indeksa u poljoprivredi jeste prepoznavanje produktivnih potencijala usjeva na lokalnom nivou u cilju primjene prostorno adaptivnog koncepta đubrenja prije svega, a potom zaštite ili navodnjavanja (Kostić, 2021).

SAT TS-Monitorng

SAT TS-Monitorng (Satelitsko praćenje suhe materije) identifikuje sadržaj suhe materije u biljkama koristeći satelitske slike. Idealan procenat je 30-35%. Kukuruz požnjeven kada je sadržaj suhe materije ispod 30% obično ima premalo skroba. Ako je sadržaj iznad 35% može doći do gubitaka prilikom skladištenja. Prostorna rezolucija sistema koju je KWS razvio je nekoliko metara. To znači da može da analizira pojedinačna polja ili njihove dijelove. Ispitivanja na 90 farmi širom Njemačke potvrđuju pouzdanost sistema u različitim klimatskim oblastima (<https://www.kws.com/rs/sr/proizvodi/kukuruz/>).

Zaoravanje žetvenih ostataka

Žetveni ostaci su materijali koji su ostali na obrađenom zemljištu nakon žetve. Zadržavanje žetvenih ostataka nakon žetve smatra se efikasnom protuerozijskom mjerom. Žetveni ostaci mogu poboljšati strukturu tla, povećati sadržaj organske tvari u tlu, smanjiti isparavanje i pomoći u vezivanju CO₂ u tlu. Osim toga, žetveni ostaci mogu se koristiti u proizvodnji biogoriva. Rezultati iz prakse pokazuju da žetveni ostaci pšenice i kukuruza povećavaju količinu vode u tlu, sadržaj humusa, infiltraciju oborinskih voda i hranjivih materija, što posljedično dovodi do povećanja produktivnosti, posebno u sušnim područjima. Nadalje, zaoravanje stajskog đubriva pokazuje pozitivne rezultate u očuvanju vlage u tlu i smanjenju potrebe za navodnjavanjem.



Slika 73. Zaoravanje žetvenih ostataka (Izvor: <https://www.lingayasvidyapeeth.edu.in/maximising-crop-residue-the-key-to-sustainable-farming/>)

Optimiziranje plodoreda povećava ugljik u tlu i smanjuje emisije stakleničkih plinova bez žrtvovanja prinosa

Emisije stakleničkih plinova iz ljudskih aktivnosti pridonose klimatskoj krizi, postavljajući izazove globalnoj sigurnosti hrane, bioraznolikosti i održivosti. Globalne poljoprivredne emisije stakleničkih plinova čine 31% ukupnih antropogenih emisija. Ublažavanje emisija stakleničkih plinova ključno je za buduću sigurnost klime, hrane i energije. Organski ugljik u tlu (SOC) može smanjiti neto emisije stakleničkih plinova, čineći 3-4% globalnih emisija. Međutim, intervencije usmjerene na smanjenje emisija stakleničkih plinova često rezultiraju promjenama u poljoprivrednim poslovima, što ga čini značajnim izazovom u 21. stoljeću.

Autonomni roboti u suzbijanju korova

Korovi usjevima oduzimaju hranu, prostor i sunčevu energiju. Ukoliko se na vrijeme korovi ne suzbiju, ometat će rast usjeva, smanjujući njihov prinos i kvalitetu, što će negativno utjecati i na ekonomičnost proizvodnje. Zbog toga je kontrola korova ključna za povećanje produktivnosti i konkurentnosti u poljoprivredi. U konvencionalnoj poljoprivredi, kontrola korova se najčešće temelji na upotrebi velikih količina herbicida. Međutim, ovakav pristup dovodi do crpljenja prirodnih resursa, onečišćenja životne sredine, te kontaminacije poljoprivrednih proizvoda. Zbog toga su razvijeni, a i dalje se razvijaju različiti načini suzbijanja korova. Upotreba autonomnih robota u kontroli korova je novijeg datuma. Globalna istraživanja i ulaganja u ovo područje bilježe eksponencijalni rast. Autonomni roboti predstavljaju alternativu hemijskom suzbijanju korova, te su kao takvi ekološki prihvatljivi (Zhang i sar., 2020). Za razliku od herbicida, korištenje robota ne izazivaju stres gajenih usjeva. Mogu se koristiti od početka nicanja usjeva, pa sve do zatvaranja međurednog prostora.

Roboti imaju sposobnost da u stvarnom vremenu identificiraju položaj gajenih biljaka i iste razlikuju od korova koje uništavaju. Zavisno o tipu i proizvođaču, roboti koriste različite metode kontrole korova. U posljednjih pet godina na tržištu su prisutni oni koji korov uklanjaju motičicama, šipkama, košenjem, mikro aplikacijom herbicida i laserima. U nastavku su opisani roboti koji se u posljednje vrijeme koriste u komercijalne svrhe.



Slika 74. Autonomni robot za suzbijanje korova (Izvor: <https://en.reset.org/these-smart-weed-killing-robots-use-twenty-times-less-herbicide-06272018/>).

Američka kompanija *Blue River Technology* razvila je robota pod nazivom "See and Spray". Ovaj robot koristi senzore i kamere za identifikaciju korova, te uz pomoć pokretnih dizni aplicira mikrokoličine herbicida na ciljane korove. Zahvaljujući ovakvom radu smanjuje se neciljano tretiranje i upotreba herbicida do 90%. Radom na ovaj način smanjuju se troškovi zaštite usjeva i doprinosi se očuvanju okoliša.

Švicarska kompanija *EcoRobotix* razvila je sličan robot. Prema njihovoj deklaraciji, na robotskim rukama se nalaze mikro dizne koji mogu smanjiti utrošak herbicida do 95% u odnosu na tradicionalni način apliciranja. Robot je opremljen solarnim pločama, ima mogućnost neprekidnog rada do 12 sati uz dnevni učinak do 3 ha. Upravljanje robotom se obavlja putem pametnog telefona.

Deepfield Robotics koji posluje u okviru *Bosch* grupacije razvio je autonomni robot pod nazivom "BoniRob". Ovaj robot ima sposobnost da tačno i precizno identificira korov te isti mehanički uništi pomoću šipki koje su montirane na platformu. Uz pomoć naprednih senzora, "BoniRob" identificira korov i zabija šipke kroz isti. Prema specifikaciji proizvođača ovaj robot omogućuje uzgoj bez herbicida, te se može koristiti i u organskoj proizvodnji. Njegova učinkovitost u suzbijanju korova je veća od 90%, a preciznost pri uništavanju korova do 2 mm. Robot je sposoban uništiti i do 20 korova u sekundi. Njegov radni učinak je 3 ha/h.



Slika 75. Solarni autonomni robot za suzbijanje korova (Izvor: <https://ecorobotix.com/company/origins/>)

Slika 76. BoniRob (Izvor: Biber i sar., 2012)

Kompanija Aigen je razvila autonomnu robot za okopavanje usjeva. Autonomni robot u stvarnom vremenu utvrđuje položaj gajenih biljaka, identificira korov i suzbija ga pomoću dvije pokretne motičice. Ovi roboti su ekološki prihvatljivi, jer ne koriste herbicide, te ne izazivaju stres kod gajenih usjeva. Suzbijanjem korova na ovaj način prozračuje se tlo, razbija pokorica, povećava mikrobiološka aktivnosti tla, te se poboljšava dostupnosti vode i hranjiva. Roboti u potpunosti rade na obnovljivu energiju. Napajaju se solarnom energijom i mogu raditi do 12 sati dnevno.



Slika 77. Robot plijeilica (Izvor: <https://www.mprnews.org/story/2024/06/17/robots-hoes-show-farmers-possible-future-weed-control>).

Roboti za lasersko suzbijanje korova. Za razliku od prethodnih robota čiji se rad zasniva na mehaničkom ili hemijskom suzbijanju korova, roboti ovog tipa korove suzbijaju toplotnom energijom.

Roboti rade na principu preciznih laserskih modula u kombinaciju sa kamerama visoke rezolucije i umjetnom inteligencijom za identifikaciju korova. Primjer takvog robota je "*LaserWeeder*" kompanije Carbon Robotics, koji može uništiti preko 100.000 korova na sat koristeći osam aktivnih laserskih modula. Laseri usmjeravaju toplotnu energiju na meristem korova, učinkovito ih uništavajući.



Slika 78. Laser robot (Izvor: <https://vegetablegrowersnews.com/news/27m-secured-by-carbon-robotics-for-its-autonomous-field-weeders/>) i Slika 79. Uništen korov (Izvor: <https://blog.adafruit.com/2021/09/13/carbon-robotics-autonomous-weeder-zaps-weeds-with-lasers/>).

Brza procjena parametara kvaliteta žita

Prilikom žetve, transporta, skladištenja i trgovine koriste se parametri kvalitete kako bi se procijenilo zdravstveno stanje sirovine, tehnologija dorade i skladištenja. Među tim parametrima su vlaga zrna, hektolitarska masa, sadržaj proteina i primjesa.

Vlaga se najčešće povezuje s kvarenjem, jer stvara povoljne uslove nepoželjnim mikroorganizmima koji se nalaze na zrnju. Naime, zrno žita nije sterilno i u uslovima povoljnim za rast i razvoj, mikroorganizmi se brzo razvijaju i počinju koristiti zrno, uzrokujući njegove gubitke u kvantitetu i kvalitetu. U određenim uvjetima, štetni mikroorganizmi mogu proizvesti i mikotoksine, izazvaju različite probleme kod životinja i ljudi koji koriste takvu sirovinu. Dakle, gubitak kvalitete, odnosno procesi kvarenja su u pozitivnoj korelaciji sa prekomjernim sadržajem vode u zrnju. Smatra se da je maksimalno dozvoljena vlaga za žita tijekom skladištenja 14%. Ako je sadržaj vlage iznad ovog postotka, zrno se mora što prije osušiti ili iskoristiti za određenu namjenu. Osim nepoželjnih mikroorganizama u žetvenoj masi mogu se naći štetni insekti, različite primjese, kao i polomljena zrna što sve zajedno umanjuje kvalitetu sirovine, te ih je stoga na vrijeme bitno indetifikovati. U posljednjih nekoliko godina razvijena je brojna terenska oprema i aplikacije sa kojim je moguće na brz i jednostavan način odrediti kvalitet zrna.

Terenski vlagomjeri pružaju ključnu pomoć na terenu pri određivanju optimalnog vremena žetve. Uređaji rade na principu mjerenja provodljivosti i temperature uzorka zrna. Tačna vrijednost sadržaja vlage izračunava se pomoću napredne softverske tehnike mjerenja, razvijene kroz dugogodišnje

praktično iskustvo. Uređaji se odlikuju velikom tačnošću ($\pm 0,5\%$). Veće oscilacije u mjerenju mogu biti u vlažnijim uzorcima zrna. Većina vlagomjera je lagana, izrađena od kvalitetne, udarno otporne plastike, te se mogu sigurno transportirati na traktorima i kombajnima bez rizika od oštećenja. Suvremeni i skuplji vlagomjeri dolaze u kombinaciji sa hektolitarskom vagom, koja ima sposobnost mjerenja hektolitarske mase većine gajenih usjeva. S obzirom da je hektolitarska masa (100 L) prvi pokazatelj kvaliteta sirovine, ona može sugerirati što se sve događalo sa sirovinom tokom uzgoja, ali i tokom skladištenja. Na primjer, neishranjen usjev (štura zrna), suša tokom uzgoja i prisustvo pljevica smanjuju njenu vrijednosti. Razvojem moderne tehnike do vrijednosti hektolitarske mase moguće je doći brzo i jednostavno koristeći prenosive vlagomjer-hektolitarske vage. Preciznost ovih terenskih vaga je bez većih odstupanja i vrijednosti su slične laboratorijskim rezultatima.



Slika 80. Terenski vlagomjer (Farmpoint - Supertech Moisture) Slika 81. Superpro Portable Digital Moisture Meter (Izvori: <https://www.agriculture-xprt.com/products/farmpoint-supertech-moisture-meter-for-grain-and-seeds-526108> i <https://spaldings.co.uk/products/sp-website/agriculture/crop-management/crop-sampling/superpro-portable-digital-grain-moisture-meter-with-built-in-grinder>)

Na tržištu postoje različiti prijenosni uređaji koji mogu brzo odrediti hemijski sastav zrna pšenice, ječma, zob, uljane repice, kukuruza, soje i drugih usjeva. Rad ovih uređaja temelji se na principu mjerenja refleksije/transmisije blisko-infracrvenog zračenja (engl. *near-infrared* – NIR). NIR analizatori se mogu koristiti za određivanje udjela proteina, masti, skroba, gutena i drugih jedinjenja u uzorcima različitih vrsta (Zhang i sar., 2022). Za analizu je potrebno svega nekoliko grama uzorka, a rezultati su dostupni za svega nekoliko sekundi. Tačnost ovih NIR analizatora usporediva je s laboratorijskim rezultatima. Terenski analizatori su lagani i jednostavni za korištenje. Mnogi od njih imaju ugrađen GPS i internu memoriju, što omogućuje mapiranje uzorkovanih lokacija, što može biti korisno za buduću popravku prinosa i kvalitete gajenih usjeva. Najnoviji uređaji se mogu povezati s mobilnim aplikacijama za pregled podataka i lokacija testiranja.



Slika 82. Terenski analizatori proteina



Slika 83. IM 8800 je prijenosni NIR uređaj

(Izvori: <https://farmtronics.com/products/product/grain-sense-portable-protein-analyzer>).

Korištenje umjetne inteligencije u određivanju kvalitete sjemena

Kvaliteta žita i drugih usjeva često je ugrožena prisutnošću nečistoća (štura zrna, fizička oštećena, korovi, kamenčići) i bolestima. Ovi neželjeni elementi značajno utječu na kvalitet sirovine, te se isti moraju analizirati tokom procjene kvalitete. Klasičan način analize ovih parametara sastoji se od uzorkovanja, transporta uzoraka u laboratorije i čekanja nekoliko dana do rezultata laboratorijske analize. U takvim slučajevima, poljoprivredni proizvođači nekoliko dana ne znaju kvalitetu i stanje svoje sirovine, što smanjuje mogućnost poduzimanja korektivnih mjera, poput izbora optimalnog vremena žetve, podešavanja mehanizacije i drugih aktivnosti, kako bi se minimizirali vanjski faktori koji mogu utjecati na kvalitetu sirovine. Zbog toga su posljednjih godina razvijeni različiti uređaji i aplikacije koje rade na principu umjetne inteligencije koji automatski određuju kvalitetu uzorka, odnosno njihovu čistoću, vlagu, temperaturu i prisustvo štetnika.

Većina ovakvih aplikacija koristi analizu slike kao automatiziranu alternativu ručnoj analizi uzoraka, pružajući visoku tačnost i rezultate u svega nekoliko sekundi. Za rad ovih aplikacije potrebno je imati foto aparat visoke rezolucije i dobro osvijetljene uzorke. Analizom slike žita u skladištu moguće je otkriti prisutne insekte, identificirati prisustvo različitih sorti, ujednačenost veličine zrna, kao i prisutnost različitih lomova i oštećenja na zrnu (Hemender i sar., 2018; Tu i sar., 2023; Wang i sar., 2024). Također, ove aplikacije mogu detektirati mjesta s povišenom temperaturom u skladišnom prostoru, što može ukazivati na narušavanje kvalitete skladištene sirovine.

Solarne sušnice

Sušenje je stara metoda konzerviranja poljoprivrednih proizvoda koja se koristi za očuvanje kvaliteta. Procesom sušenja smanjuje se sadržaj vlage u proizvodu, te se na taj način produžuje vrijeme korištenja proizvoda. Na primjer, uklanjanjem suvišne vlage inhibira se proces klijanja sjemena, razvoj gljivica i bakterija na površini zrna, to jest, stvaraju se nepovoljni uvjeti za uzročnike

kvarenja "žetve". S druge strane, sušenjem se značajno smanjuju volumen i težina poljoprivrednih proizvoda, što u određenoj mjeri snižava troškove pakovanja, transporta i skladištenja.


Različiti načini sušenja poljoprivrednih proizvoda, bilo da se radi o tradicionalnim ili konvencionalnim, imaju svoje prednosti i nedostatke. Tradicionalno prirodno sušenje je sporo i nepredvidivo u pogledu kvaliteta osušene sirovine. Na primjer, izlaganje ljekovitog bilja direktnoj sunčevoj svjetlosti može značajno smanjiti njegovu kvalitetu. Korištenjem konvencionalnog načina sušenja proces je u potpunosti automatiziran i kontroliran, te se postiže zadovoljavajući kvalitet proizvoda. Međutim, glavni nedostatak je velika potrošnja energije (nafta, plin, struja i drugi energenti), što u današnje vrijeme izaziva zabrinutost zbog prekomjernog oslobađanja CO₂ i utjecaja na klimatske promjene. Zbog svega navedenog, u posljednjih godina promoviraju se održivi načini sušenja. Solarne sušare, iako zahtijevaju veće početne investicije, imaju prednosti u odnosu na prirodne i konvencionalne metode sušenja. Njihovi operativni troškovi su niski jer koriste obnovljivu energiju (solarnu) koja ne zagađuje okoliš, čime se smanjuje emisija CO₂. Solarne sušare već se koriste za sušenje žita, uljarica, voća, povrća i ljekovitog bilja u sunčanim podnebljima. S razvojem jeftinijih solarnih tehnologija i subvencijama za zelenu energiju, ova rješenja postaju sve dostupnija malim i srednjim poljoprivrednicima.

U praksi postoji nekoliko tipova solarnih sušnica. Sušnice se s obzirom na strujanje zraka dijele u dvije grupe: pasivne (sa prirodnim strujanjem) i aktivne (sa prinudnim strujanjem) (Hodžić i Hasanagić, 2024).

Solarne pasivne sušnice su jednostavne konstrukcije, malog kapaciteta i jeftine za investiciju. Prema konstrukciji dijele se na solarne direktne i solarne indirektne.

Solarne direktne pasivne sušnice su najpovoljnije i najjednostavnije za korištenje (slika 84a). Komora za sušenje sušnice izgleda kao kutija sa čije prednje strane je prozirna ploča od stakla, polietilena ili polikarbonata s otvorom za punjenje i pražnjenje (Venkateswarlu i Reddy, 2024). Proces sušenja se zasniva na direktnom izlaganju poljoprivrednih proizvoda sunčevoj svjetlosti. Glavni nedostatak ovih sušnica je mali kapacitet i nemogućnost sušenja proizvoda koji su skloni gubitku kvaliteta (vitamin, enzimi, boja) zbog direktnog izlaganja sunčevoj svjetlosti.


Solarne indirektne pasivne sušnice su složenije konstrukcije. Sastoje se od solarnog kolektora i komore za sušenje (slika 84b). Solarni kolektor prikuplja toplotnu energiju i zagrijava zrak koji se potom prirodno kreće do komore za sušenje u kojoj preuzima dio vlage sa poljoprivrednih proizvoda (Ennissiou i sar., 2023). Zrak zasićen vlagom prirodno nastavlja svoj put do otvora na vrhu komore. Iako je efikasnost sušenja niža nego kod direktnih pasivnih sušnica, proces sušenja se odvija u termički izoliranim i tamnim komorama, omogućujući sušenje proizvoda u prirodnoj boji, što je posebno bitno kod ljekovitog bilja. Moderni tipovi ovih sušnica su opremljeni različitim senzorima koji prate uvjete sušenja (temperatura i relativna vlaga u komori), na osnovu kojih se regulira protok zagrijanog zraka i otpuštanje vlage iz komore za sušenje.



Slika 84. Šematski prikaz solarnih pasivnih sušnica (a – direktna i b – indirektna)

(Izvor: Gorjian i sar., 2021)

Solarne aktivne sušnice su složenije konstrukcije i skuplje su u odnosu na solarne pasivne. Proizvode se u različitim dimenzijama, od vrlo malih do vrlo velikih. Veća konstrukcijska rješenja su ekonomičnija. Solarne aktivne sušnice se sastoje od solarnog kolektora, komore za sušenje i sistema za cirkulaciju zraka. Solarni kolektor prikuplja energiju i zagrijava zrak kojeg ventilatori usmjeravaju u komoru za sušenje gdje se nalaze poljoprivredni proizvodi (slika 85). Na vrhu komore za sušenje nalazi se ispusni ventilator sa senzorima koji reguliraju zasićenost zraka vlagom. Moderne sušnice su opremljene senzorima za temperaturu i vlažnosti zraka, sistemima ventilatora za cirkulaciju zraka, te mikroprocesorom koji kontrolira proces sušenja. Njihov rad pokreće električna energija proizvedena iz fotonaponskih ćelija na krova sušnice (Tiwari i sar., 2016).



Slika 85. Šematski prikaz solarne aktivne sušnice (Izvor: Gorjian i sar., 2021)

Unatoč nabrojanim prednostima, prethodno opisane sušnice imaju nizak energetska učinak. Ovaj nedostatak dolazi zbog nepravilnog dnevnog i sezonskog intenziteta solarne energije što dovodi do nepravilnog sušenja. Kao rezultat toga često dolazi do smanjenja kvaliteta osušenih proizvoda, odnosno povećava se rizik od mikrobiološke kontaminacije. Zbog toga su razvijene energetska učinkovitije *solarne hibridne sušnice*.

Ove sušnice neiskorišteni dio solarne energije pohranjenu u jedinicu za pohranu energije (pufer), te istu koriste u vrijeme kada sunčeva energija nije dostupna. Na primjer, pohranjenu energiju moguće je iskoristiti za sušenje poljoprivrednih proizvoda i tokom noći. Glavni dijelovi hibridnih sušnica su solarni kolektor, jedinica za pohranu toplotne energije, izmjenjivači toplote, komora za sušenje, mikroprocesori i sistemi senzora za kontrolu ambijentalnih uvjeta. Većina ovih sušnica je autonomna zahvaljujući vlastitim fotonaponskim panelima i nema potrebu za vanjskim izvorima električne energije. Također, solarne hibridne sušnice većeg kapaciteta mogu biti opremljene i dodatnim izvorom toplotne energije koja osigurava kontinuirani rad u dužem vremenskom periodu (zimsko oblačno vrijeme). Na tržištu postoje različita konstrukcijska rješenja hibridnih solarnih sušnica, te, na osnovu dopunskog izvora energije solarne hibridne sušnice mogu biti:

- Solarne sušnice u kombinaciji sa toplotnom pumpom,
- Solarne sušnice u kombinaciji sa biomasom,
- Solarne sušnice u kombinaciji sa bioplinom i
- Solarne sušnice u kombinaciji sa električnom energijom fotoćelija ili vjetra (Kong, 2024).

Navedene vrste hibridnih solarnih sušilica su vrlo učinkovite i imaju sposobnost da rade i u manje povoljnim vremenskim uvjetima (tokom zime).

Moderne solarne sušare omogućuju preciznu kontrolu temperature i vlažnosti, što rezultira ravnomjernijim sušenjem i očuvanjem kvalitete. Solarne sušnice su opremljene senzorima i automatskim upravljanjem koji omogućuju praćenje temperature i vlage u realnom vremenu čime se sprječava presušivanje ili nedovoljno sušenje sirovine. Zatim, opremljene su senzorima i mikroprocesorima koji kontroliraju i prilagođavaju protok zraka čime se postiže veća energetska učinkovitost. Također, najnovije solarne sušnice su pogonjene umjetnom inteligencijom, te pametno upravljaju energijom, odnosno višak energije akumuliraju, ili se koristi za druge potrebe na gazdinstvu.

LITERATURA:

- 1) Biber, P., Weiss, U., Dorna, M., Albert, A. (2012). Navigation System of the Autonomous Agricultural Robot Bonirob. In: Workshop on Agricultural Robotics: Enabling Safe, Efficient, and Affordable Robots for Food Production (Collocated with IROS 2012), Vilamoura.
- 2) Ennissioui, J., Benghoulam, E.M., El Rhafiki, T. (2023). Experimental study of a natural convection indirect solar dryer. *Heliyon*. 9(11): e21299. doi:10.1016/j.heliyon.2023.e21299.
- 3) FAO. (2023). World Food and Agriculture – Statistical Yearbook 2023. Rome.
- 4) Gorjian, S., Hosseingholilou, B., Jathar, L.D., Samadi, H., Samanta, S., Sagade, A.A., Kant, K., Sathyamurthy, R. (2021). Recent Advancements in Technical Design and Thermal Performance Enhancement of Solar Greenhouse Dryers. *Sustainability*. 13(13). <https://doi.org/10.3390/su13137025>

- 5) Hemender, H., Sharma, S., Mor, V. S., Bhuker, A. (2018). Image Analysis: A Modern Approach to Seed Quality Testing. *Current Journal of Applied Science and Technology*, 27(1), 1–11. <https://doi.org/10.9734/CJAST/2018/40945>
- 6) Hodžić, A., Hasanagić, R. (2019). Obnovljivi izvori energije u procesu sušenja drveta. 32. Međunarodni kongres o procesnoj industriji. Beograd, Srbija
- 7) <https://autosteersystem.co.uk/products/f100-auto-steer-system-advanced-bundle>
- 8) <https://blog.adafruit.com/2021/09/13/carbon-robotics-autonomous-weeder-zaps-weeds-with-lasers/>
- 9) <https://dssat.net/about/>
- 10) <https://ecorobotix.com/company/origins/>
- 11) <https://farmtronics.com/products/product/grain-sense-portable-protein-analyzer>
- 12) <https://geopard.tech/blog/agte3p8ec1-analyze-geoprospectors-topsoilmapper-dat/#>
- 13) <https://green-paak.com/the-biodegradable-mulch-films-industry/>
- 14) <https://soft.farm/en/blog/field-edata-portal-visualization-precision-planting-2020-shape-172>
- 15) <https://spaldings.co.uk/products/sp-website/agriculture/crop-management/crop-sampling/superpro-portable-digital-grain-moisture-meter-with-built-in-grinder>
- 16) <https://university.taylors.edu.my/en/student-life/news/2023/fields-of-the-future-agro-innovation-of-laser-weeding-robots.html>
- 17) <https://vegetablegrowersnews.com/news/27m-secured-by-carbon-robotics-for-its-autonomous-field-weeders/>
- 18) <https://www.agriculture-xprt.com/products/farmpoint-supertech-moisture-meter-for-grain-and-seeds-526108>
- 19) <https://www.agroklub.com/ratarstvo/novi-pioneerovi-hibridi-prilagodeni-susnim-uvjetima/36526/>
- 20) <https://www.agroklub.com/ratarstvo/zasto-je-tlo-bolje-obradivati-nocu/54177/>
- 21) <https://www.apsim.info/about-us/>
- 22) <https://www.deere.hr/hr/precizna-poljoprivreda/>
- 23) https://www.instagram.com/traktorskenavigacije/p/Cvsng1zsyNU/?img_index=5
- 24) <https://www.kws.com/rs/sr/proizvodi/kukuruz/>
- 25) <https://www.lingayasvidyapeeth.edu.in/maximising-crop-residue-the-key-to-sustainable-farming/>
- 26) <https://www.mprnews.org/story/2024/06/17/robots-hoes-show-farmers-possible-future-weed-control>
- 27) <https://www.sciencedirect.com/science/article/pii/S2666154320300703>
- 28) <https://www.sciencedirect.com/science/article/pii/S2666154320300703>
- 29) <https://www.svz.com/news-and-blog/a-farmers-perspective-the-potential-benefits-of-biodegradable-mulching-paper/>

- 30) Juroszek, P., Neuhoﬀ, D., Köpke, U. (2017). Night-time tillage revisited: the delayed soil desiccation process in night-time tilled plots may promote unexpected weed germination. *Weed Research*, 57(4), 213-217.
- 31) Khaliullin, D., Belinsky, A., Valiev, A., Lukmanov, R., Bourges, G. (2020). Optimization of plow adjustment. In: *BIO Web Conference*, 27.
- 32) Kong, D., Wang, Y., Li, M., Liang, J. (2024). A comprehensive review of hybrid solar dryers integrated with auxiliary energy and units for agricultural products. *Energy*, 293.
- 33) Kostić, M. M. (2021). Precizna poljoprivreda. Univerzitet u Novom Sadu. Poljoprivredni fakultet <http://polj.uns.ac.rs/sites/default/files/udzbenici/Precizna%20poljoprivreda%20-%20Kosti%C4%87%20Marko%20kona%C4%8Dno.pdf>
- 34) Lamichhane, J. R., Soltani, E. (2020). Sowing and seedbed management methods to improve establishment and yield of maize, rice and wheat across drought-prone regions: a review. *Journal of Agriculture and Food Research*, 2, 100089.
- 35) Menđušić, I., Knežević, D., Petrović, D., Banaj, A. (2017). Vučna sila traktora potrebna za svladavanje otpora lemešnih plugova // *Agriculture in nature and environment protection*. Vukovar: Glas Slavonije. 191-196.
- 36) Šarauskis, E., Kazlauskas, M., Naujokienė, V., Bručienė, I., Steponavičius, D., Romanekas, K., Jasinskas, A. (2022). Variable Rate Seeding in Precision Agriculture: Recent Advances and Future Perspectives. *Agriculture*, 12, 305. <https://doi.org/10.3390/agriculture12020305>
- 37) Tiwari, S., Tiwari, G.N., Al-Helal, I.M. (2016). Performance analysis of photovoltaic–thermal (PVT) mixed mode greenhouse solar dryer. *Sol. Energy*, 133, 421–428
- 38) Tu, K., Wu, W., Cheng, Y., Zhang, H., Xu, Y., Dong, X., Wang, M., Sun, Q. (2023). AIseed: An automated image analysis software for high-throughput phenotyping and quality non-destructive testing of individual plant seeds. *Computers and Electronics in Agriculture*. 207, 107740. doi:10.1016/j.compag.2023.107740
- 39) Venkateswarlu, K., Reddy, S.V.K. (2024). Recent trends on energy-efficient solar dryers for food and agricultural products drying: a review. *Waste Disposal & Sustainable Energy*, 6: 335–353. <https://doi.org/10.1007/s42768-024-00193-3>
- 40) Wang, Z., Fan, S., An, T., Zhang, C., Chen, L., Huang, W. (2024). Detection of Insect-Damaged maize seeds using hyperspectral imaging and hybrid 1D-CNN-BiLSTM models., *Infrared Physics & Technology*, 137. <https://doi.org/10.1016/j.infrared.2024.105208>
- 41) Zhang, S., Liu, S., Shen, L., Chen, S., He, L., Liu, A. (2022). Application of near-infrared spectroscopy for the nondestructive analysis of wheat flour: A review. *Current Research in Food Science*. 5, 1305–1312FAO. 2023. *World Food and Agriculture – Statistical Yearbook 2023*. Rome. <https://doi.org/10.4060/cc8166en>
- 42) Zhang, W., Miao, Z., Li, N., Sun, T. (2022). Review of Current Robotic Approaches for Precision Weed Management. *Curr Robot Rep* 3, 139–151. <https://doi.org/10.1007/s43154-022-00086-5>.

NAPREDNE TEHNIKE POLJOPRIVREDNE MEHANIZACIJE ZA ODRŽIVE SISTEME BILJNE PROIZVODNJE

Nermin Rakita, Zuhdija Omerović

Pametni sistem biljne proizvodnje predstavlja pristup poljoprivredi koji se temelji na očuvanju resursa, smanjenju negativnog utjecaja na okoliš, te osiguravanju ekonomske i socijalne održivosti. Cilj sistema je dugoročno očuvanje plodnosti tla, očuvanje biološke raznolikosti, te minimiziranje upotrebe hemikalija kroz integrirane metode upravljanja. Pametna poljoprivreda omogućava ne samo proizvodnju hrane za sadašnje generacije, već i očuvanje resursa za buduće generacije, što je od presudne važnosti u kontekstu globalnih izazova poput klimatskih promjena i rasta populacije (Altieri, 1995).

Poljoprivredna mehanizacija predstavlja temelj pametnih poljoprivrednih sistema. Korištenje naprednih tehnologija u mehanizaciji omogućava optimalno iskorištavanje ključnih resursa poput vode, energije i radne snage, što doprinosi smanjenju negativnih ekoloških utjecaja. Osim toga, pametna mehanizacija omogućava preciznu primjenu agrotehničkih mjera, što direktno utiče na smanjenje upotrebe fitofarmaceutskih sredstava (FFS) i mineralnih gnojiva. Time se postiže efikasnije upravljanje zemljištem, povećava produktivnost i doprinosi održivom razvoju poljoprivrede, u skladu s ciljevima zaštite okoliša i očuvanja prirodnih resursa.

Na primjer, precizna poljoprivreda, koja uključuje korištenje GPS tehnologije, senzora i GIS sistema, omogućava poljoprivrednicima precizno upravljanje resursima i smanjenje gubitaka. Ova tehnologija se može koristiti za preciznu sjetvu, gnojidbu i navodnjavanje, što smanjuje troškove i povećava prinose. Pored toga, primjena pametne mehanizacije u procesima berbe i post-berbenog tretmana omogućava smanjenje gubitaka i poboljšanje kvaliteta proizvoda (Gebbers & Adamchuk, 2010).

U kontekstu globalnih izazova, kao što su klimatske promjene, smanjenje plodnosti tla, te rastuća potražnja za hranom, pametne tehnike mehanizacije postaju sve značajnije. Ove tehnike omogućavaju prilagodbu poljoprivrednih praksi promjenama u klimatskim uslovima, smanjenje emisija stakleničkih gasova, te očuvanje prirodnih resursa.

Jedan od primjera modernih tehnologija u poljoprivredi je primjena automatizovanih sistema za navodnjavanje, koji imaju značajan utjecaj na optimizaciju potrošnje vode, posebno u kontekstu sve učestalijih suša. Ovi sistemi su sposobni prilagoditi količinu vode specifičnim potrebama usjeva u realnom vremenu, čime se ne samo smanjuje nepotrebna potrošnja resursa, već se i povećava efikasnost cjelokupnog navodnjavanja. Slično tome, primjena naprednih tehnologija u zaštiti bilja, kao što su dronovi za preciznu primjenu FFS, omogućava smanjenje upotrebe hemijskih sredstava, što ima pozitivan efekat na očuvanje okoliša i zdravlja tla.

Pored toga, mehanizacija može igrati ključnu ulogu u održavanju i poboljšanju kvaliteta tla. Tehnike minimalne obrade tla, koje koriste specijalizirane mašine za smanjenje zbijanja tla i očuvanje organske materije, mogu značajno doprinijeti održivosti poljoprivrednih sistema. Ove tehnike ne samo da smanjuju eroziju tla, već i poboljšavaju strukturu i plodnost tla, što je od suštinskog značaja za dugoročnu produktivnost poljoprivrede (Lal, 2004).

Tehnike precizne poljoprivrede

Primjena GPS i GIS tehnologija

Precizna poljoprivreda predstavlja revoluciju u načinu na koji se obavljaju poljoprivredne operacije, koristeći napredne tehnologije kako bi se optimizirali prinosi, smanjili troškovi i smanjio negativan utjecaj na okoliš. Jedna od ključnih tehnologija u preciznoj poljoprivredi je globalni navigacijski satelitski sistem (GNSS), koji uključuje GPS (*Global Positioning System*). Korištenjem GPS-a, poljoprivrednici mogu precizno mapirati svoja polja, pratiti položaj opreme i upravljati usjevima na način koji je mnogo precizniji od tradicionalnih metoda.

GPS tehnologija omogućava poljoprivrednicima praćenje položaja traktora i ostalih mašina s izuzetnom preciznošću, koja doseže tačnost do nekoliko centimetara. Ova visoka razina preciznosti posebno je značajna tokom sjetve i primjene gnojiva, gdje i najmanje odstupanje može dovesti do značajnih ekonomskih gubitaka. Na primjer, primjena GPS sistema u preciznoj sjetvi osigurava ravnomjernu distribuciju sjemena, smanjujući preklapanje i praznine na polju, što u konačnici dovodi do efikasnijeg korištenja resursa i povećanja prinosa.

Pored GPS-a, tehnologije geografskih informacijskih sistema (GIS) također igraju važnu ulogu u preciznoj poljoprivredi. GIS omogućava integraciju i analizu podataka prikupljenih s različitih senzora i satelita, čime se omogućava detaljno mapiranje tla, usjeva i okoliša. GIS omogućava poljoprivrednicima da identifikuju varijabilnost unutar svojih polja i prilagode svoje operacije prema specifičnim potrebama različitih dijelova polja (McBratney *et al.*, 2005).

Primjena GPS i GIS tehnologija omogućava preciznu i efikasnu primjenu resursa, što je ključno za pametnu poljoprivredu. Na primjer, poljoprivrednici mogu koristiti GIS podatke za identifikaciju područja unutar svojih polja koja zahtijevaju više ili manje gnojiva, te prema tome prilagoditi količinu koja se primjenjuje. Na taj način, smanjuje se upotreba gnojiva, smanjuje se zagađenje okoliša i povećava se prinos.

Navođenje traktora GPS-om

Ova tehnologija pomaže u optimizaciji rada traktora, smanjenju grešaka i unapređenju produktivnosti. Postoje dvije glavne vrste sistema automatskog navođenja traktora, koje se razlikuju po načinu integracije i funkcionalnosti: sistemi za pomoć pri upravljanju i potpuno automatizovani sistemi.

Potpuno automatizovani sistemi upravljanja traktorom, poznati kao “traktorski autopilot” sistemi, koriste naprednu GPS tehnologiju za autonomno navođenje traktora, eliminirajući potrebu za konstantnom intervencijom vozača. Ovi sofisticirani sistemi direktno upravljaju hidrauličkim i elektroničkim komponentama traktora, omogućavajući održavanje preciznog kursa s minimalnim odstupanjima, što značajno povećava tačnost rada i smanjuje mogućnost ljudske greške.

Ključne komponente traktorskog autopilot sistema uključuju GPS prijemnik, centralnu kontrolnu jedinicu i servo-motore koji upravljaju mehaničkim elementima traktora. Ovi napredni sistemi pružaju izvanrednu preciznost čak i u nepovoljnim vremenskim i terenskim uvjetima, čime se omogućava efikasnije i produktivnije izvođenje poljoprivrednih operacija.

Sistemi za pomoć pri upravljanju, poznati kao “*assisted steering systems*”, ne preuzimaju direktnu kontrolu nad hidrauličnim komponentama traktora, već pružaju vozaču podršku kroz vizualne i zvučne signale. Ovi sistemi pomažu u održavanju preciznog pravca traktora, smanjujući zamor

vozača poboljšavajući ukupnu produktivnost rada. Umjesto automatskog upravljanja, vozaču se daju informacije koje olakšavaju precizno kretanje i smanjuju mogućnost greške tokom obavljanja poljoprivrednih operacija.

Među najpoznatijim proizvođačima ovih sistema su: John Deere sa svojim *AutoTrac* sistemom, Trimble sa *Autopilotom*, AG Leader sa *OnTrack3* sistemom, te Case IH (*AFS AccuGuide*) i CLAAS (*AUTO-GUIDE*). Svaki od ovih sistema ima specifične karakteristike koje omogućavaju poboljšanu preciznost i jednostavnost korištenja.

Primjer naprednog sistema za pomoć pri upravljanju je *OnTrack3* kompanije Ag Leader. Ovaj sistem omogućava brzu i jednostavnu instalaciju zahvaljujući modelu “*Lock-n’-Roll*”, što olakšava prebacivanje između različitih vozila. *OnTrack3* koristi električni motor koji je montiran na volan traktora, omogućujući precizno vođenje bez potrebe za stalnom intervencijom vozača. GPS podaci, koji se prikupljaju putem antene, šalju se u kontrolnu jedinicu koja ih obrađuje kako bi održala vozilo na željenoj putanji.

Sistem se sastoji od ključnih komponenti kao što su aktuator, GPS antena, kontrolna jedinica, žičana veza za prijenos podataka i korisnički terminal. Za razliku od potpuno automatizovanih sistema, *OnTrack3* ne intervenira direktno u mehaničke komponente upravljanja, već vozaču pruža precizne informacije, pomažući mu da održi tačan smjer i smanji mogućnost greške prilikom obrade tla.



Slika 86. Postavljanje aktuatora na upravljački uređaj - *Ag Leader's SteadySteer* (Izvor: <https://www.youtube.com/watch?v=3cYQpu4Mm9w>).

Komponente autopilota koje se ugrađuju u traktor ključne su za osiguranje autonomnog upravljanja i preciznog vođenja vozila. Glavni dijelovi sistema uključuju:

- Upravljač i motor upravljača: Ova komponenta je temelj autopilot sistema, odgovorna za automatsko upravljanje traktorom. Motor upravljača preuzima kontrolu nad volanom, omogućavajući precizne pokrete bez potrebe za manuelnom intervencijom vozača, čime se postiže visoka preciznost pri radu u polju.
- GNSS antena: Globalni navigacijski satelitski sistem (GNSS) koristi antenu za prijem signala sa satelita, što omogućava pozicioniranje traktora s tačnošću od nekoliko centimetara. Ova antena je ključna komponenta koja osigurava visoku razinu preciznosti neophodnu za poljoprivredne radove poput sjetve i primjene gnojiva.
- RTK modem: Ovaj modem omogućava povezivanje sistema s RTK (*Real-Time Kinematic*) mrežom koja pruža korekciju pozicioniranja. RTK tehnologija dodatno povećava preciznost GNSS signala, omogućavajući traktoru da zadrži optimalnu putanju čak i u složenijim uvjetima rada.

- Terminal (*Touch Screen*): Ekran osjetljiv na dodir služi kao glavni interfejs za upravljanje autopilot sistemom. Korisnicima omogućava postavljanje AB linija, praćenje statusa sistema, podešavanje parametara i kontrolu nad operacijama, čineći rad jednostavnijim i efikasnijim.
- Kablovi i senzori: Ovi elementi povezuju sve komponente autopilot sistema, osiguravajući međusobnu komunikaciju i pravilno funkcioniranje. Senzori nadgledaju različite aspekte rada sistema, dok kablovi osiguravaju stabilan prijenos podataka između dijelova sistema.

Ova integracija naprednih tehnologija omogućava precizno i efikasno vođenje traktora, značajno povećavajući produktivnost i smanjujući mogućnost greške u poljoprivrednim operacijama.

Proces instalacije autopilot sistema za traktor započinje montažom upravljačkog mehanizma i motora na volan traktora. Aktuator, odnosno upravljački mehanizam, je dizajniran tako da omogućava brzu i jednostavnu ugradnju bez potrebe za specijalizovanim alatima, čime se značajno olakšava proces postavljanja. GNSS antena se obično montira na najvišu tačku traktora, najčešće na krov kabine, kako bi osigurala nesmetan prijem satelitskih signala.

Nakon toga, RTK modem se povezuje sa sistemom, omogućavajući prijem korekcijskih signala preko mobilne mreže ili vlastite RTK baze, čime se dodatno povećava preciznost pozicioniranja. Terminal s ekranom osjetljivim na dodir postavlja se unutar kabine traktora na pristupačno mjesto za vozača, kako bi mu omogućio jednostavan pristup i upravljanje sistemom. Sve komponente se međusobno povezuju putem kablova, čime se omogućava stabilna komunikacija unutar sistema.

Zadnji korak u instalaciji je kalibracija sistema. To uključuje podešavanje ključnih parametara, poput širine traktora i radnog zahvata, kako bi se osigurala optimalna preciznost i ispravan rad autopilot sistema tokom poljoprivrednih operacija.

Korištenje senzora za monitoring usjeva

Senzori su ključna komponenta pametne poljoprivrede, omogućavajući stalno praćenje stanja usjeva i tla u realnom vremenu. Postoji širok spektar senzora koji se koriste u poljoprivredi, uključujući senzore za mjerenje vlažnosti tla, temperature, pH vrijednosti, sadržaja hranjivih tvari, te stanja usjeva.

Senzori za vlažnost tla, na primjer, omogućavaju poljoprivrednicima da precizno prate nivo vlage u različitim dijelovima polja, čime se optimizuje navodnjavanje i smanjuje potrošnja vode. Ovi senzori su posebno korisni u sušnim područjima, gdje je voda ograničen resurs i gdje precizno upravljanje vodom može značajno povećati produktivnost i održivost poljoprivrednih sistema (Jones, 2004).

Senzori za monitoring usjeva omogućavaju poljoprivrednicima da prate zdravlje biljaka, identifikuju bolesti i štetočine, te prate rast usjeva u različitim fazama razvoja. Ovi senzori mogu prikupljati podatke o spektralnim karakteristikama biljaka, što omogućava precizno praćenje stanja usjeva i identifikaciju problema prije nego što postanu ozbiljni. Na primjer, senzori koji prate sadržaj hlorofila u listovima mogu ukazati na nedostatak hranjivih tvari ili prisutnost bolesti, omogućavajući poljoprivrednicima da pravovremeno reaguju (Baret & Guyot, 1991).

Korištenje senzora omogućava poljoprivrednicima da smanje upotrebu FFS i gnojiva, povećaju efikasnost resursa, te poboljšaju kvalitetu i prinos usjeva. Ovi senzori također omogućavaju bolje upravljanje rizicima u poljoprivredi, jer poljoprivrednici mogu brzo reagirati na promjene u stanju tla i usjeva, čime se smanjuju gubici i povećava produktivnost (Hatfield & Prueger, 2010).

Tipovi i princip rada senzora

Senzori pretvaraju mjerenu fizikalnu veličinu u analognu električnu (struja, napon, otpor) ili digitalnu veličinu. Senzori rade na osnovu njihove interakcije sa procesorom i to tako što reagiraju na stanja, a reakciju transformiraju u izlazni signal. Nosač informacije je masa ili energija. Mjerenje neelektričnih signala počinje pretvaranjem u električni pa se onda obavlja procesiranje uz fizikalne efekte koji omogućavaju takvu konverziju. Većina mjernih pretvarača sastoji se od tri osnovna dijela: izvor informacija ili senzor, mjernog sistema ili procesora i podsistema za predstavljanje informacija ili displeja. U poljoprivredi, senzori se koriste za poboljšanje učinkovitosti i preciznosti različitih operacija, omogućavajući detaljno praćenje usjeva i optimizaciju resursa. Među najzastupljenijim tipovima senzora su elektromagnetski, induktivni, fotoelektrični, kapacitativni, termoelektrični, ultrazvučni i optički - LIDAR senzori, svaki sa svojim specifičnim principom rada i primjenom.

Elektromagnetski senzori se koriste za detekciju metalnih objekata u zemljištu, kao što su kamenje ili metalni otpad, koji mogu oštetiti poljoprivredne mašine. Njihova primjena u kombinaciji s GPS tehnologijom može unaprijediti preciznost poljoprivrednih operacija. Induktivni senzori su korisni za mjerenje brzine vrtnje i položaja pokretnih dijelova poljoprivrednih mašina. Unapređenje može uključivati integraciju s IoT (*Internet of Things*) tehnologijom za prikupljanje i analizu podataka u realnom vremenu.

Fotoelektrični senzori koriste se za detekciju prisutnosti biljaka ili drugih objekata. Mogu se unaprijediti tako da prepoznaju specifične karakteristike biljaka, poput boje ili veličine, što bi omogućilo precizniju aplikaciju FFS ili gnojiva.

Kapacitativni senzori su idealni za mjerenje vlažnosti tla. Ovi senzori su visoke osjetljivosti za preciznije praćenje promjena u vlažnosti tla na mikro nivoima, što doprinosi optimizaciji navodnjavanja.

Termoelektrični senzori su za praćenje temperaturnih uslova unutar staklenika ili na otvorenom polju. Ovi senzori se povezuju s automatiziranim sistemima grijanja i hlađenja za održavanje optimalnih uvjeta rasta biljaka.

Ultrazvučni senzori se koriste za detekciju udaljenosti između mašina i biljaka ili prepreka. Ovi uređaji se ugrađuju u autonomnim vozilima za preciznu navigaciju na poljima.

Optički - LIDAR senzori se upotrebljavaju za mapiranje terena i praćenje visine, gustine i oblika biljaka. Upotrebljavaju se u dronovima za detaljnije praćenje stanja usjeva i predviđanje prinosa, a također se primjenjuju u atomizerima i nekim drugim poljoprivrednim mašinama.

Pametni senzori za ispitivanje svojstava tla

Senzori i sonde za ispitivanje tla postaju neizostavni alati u pametnoj poljoprivredi, posebno u kontekstu precizne poljoprivrede, gdje je cilj optimizirati upotrebu resursa i povećati prinose. Različiti senzori koriste se za mjerenje ključnih parametara tla, poput vlage, temperature, pH vrijednosti i induktivnosti tla. Među najznačajnijim rješenjima u ovom području su mobilne senzorske platforme (MSP) napravljene kao drljača, koje omogućuje dinamično ispitivanje tla na terenu.



Slika 87. Senzori Veris MSP3 platforme omogućava mapiranje tri svojstva tla u jednom prolazu (Izvor: <https://www.youtube.com/watch?v=ND-gPCux3DY&t=34s>).

Primjer jednog takvog uređaja je mobilna senzorska platforma MSP3 od *Veris Technologies* (slika 87). Ova mobilna senzorska platforma dizajnirana je kao tanjirača koja se vuče preko polja, obično u kombinaciji s drugim priključnim mašinama, poput sijačica. MSP3 mjeri tri ključna parametra tla: induktivnost, pH vrijednost i organsku materiju. MSP3 se sastoji od nekoliko ključnih dijelova:

- Elektrode (*Coulter*) koje omogućuju mjerenje električne vodljivosti tla na tri različite dubine, što pomaže u određivanju teksture tla, vlažnosti i sadržaja organske materije.
- pH senzor koristi posebnu „papuču“ koja se aktivira hidrauličkim cilindrom kako bi uzela uzorke tla za mjerenje pH vrijednosti. Za tačno mjerenje pH vrijednosti tla, uređaj je opremljen sistemom za automatsko pranje elektroda, čime se osigurava preciznost i ponovljivost rezultata.
- Infracrveni optički senzor: Ovaj senzor koristi infracrvenu tehnologiju za mjerenje razine azota i vlažnosti tla. Ovi parametri su ključni za donošenje odluka o gnojidbi i navodnjavanju.
- Vanjska upravljačka jedinica: Ova jedinica omogućuje operateru da u realnom vremenu prati i upravlja svim funkcijama MSP3, dok se podaci prikupljeni s terena automatski sinhroniziraju s centralnim sistemom putem *FieldFusion* softvera.

MSP3 i slične platforme primjenjuju se u različitim fazama poljoprivredne proizvodnje, od pripreme tla, preko sjetve, do gnojidbe. Na temelju podataka prikupljenih ovim uređajima, poljoprivrednici mogu precizno planirati kalcifikaciju tla, prilagoditi gnojidbene režime te optimizirati sjetvene obrasce. Ovaj način rada omogućuje ciljanje specifičnih područja unutar polja koja zahtijevaju dodatnu pažnju, čime se smanjuje potreba za uniformnim tretmanima, koji često rezultiraju prekomjernom upotrebom resursa.

Pametne mobilne senzorske platforme poput Veris MSP3 predstavljaju značajan iskorak u primjeni tehnologije za ispitivanje tla u poljoprivredi. Ove tehnologije ne samo da pružaju detaljan uvid u stanje tla, nego omogućuju i preciznu prilagodbu agronomskih praksi, što je ključno za

održivu i profitabilnu poljoprivrednu proizvodnju. Korištenje ovakvih senzorskih sistema pomaže u povećanju efikasnosti resursa, smanjenju negativnog utjecaja na okoliš i optimizaciji proizvodnih procesa.

Automatizacija u oranju, sjetvi, gnojdbi i navodnjavanju

Jedan od ključnih aspekata pametne poljoprivrede je automatizacija poljoprivrednih operacija, uključujući sjetvu, gnojidbu i navodnjavanje. Automatizacija omogućava poljoprivrednicima da precizno upravljaju ovim operacijama, smanjujući troškove rada i poboljšavajući efikasnost.

Oranje

Automatizacija oranja predstavlja budućnost poljoprivrede, omogućavajući poljoprivrednicima da povećaju prinos, smanje troškove i očuvaju prirodne resurse. Precizno oranje koristi GPS tehnologiju kako bi se osigurala tačna kontrola putanje traktora i dubine oranja. GPS sistemi omogućavaju traktoru da prati unaprijed određene linije sa visokom preciznošću, što rezultira ravnim brazdama i jednoličnom obradom tla. Pametno oranje ide korak dalje od preciznog oranja, koristeći dodatne senzore, softvere i automatizovane sisteme za prikupljanje podataka i donošenje odluka u realnom vremenu. Ova tehnologija omogućava prilagođavanje operacija u zavisnosti od uslova na terenu, optimizujući rezultate i smanjujući troškove.



Slika 88. Postepeno, pojedinačno i ravnomjerno zabražđavanje plužnih tijela

(Izvor: <https://www.youtube.com/watch?v=fH-xHlsS2I4>)

Iako se sama tehnika oranja malo mijenjala kroz stoljeća, pametna poljoprivreda donijela je značajne inovacije, posebno u kontekstu precizne poljoprivrede. U tom smislu, “oranje izvan brazde” tzv. “*ON-LAND*” oranje, gdje traktor ostaje na neuzoranom dijelu tla, predstavlja ključnu evoluciju koja donosi brojne prednosti za poljoprivrednike.

Jedna od glavnih prednosti oranja izvan brazde je ravnomjerna raspodjela težine traktora na lijevim i desnim točkovima. To omogućuje da traktor zadrži stabilnost i optimalnu vučnu silu, čime se povećava ukupna učinkovitost oranja (slika 89). S obzirom na to da točkovi traktora ostaju na

neuzoranom tlu, izbjegava se sabijanje već preoranog tla, što je ključno za očuvanje njegove strukture i plodnosti. Time se osigurava ravnomjernija obrada cijele parcele, što je od posebne važnosti u osjetljivim usjevima poput povrća.

Oranje izvan brazde omogućuje korištenje traktora s širokim gumama, koje inače ne bi bile pogodne za tradicionalno oranje zbog povećanog pritiska na tlo. Ova tehnologija omogućuje poljoprivrednicima da iskoriste sve prednosti šireg gazišta, uključujući smanjenje sabijanja tla i povećanu stabilnost traktora. Također, traktori s duplim točkovima mogu se koristiti bez potrebe za stalnim podešavanjem i skidanjem točkova, što štedi vrijeme i povećava efikasnost na terenu.



Slika 89. Oranje izvan brazde - *On land* oranje

(Izvor: <https://www.youtube.com/watch?v=VNCEcBuG7gE>).

Korištenje oranja izvan brazde zahtijeva visoku razinu tačnosti pozicioniranja, koja se postiže automatskim upravljanjem traktora uz pomoć GPS tehnologije. GPS sistem, u kombinaciji s baznim stanicama za korekciju satelitskog signala, omogućuje iznimno preciznu kontrolu položaja i radnog zahvata pluga. Ovo rezultira idealno ravnim brazdama, što je ključno za osiguranje ravnomjernih uvjeta nicanja i rasta usjeva. Oranje izvan brazde doprinosi postizanju visokih prinosa i povećava ukupnu učinkovitost poljoprivredne proizvodnje, posebno u intenzivnoj ratarsko-povrtnarskoj proizvodnji.

Sve ove prednosti čine oranje izvan brazde ne samo efikasnijim, već i ekološki prihvatljivijim, jer smanjuje sabijanje tla i osigurava bolju obradu poljoprivrednih površina. Moderni plugovi, opremljeni senzorima za kontrolu dubine oranja i GPS navođenjem, omogućuju poljoprivrednicima da postignu vrhunske rezultate u različitim uvjetima tla i klimatskim situacijama, čime se osigurava održiva i produktivna poljoprivreda.

Sjetva

Automatizacija sjetve uključuje upotrebu traktora i sijačica opremljenih GPS tehnologijom i senzorima, što omogućava izuzetno precizno postavljanje sjemena na odgovarajuću dubinu i razmak. Ovi sistemi omogućavaju ravnomjerno raspored sjemena po površini, smanjujući nepotrebna preklapanja i prazna mjesta, čime se optimizira korištenje resursa i povećava prinos. Također, automatski sistemi prilagođavaju brzinu i dubinu sjetve prema uvjetima tla, što dodatno doprinosi efikasnosti rada i prilagođava proces specifičnim potrebama svake parcele.

Precizna sjetva podrazumijeva prilagođavanje sjetve specifičnim uslovima svakog dijela polja. Ova tehnika se oslanja na detaljnu analizu tla, vremenskih uslova, i drugih faktora kako bi se sjeme posijalo na optimalnoj dubini, na odgovarajućim razmacima, i na najboljim mjestima. Prednosti precizne sjetve su povećani prinosi, smanjenje troškova i smanjen negativan uticaj na okolinu.

Pametna sjetva je naprednija verzija precizne sjetve koja koristi dodatne tehnologije za automatizaciju i daljinsko praćenje procesa sjetve. Ova tehnika koristi senzore, IoT uređaje, dronove, i softverske alate za analizu podataka u realnom vremenu. Prednosti pametne sjetve su automatizacija, daljinsko upravljanje, bolja analiza i planiranje. Oprema neophodna za sprovođenje precizne i pametne sjetve je:

- GPS navigacija, odnosno prijemnici koji se koriste se za tačno pozicioniranje sijačica na polju, omogućavajući ravnomjernu sjetvu i izbjegavanje preklapanja ili praznina.
- Pametne sijačice opremljene senzorima i aktuatorima mogu automatski prilagoditi dubinu sjetve i gustoću sjemena u realnom vremenu, u skladu s uvjetima tla i prethodnim analizama.
- Senzori za mjerenje vlažnosti, temperature, pH i drugih karakteristika tla omogućavaju prikupljanje podataka o stanju tla, što je ključno za donošenje odluka o sjetvi.
- Softver za upravljanje poljem, kao npr. GIS i drugi softverski alati za planiranje i praćenje sjetve omogućavaju poljoprivrednicima da analiziraju podatke o tlu, vremenskim uvjetima, i stanju usjeva, te optimiziraju sjetvu prema tim podacima.
- IoT ili drugi komunikacijski sistemi i uređaji povezuju senzore, sijačice, dronove i druge uređaje, omogućavajući razmjenu podataka u realnom vremenu i daljinsko upravljanje operacijama.
- Bespilotne letjelice ili dronovi koji se koriste za snimanje i praćenje polja iz zraka, pomažu i omogućavaju brzu identifikaciju problema i prilagođavanje sjetve u skladu s trenutnim uslovima.

Gnojidba

Automatizacija gnojidbe uključuje korištenje tehnologija kao što su promjenjiva doza gnojidbe (*Variable Rate Technology - VRT*), koja omogućava prilagođavanje količine gnojiva prema specifičnim potrebama različitih dijelova polja. Ova tehnologija koristi podatke prikupljene od senzora i GIS sistema za identifikaciju varijabilnosti unutar polja, te primjenu gnojiva samo na mjestima gdje je to potrebno. Na taj način, smanjuje se prekomjerna upotreba gnojiva, smanjuje zagađenje okoliša i povećava efikasnost resursa (Bongiovanni & Lowenberg-DeBoer, 2004).

Tehnologija promjenjive doze gnojidbe (VRT) oslanja se na podatke prikupljene putem različitih senzora i GPS tehnologije, kako bi se optimizirala primjena gnojiva, smanjili troškovi, i povećala efikasnost u poljoprivrednoj proizvodnji. Ključni dijelovi za rad VRT sistema su senzori tla i usjeva, GPS sistem, karta prinosa, softver za planiranje i VRT aplikatori. Prednosti VRT gnojidbe su povećana efikasnost, smanjeni troškovi, očuvanje okoliša, poboljšani prinosi i bolja kontrola.

Primjena VRT tehnologije u gnojidbi zahtijeva ulaganje u odgovarajuću opremu i softver, ali dugoročne prednosti u smislu smanjenja troškova i povećanja prinosa čine ovu tehnologiju vrijednom investicijom za poljoprivrednike. Precizna gnojidba uz korištenje VRT omogućava prilagodbu količine gnojiva u skladu s potrebama različitih dijelova poljoprivrednog zemljišta. Ovaj pristup oslanja se na podatke prikupljene putem različitih senzora i GPS tehnologije, kako bi se optimizirala primjena gnojiva, smanjili troškovi i povećala efikasnost u poljoprivrednoj proizvodnji.

Automatsko navodnjavanje

Automatizacija navodnjavanja igra ključnu ulogu u pametnoj poljoprivredi, omogućavajući poljoprivrednicima da precizno kontrolišu količinu i vrijeme primjene vode. Korištenjem automatskih sistema, poput kap po kap tehnologije s ugrađenim senzorima za vlažnost tla, omogućava se optimalno prilagođavanje količine vode specifičnim potrebama biljaka. Ovi napredni sistemi značajno smanjuju potrošnju vode u poređenju s tradicionalnim metodama, dok istovremeno doprinose većim prinosima, osiguravajući efikasniju upotrebu resursa i održivost proizvodnje.

Automatizacija u preciznoj poljoprivredi značajno poboljšava efikasnost resursa, smanjuje troškove rada i povećava ekonomsku održivost poljoprivrednih sistema. Omogućava poljoprivrednicima da upravljaju većim površinama s manje radne snage, što je posebno važno u područjima sa ograničenom radnom snagom.

Automatski sistem navodnjavanja dizajniran je da efikasno kontroliše protok vode uz minimalnu ljudsku intervenciju. Ključne komponente uključuju senzore vlažnosti tla, elektroventile, kontrolnu jedinicu, pumpu za vodu, cjevovode i filtere.

Senzori vlažnosti tla prate nivo vlažnosti i omogućavaju automatsko pokretanje ili zaustavljanje navodnjavanja kada vlažnost padne ispod ili dostigne određeni prag. Elektroventili kontrolišu protok vode, otvarajući ili zatvarajući se automatski na osnovu podataka koje dobivaju od senzora i uputa kontrolne jedinice. Kontrolna jedinica, kao centralni element sistema, upravlja radom pumpi, ventila i rasporedom navodnjavanja prema unaprijed postavljenim parametrima.

Pumpa za vodu osigurava pritisak potreban za distribuciju vode kroz cjevovode, dok cjevovodi prenose vodu od izvora do različitih dijelova zemljišta. Na krajevima cjevovoda postavljene su kapajuće linije ili prskalice, koje ispuštaju vodu direktno u tlo, omogućavajući precizno i kontrolisano navodnjavanje. Filter za vodu osigurava čistoću sistema, sprečavajući ulazak nečistoća koje bi mogle ometati rad ventila i prskalica.


Ovaj sistem omogućava optimalno korištenje vode, smanjujući potrošnju i istovremeno poboljšavajući prinos, jer se količina vode prilagođava stvarnim potrebama biljaka u realnom vremenu.

Mehanizacija u pametnoj zaštiti bilja

U pametnoj poljoprivredi pri primjeni FFS važno je znati procijeniti usjev i odrediti granicu modeliranja terena. Kako bi podaci bili tačni pri radu na polju, svaki uređaj za preciznu poljoprivredu (aplikaciju FFS-a), mora imati ugrađene mjerne senzore koji isporučuju informacije o željenom parametru. Senzorski pristup samostalno raspoznaje aktuelnu situaciju. Ovaj pristup se u praksi primjenjuje kod suzbijanja korova na poljoprivrednim površinama. Jedna od vrsta senzora radi u infracrvenom dijelu spektra, a postavlja se na traktor ili na samohodnu mašinu kojom se vrši zaštita bilja, te svo vrijeme kretanja traktora snima se usjev. Od biljke senzor prima reflektovani dio svjetla i na taj način detektuje prisustvo biljke i stanje (vegetacijski indeks). U zavisnosti od intenziteta boje biljke, direktno komunicira s upravljačkom jedinicom i tako mijenja dozu aplikacije. Na taj način određene zone polja dobiti će veću, a neke manju količinu FFS pri čemu se želi postići ujednačeni kvalitet raspodjele FFS na polju. Pametne i precizne prskalice za ratarske usjeve predstavljaju ključni alat u modernoj poljoprivredi, omogućavajući efikasno korištenje herbicida, insekticida i fungicida uz minimalan utrošak resursa i maksimalnu zaštitu biljaka. Jedan od primjera napredne prskalice

je *John Deere R4038*, koja koristi brojne senzore i tehnologije za precizno prskanje. Ključne komponente pametne prskalice su senzori za detekciju korova, senzori za vlagu i temperaturu, senzori za protok, sistem za kontrolu sekcija, GPS i RTK (*Real-Time Kinematic*) sistem.

Pametne prskalice mogu biti opremljene optičkim sensorima za prepoznavanje korova kao na slici 90 (npr. sistem *See & Spray*). Ovi senzori skeniraju površinu tla i biljaka, razlikujući korov od usjeva na osnovu spektralnih karakteristika. Na osnovu podataka prikupljenih u realnom vremenu, prskalice primjenjuje herbicid samo na mjesta gdje je detektovan korov, čime se smanjuje upotreba FFS.



Slika 90. Senzori na pametnoj prskalici (Izvor: https://www.youtube.com/watch?v=noLu_xwfgXY)

Senzori za vlagu i temperaturu mjere uslove okoline poput vlažnosti i temperature zraka i tla, što omogućava prskalici da prilagodi dozu FFS prema trenutnim uvjetima. Na primjer, u vlažnim uvjetima biljke mogu lakše upiti aktivne supstance, što omogućava smanjenje doze FFS.

Senzori za protok (*Flow Sensors*), prate protok tečnosti kroz dizne, osiguravajući da prskalice ravnomjerno primjenjuje tekućinu na cijeloj površini. Ako senzor detektuje promjenu u protoku, sistem automatski prilagođava rad prskalice kako bi osigurao optimalnu aplikaciju.

Sistem za kontrolu sekcija (*Section Control*) automatski isključuje sekcije prskalice na mjestima gdje je aplikacija već obavljena, čime se sprječava preklapanje i nepotrebna primjena hemikalija. Ova funkcija omogućava uštedu sredstva i smanjuje negativan uticaj na okolinu.

Prskalice koriste GPS i RTK sistem za precizno pozicioniranje. Ovi sistemi osiguravaju da se prskanje obavlja precizno na ciljanim područjima, čime se smanjuje rasipanje i optimizira upotreba hemikalija. GPS također pomaže prskalici u vođenju po parceli, prateći prethodne aplikacije i izbjegavajući dupliranje tretmana.

Pametna prskalica je povezana sa traktorom putem *ISOBUS* tehnologije. Kroz *ISOBUS*, prskalica komunicira sa traktorom i njegovim GPS sistemom, što omogućava sinhronizaciju između kretanja traktora i rada prskalice. Monitor u kabini traktora prikazuje operateru sve ključne podatke u realnom vremenu, uključujući rad prskalice, protok tekućine, stanje dizni, kao i informacije o prethodno tretiranim dijelovima parcele.

Autonomni sistemi i robotika

Jedan od najvažnijih napredaka u poljoprivrednoj mehanizaciji je uvođenje autonomnih traktora i robota. Ove tehnologije donose revolucionarne promjene u efikasnosti rada, smanjujući potrebu za ljudskom radnom snagom. Autonomni traktori i kombajni opremljeni su GPS-om, senzorima i naprednim algoritmima koji omogućavaju obavljanje poslova poput obrade tla, sjetve i žetve bez stalnog ljudskog nadzora. Korištenje ovih tehnologija omogućava preciznije upravljanje poljoprivrednim površinama i smanjuje operativne troškove, što je od velike koristi, posebno za veće farme i komercijalne proizvođače.

S druge strane, robotski sistemi namijenjeni specifičnim zadacima, poput rezidbe voćaka, berbe plodova i primjene FFS, postaju sve sofisticiraniji. Robotski sistemi za berbu voća sada koriste napredne senzore za prepoznavanje zrelih plodova, dok mehaničke ruke obavljaju samu berbu. Ova tehnologija ne samo da povećava efikasnost, već i smanjuje gubitke. Takođe, ovi robotski sistemi omogućavaju preciznu primjenu FFS i gnojiva, što doprinosi smanjenju upotrebe hemikalija i poboljšanju održivosti proizvodnje. Robotske mašine koriste napredne senzore, kamere i algoritme za precizno obavljanje svojih zadataka, čime se smanjuje potreba za ljudskom radnom snagom i povećava ukupna efikasnost procesa.

Roboti za berbu voća koriste napredne vizualne senzore kako bi prepoznali zrele plodove i pažljivo ih ubrali bez oštećenja, čime se povećava kvalitet i kvantitet plodova. Ovi sistemi postaju sve napredniji, a tehnologije poput mašinskog učenja i umjetne inteligencije omogućavaju robotima da prepoznaju plodove na osnovu boje, oblika i veličine. Pored toga, senzori mogu analizirati i stanje biljaka, omogućavajući optimalno vrijeme berbe. Inženjeri se fokusiraju na razvoj robota koji mogu brati voće s većom nježnošću i prilagoditi se različitim vrstama usjeva, kako bi smanjili ovisnost o ljudskoj radnoj snazi i povećali održivost voćarstva.

Internet stvari i umjetna inteligencija

Četvrta industrijska revolucija, poznata kao Industrija 4.0, donosi revolucionarne promjene u industrijske i proizvodne prakse kroz primjenu naprednih pametnih tehnologija. U poljoprivredi, ove promjene su se odrazile kroz sve veću integraciju tehnologija koje omogućavaju preciznije i efikasnije upravljanje. Tehnologije kao što su Internet stvari (IoT), računarstvo u oblaku (*CC – Cloud Computing*), daljinsko istraživanje (*RS – Remote Sensing*), mašinsko učenje (*ML – Machine Learning*), umjetna inteligencija (*AI – Artificial Intelligence*), bespilotne letjelice (*UAV – Unmanned Aerial Vehicles*) i analiza velikih podataka (*BDA – Big Data Analytics*) moderniziraju tradicionalne metode u poljoprivredi. Moderni poljoprivrednici teže povećanju proizvodnje hrane uz optimizaciju troškova i smanjenje uticaja na životnu sredinu. IoT, na primjer, otvara brojne mogućnosti za unapređenje sektora poljoprivrede, omogućavajući razvoj tehnika precizne i pametne poljoprivrede.

Senzori za praćenje vlage u tlu igraju ključnu ulogu u modernom upravljanju navodnjavanjem, jer omogućavaju precizno regulisanje količine vode koja se koristi. Ovi senzori prikupljaju podatke koji se zatim prenose u oblak, čime postaju dostupni putem interneta za daljnju analizu i upravljanje. Tehnologije IoT omogućavaju povezivanje različitih sistema unutar poljoprivrednog sektora, što omogućava integrirano upravljanje farmama. Ova povezanost unapređuje procese donošenja odluka, poboljšavajući ukupnu efikasnost i održivost poljoprivrednih operacija.

IoT omogućava integraciju različitih tehnologija i sistema u poljoprivredi. IoT senzori ugrađeni u poljoprivrednu mehanizaciju omogućavaju prikupljanje i razmjenu podataka u realnom vremenu, što omogućava precizno upravljanje resursima. Na primjer, IoT senzori mogu pratiti vlagu u tlu, temperaturne uvjete i stanje usjeva, te automatski prilagoditi navodnjavanje i primjenu hranjiva prema potrebama usjeva (Verdouw *et al.*, 2016).

Umjetna inteligencija (AI) također igra ključnu ulogu u budućnosti poljoprivredne mehanizacije. AI se koristi za razvoj algoritama koji mogu analizirati velike količine podataka prikupljenih od senzora i dronova, omogućavajući poljoprivrednicima donošenje informiranih odluka. Na primjer, AI može analizirati slike usjeva za rano otkrivanje bolesti i štetočina, predložiti optimalne prakse za gnojidbu i navodnjavanje, te unaprijediti strategije upravljanja usjevima (Liakos *et al.*, 2018).

Budućnost pametne mehanizacije u poljoprivredi obećava značajne promjene koje će unaprijediti efikasnost, održivost i produktivnost u sektoru. Razvoj autonomnih sistema, naprednih senzora, i održivih tehnologija predstavlja ključne trendove koji će oblikovati budućnost poljoprivredne mehanizacije. S obzirom na rastuće globalne potrebe za hranom i potrebu za očuvanjem okoliša, ove inovacije će igrati ključnu ulogu u ispunjavanju tih izazova i omogućiti održivu poljoprivredu.

Napredne tehnike mehanizacije u poljoprivredi su se u posljednjim desetljećima dramatično razvile, a budućnost obećava još brže promjene koje će oblikovati sektor poljoprivrede. Ovaj razvoj vođen je inovacijama u robotici, AI i IoT, kao i potrebom za održivijim praksama u poljoprivredi.

Održiva i energetski efikasna mehanizacija

S obzirom na rastuće globalne izazove u oblasti zaštite okoliša i održivosti, budućnost poljoprivredne mehanizacije sve više se usmjerava ka razvoju energetski efikasnih i ekološki prihvatljivih tehnologija. Električni traktori i oprema predstavljaju značajan napredak u smanjenju emisije stakleničkih plinova i smanjenju zavisnosti od fosilnih goriva. Ovi traktori koriste baterije i elektromotore za obavljanje različitih poljoprivrednih zadataka, čime se značajno smanjuje ugljični otisak u sektoru. Prelazak na električne sisteme ne samo da smanjuje negativan uticaj na okoliš, već i poboljšava efikasnost i održivost poljoprivrednih operacija.

Osim toga, razvoj tehnologija za reciklažu organskih materijala i proizvodnju biogoriva iz poljoprivrednih ostataka dodatno doprinosi smanjenju ekološkog uticaja poljoprivredne proizvodnje. Ove tehnologije omogućavaju efikasno upravljanje otpadom i stvaraju održive izvore energije za različite poljoprivredne aktivnosti. Upotreba biogoriva i recikliranih materijala pomaže poljoprivrednom sektoru da značajno smanji svoj ekološki otisak i unaprijedi održivost svojih procesa.

Razvoj održivih praksi u poljoprivredi postaje ključan u kontekstu globalnih izazova vezanih za zaštitu okoliša i klimatske promjene. Pametna mehanizacija koristi tehnologije koje smanjuju negativan uticaj na okoliš, poboljšavaju efikasnost resursa i podržavaju očuvanje biodiverziteta. Električni traktori, koji koriste baterije i elektromotore umjesto fosilnih goriva, značajno smanjuju emisije CO₂ i drugih zagađivača.

S obzirom na značajne napretke, postoje i brojni izazovi i prilike za budući razvoj napredne poljoprivredne mehanizacije. Visoki troškovi novih tehnologija mogu predstavljati prepreku za mnoge male i srednje poljoprivrednike, što može uzrokovati razlike u pristupu između velikih komercijalnih i manjih obiteljskih farmi. Također, potreba za obukom i obrazovanjem poljoprivrednika za učinkovito korištenje novih tehnologija može biti izazov, budući da implementacija složenih sistema zahtijeva razumijevanje i interpretaciju podataka.

S druge strane, razvoj pristupačnih i interoperabilnih tehnologija pruža značajne prilike za istraživanje i inovacije. Ove prilike mogu pomoći u smanjenju troškova i omogućiti široku primjenu napredne mehanizacije u poljoprivredi.

LITERATURA:

- 1) Altieri, M. A. (1995). *Agroecology: The Science of Sustainable Agriculture*. CRC Press.
- 2) Baret, F., & Guyot, G. (1991). Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35(2-3), 161-173.
- 3) Bongiovanni, R., & Lowenberg-DeBoer, J. (2004). Precision agriculture and sustainability. *Precision Agriculture*, 5(4), 359-387.
- 4) Gebbers, R., & Adamchuk, V. I. (2010). Precision agriculture and food security. *Science*, 327(5967), 828-831.
- 5) Hatfield, J. L., & Prueger, J. H. (2010). Value of using different vegetative indices to quantify agricultural crop characteristics at different growth stages under varying management practices. *Remote Sensing*, 2(2), 562-578.
- 6) Jones, H. G. (2004). Irrigation scheduling: advantages and pitfalls of plant-based methods. *Journal of Experimental Botany*, Vol. 55, No. 407, Water-Saving Agriculture Special Issue, pp. 2427–2436, doi:10.1093/jxb/erh213
- 7) Lal, R. (2004). Soil carbon sequestration impacts on global climate change and food security. *Science*, 304(5677), 1623-1627.
- 8) Liakos, K. G., & Busato, P. (2018). Artificial Intelligence in Agriculture: A Review. *Computers and Electronics in Agriculture*, 146, 275-283.
- 9) McBratney, A. B., Whelan, B. M., Ancev, T., & Bouma, J. (2005). Future directions of precision agriculture. *Precision Agriculture*, 6(1), 7-23.
- 10) Verdouw, C., Wolfert, S., & Tekinerdogan, B. (2016). Internet of Things in agriculture. *CABI Reviews*, 11, 1-12. <https://doi.org/10.1079/PAVSNNR201611035>.

KORISTI OD PRIMJENE SAVREMENIH TEHNOLOGIJA U AGROBIZNISU

Alen Mujčinović

Poljoprivredno-prehrambeni sistem se suočava sa brojnim izazovima, turbulentnim okruženjem, te je nerijetko okarakterisan kao neodrživ (Reisch *et al.*, 2013; Forssell & Lankoski, 2015). Trenutačni visoko globalizirani poljoprivredno-prehrambeni sistem je neodrživ i prepoznat je kao odgovoran za kontinuirano onečišćenje zraka, zemlje i vode (Sun *et al.*, 2017; Farmery *et al.*, 2021), odnosno s velikim negativnim uticajem na okoliš. Ovaj sistem odgovoran je za 70 do 90% potrošnje vode (Richter & Bokelmann, 2016; Charania & Li, 2020), 25% emisije GHG-a (staklenički plinovi) (Sun *et al.*, 2017) i 75% globalne emisije amonijaka uglavnom od upotrebe gnojiva i životinjskog otpada (Sun *et al.*, 2017). Prema posljednjim procjenama, emisije stakleničkih plinova iz poljoprivredno-prehrambenog sistema će se povećati za 15 do 20% do 2050. godine (WEF, 2020). Takvi neodrživi obrasci proizvodnje hrane odgovorni su za 70% smanjenja biodiverziteta (Lezoche *et al.*, 2020) i gubitaka od 10 do 15 miliona hektara obradivog zemljišta godišnje, gnojidbom, pesticidima, krčenjem šuma (WEF, 2018; 2020; 2022). Osim toga, više od 30% hrane baca se u cijelom lancu vrijednosti hrane, dosežući 179 do 290 kg po stanovniku godišnje u razvijenim zemljama (Annosi *et al.*, 2021), te se očekuje povećanje stvaranja otpada od hrane (Richter & Bokelmann, 2016). Istovremeno, 812 miliona ljudi suočava se s nedostatkom hrane (Smitha & Floro, 2020; WEF, 2020). Različite vrste neizvjesnosti (vremenski uslovi, ponuda i potražnja, promjene u ponašanju potrošača) pokreću prekomjernu upotrebu poljoprivrednih inputa i prekomjernu proizvodnju hrane oblikujući stalni porast stvaranja otpada od hrane (Richter i Bokelmannu, 2016). Istodobno, postoji rastuća potreba za povećanjem proizvodnje kako bi se prehranilo stalno rastuće stanovništvo koje će 2050. godine dosegnuti 9,8 milijardi (Charania & Li, 2020). Takav rast stanovništva zahtijevat će najmanje 60% do 90% povećanja proizvodnje hrane (Richter & Bokelmann, 2016; Sun *et al.*, 2017), dok se u isto vrijeme poljoprivredno-prehrambeni sistem suočava s dva negativna trenda, starenja ruralnog stanovništva i nedostatka radne snage u ruralnim područjima na globalnoj razini. Navedeno iziskuje različite napore, a uzme li se u obzir kako je sa izražajnijim rastom stanovništva došlo i do rapidnog smanjenja prirodnih površina (a nerijetko i poljoprivrednih) na uštrb urbanih zona, tako je i uloga i odgovornost poljoprivrednog i prehrambenog sistema još veća.


U svjetlu migracija stanovništva iz ruralnih u urbane zone, te porast u broju multimilionskih gradova, praćen je snažnim rastom potražnje potrebe za standardizovanim (industrijskim) proizvodima (težnjom za postizanje ekonomije obima, većom produktivnosti, jeftinijom i dostupnijom hranom), a time i dominacijom vertikalno integrisanih kompanija (lanaca snabdijevanja) (kompanije koje upravljaju sa više drugih kompanija), a za konsekvence ima brojne negativne ekonomske, socijalne i okolišne posljedice poput: marginalizacije, nejednakosti, nepovoljnog položaja i pregovaračke moći malih i srednjih gazdinstava/kompanija, nejednakom distribucijom prihoda, tržišnim barijerama itd.

Kao što se može primjetiti, poljoprivredno-prehrambeni sistem prolazi kroz sporu transformaciju, a sa ciljem umanjenja gore navedenih negativnih efektata, te postizanja balansa između sigurnosti i kvaliteta hrane sa ukupnom održivošću lanca, unapređenja produktivnosti sektora i u konačnici ponuditi atraktivnija radna mjesta. U navedenom procesu, neophodno je da učešće uzmu svi akteri u poljoprivredno-prehrambenom sektoru, od primarnih proizvođača, prerađivača, distributera, proizvođača inputa, kupaca, ali i NVO sektora, stručne/poslovne/istraživačke zajednica i vlade. Trenutno to nije slučaj, jer je svijest o promjenama koje se odvijaju u agrobiznisu još uvijek niska, što pridonosi složenosti postojećih problema, te sporijoj transformaciji sistema. Upravo radi navedenog

cilj ovog poglavlja je (i) *podcrtati ulogu savremenih tehnologija u poljoprivrednoj proizvodnji*, odnosno ukazati na brojne koristi koje mogu proistći od primjene široke palete „pametnih/SMART“ tehnologija, te (ii) *podcrtati ograničavajuće i stimulirajuće faktore* u procesu primjene inovacija u poljoprivrednom sektoru. Navedenim se nastoji podići nivo svjesnosti o potencijalnim koristima koje mogu nastati od primjene savremenih tehnologija u agrobiznisu i ubrzati primjenu istih.


Uloga poljoprivredno-prehrambenog lanca snabdijevanja

Poljoprivredno-prehrambeni lanac snabdijevanja se definira kao sve aktivnosti neophodne da bi se proizveo finalni proizvod/usluga prema zahtjevima potrošača, a kompleksnost interakcija determinišu ovaj lanac kao najkompleksniji i najvažniji za funkcionisanje cjelokupnog društva (Grunert, 2005; Van der Spiegel *et al.*, 2005; Luning & Willem, 2007). Poljoprivreda je složen i nepredvidiv posao (Farmery *et al.*, 2021), a pred poljoprivrednim proizvođačima se nalazi mnoštvo izazova, od onih koje se tiču izraženih klimatskih promjena, očekivanja donosioca odluka, potrošača, prerađivača, trgovaca, do onih problema koji se tiču erozije tla, gubitka biodiverziteta, promjena ukusa potrošača itd. Resursi, procesi, aktivnosti, akteri unutar prehrambenog lanca snabdijevanja su brojni, a njihove interakcije sistem čine najkompleksnijim jer se odvijaju u mnogim fazama, na mnogim lokacijama, inkorporiraju protok znanja, podataka i informacija, te dobra koja dolaze iz poljoprivrede, šumarstva i ribarstva (Tefft *et al.*, 2017; Tijan *et al.*, 2019; Mausch *et al.*, 2020) (slika 91). Upravo radi navedenog, usvajanje najboljih praksi zavisit će od jasnog definiranja ekonomskih i okolišnih benefita, identificiranja i rješavanja tehničkih i operativnih problema, postojanja demo-plotova, postojanja jasnih uputstava za implementiranje kompleksnijih rješenja, a pred proizvođačima se stavlja izazov donošenja odluka koji se tiču pravilnog upravljanja zemljištem, odabirom i primjenom onih sorti poljoprivrednih kultura koje su otporne na sušu, primjenom sistema za podršku u odlučivanju, korištenju tehničkih i tehnoloških rješenja koja su neophodna za uspostavljanje preciznog navodnjavanja, itd. Posebnu ulogu u svemu navedenom imaju i potrošači, koji sve više traže različite izvore pouzdanih informacija o autentičnosti hrane, o procesima proizvodnje i distribucije, poslovnoj odgovornosti (Kayikci *et al.*, 2020; WEF, 2020) i ekološkim performansama, posebice doprinosu postizanja Ciljeva održivog razvoja - SDG.



Slika 91. Šematski prikaz pokretača promjena u lancu snabdijevanja hranom (Nikolić *et al.*, 2020)


U Bosni i Hercegovini, poljoprivreda je oduvijek igrala važnu ulogu kako u ekonomskom tako i socio-ekonomskom smislu. Globalizacijom, otvorene su brojne mogućnosti, ali su se pojavili i brojni izazovi koji zahtijevaju drugačiji pristup poslovanju. Trenutni poljoprivredni sektor u BiH je zastario, niskih je proizvodnih i poslovnih performansi. Male i fragmentirane površine, niske tehničke (npr. jaz u onom što se proizvodi i onom što tržište traži, niska tržišna orijentacija, marketing sposobnosti) i tehnološke sposobnosti (npr. niska primjena modernih proizvodnih tehnika, organske, održive, integralne proizvodnje, niska primjena pametnih uređaja u poljoprivredi, navodnjavanja i sl.) individualnih poljoprivrednih proizvođača, te sa druge strane nekonzistentna budžetska izdvajanja, usmjerenost na direktne mjere podrške, nedostatak informacionog sistema u poljoprivredi, registara, netransparentnost izdvajanja u sektoru, te manjak adekvatnog monitoringa i evaluacije poljoprivrednih politika baziranih na stvarnim činjenicama (Bajramović *et al.*, 2017 citirano iz Volk *et al.*, 2017; Stojceska *et al.*, 2021) su samo neke od glavnih karakteristika i problema sa kojima se sektor suočava. Ovo su samo neki od značajnih problema koji usporavaju tranziciju ka savremenim tehnologijama u poljoprivredi i na taj način direktno doprinose i usporavanju rasta i razvoja sektora, te onemogućavaju snažniju konkurentsku poziciju i bolji položaj na tržištu (Nikolić *et al.*, 2017; Djekic *et al.*, 2019; Djekic *et al.*, 2021; Mujčinović *et al.*, 2022). Tranzicijski put nije lak (slika 92), ali postoje brojni alati, mehanizmi podrške za razvoj, poput EU Zelenog plana (*Green Deal*), Strategije od njive do trpeze (*Farm to Fork strategy*), Strategije Biodiverziteta (*Biodiversity strategy*), gdje je predanost različitih nacionalnih i internacionalnih organizacija u postizanju održivog napretka najvažnija karakteristika. Ono što je zajedničko za sve inicijative, jeste put izgradnji održivog (eng. *resilient*) poljoprivrednog i prehrambenog sistema koji je izgrađen na temeljima transparentnog i društveno odgovornog poslovanja u kojem svaki akter unutar sistema zna koju vrijednost gradi, te šta dobija korištenjem proizvoda/usluge. Također, navedene inicijative adresiraju važnu komponentu (koja u BiH društvu tek dobija obrise djelovanja), a to je da ruralna sredina nije isključivo vezana za poljoprivrednu proizvodnju, nego podrazumijeva sredinu koja treba da kreira setove različitih poslovnih modela koji prije svega garantuju bolje performanse u smislu finansija, ali i generalno kvaliteta života. Takvi modeli podrazumijevaju angažman mladih, žena i ostalih u bavljenju održivom poljoprivredom, ruralnim turizmom, eko turizmom, pčelarstvom, ručnim radovima i svim ostalim komplementarnim aktivnostima koje upotpunjuju ponudu ruralne sredine. Da bi se to ostvarilo, neophodno je raditi na kreiranju atraktivnih radnih okruženja, a savremene tehnologije upravo omogućavaju navedeno.



Slika 92. Šematski prikaz željenog unapređenja lanca snabdijevanja hranom

(Willer & Lernoud, 2016; Eyhorn *et al.*, 2019)

Ovdje treba i podcrtati da u Europi, agroekološki programi (AES – *Agri-environmental schemes*) koji su usmjereni na poboljšanje ruralnog okoliša su poprilično dobili zamaha (Riley, 2016), dok se u BiH o ovakvim mjerama još uvijek i ne govori. Željene koristi za okoliš (a i korisnike) se mogu očekivati tek dugoročnom primjenom datih mjera, te veoma često rezultiraju i odgovarajućim promjenama u poljoprivrednim praksama što rezultira složenijim i dugotrajnijim obrascima donošenja odluka (Swetnam *et al.*, 2004; Pedzisa *et al.*, 2015). Doda li se ovome i činjenica da je poljoprivredni sistem generalno prepoznat kako spor u primjeni inovacija, a naročito tehnoloških inovacija (Braun *et al.*, 2018; Duong *et al.*, 2020) onda je više nego jasno da treba usmjeriti posebnu pažnju navedenom. Najboljim primjerima iz prakse neophodno je kontinuirano i snažno informisati poljoprivredne proizvođače i ostale aktere u sektoru o neophodnosti usvajanja inovativnih praksi. Brojna istraživanja podcrtavaju da eksperimentisanjem na poljoprivrednim gazdinstvima može doći do značajnih unapređenja performansi poslovanja, što je naročito važno uzmemo li u obzir gore navedene izazove sa kojima se proizvođači suočavaju. Slika 93 jasno podcrtava potencijalne koristi koje mogu proisteći od primjene inovacija.



Primjeri iz prakse – Poljoprivredno-prehrambeni fakultet Univerziteta u Sarajevu
 Western Balkans Urban Agriculture Initiative (BUGI): <https://www.bugi.unsa.ba/>,
 MSc in Sustainable Food Production Systems (STEPS): <http://steps-project.eu/>,
 Agriturismo landscapes development (LANDS): <https://www.landsproject.net/>,
 Harmonization and Innovation in PhD Study Programs for Plant Health in Sustainable Agriculture (HarISA): <https://harisa.site123.me/>,
 Promoting SMART agricultural WATER management in Bosnia and Herzegovina — (SMARTWATER): <http://www.smartwater-project.eu/>
 Positive Food Environments Fortified with Nature-Based Solutions and New European Bauhaus (BAUHAUS BITES);
 Sustainable Soil and Subsoil health promotion by implementing agroecological land use and management to enhance ecosystem services delivery for society (SUS-SOIL).

Slika 93. Šematski prikaz konceptijskog modela ograničenja prinosa (prilagođeno iz Gomez, 1977)


Mora se naglasiti da se trenutni poljoprivredno-prehrambeni sistem oslanja na metode temeljene isključivo na iskustvu (Braun *et al.*, 2018), pa je nesclo novim tehnikama, tehnologijama kao i disruptivnim poslovnim modelima (Mausch *et al.*, 2020). Trenutni linearni poljoprivredno-prehrambeni sistem organiziran prema načelu “take-make-waste” vrlo je ranjiv i s niskim kapacitetom predviđanja potrebe za promjenom kako bi se suočili s višestrukim, međusobno povezanim i vrlo složenim izazovima. Umjesto toga, cilj bi trebao biti transformacija u vrlo živ sistem koji odražava i odgovara na društvene, ekonomske, političke i okolišne uvjete (Zhaoa *et al.*, 2019; Papadopoulos *et al.*, 2024). Kako bi postigao željeni efekat, svi akteri uključujući kreatore politika, predstavnike industrije i pružatelji tehnologija moraju raditi zajedno na transparentnom promicanju prednosti

savremenih tehnologija i podržati poljoprivredne proizvođače obukom, resursima i poticajima za usvajanje novih tehnologija.

Savremene tehnologije u ovom poglavlju podrazumijevaju digitalne, pametne, „SMART“ sisteme, koje uključuju ali se ne ograničavaju samo na preciznu poljoprivredu, alate za analizu velikih setova podataka (*big data*), a zajedničko za sve njih jeste unapređenje ekonomskih i ekoloških performansi sistema. Njihovom primjenom omogućava se precizno praćenje unosa/korištenja resursa, efikasno praćenje usjeva, unapređenje produktivnosti i smanjenje ekološkog otiska (Saiz-Rubio & Rovira-Más, 2020; Clapp & Ruder, 2020; Karunathilake *et al.*, 2023). Kako bi se čitaocu dala detaljnija slika o tome šta predstavljaju savremeni alati, u narednom dijelu teksta dat je kratki historijski pregled razvoja savremenih tehnologija u poljoprivredi. Ključne faze u razvoju su:

- **Početno usvajanje (1980-1990-te)**, faza koja obuhvata rano korištenje kompjutera za upravljanje farmama, vođenje evidencija i osnovnog finansijskog planiranja, te korištenje GPS tehnologija za navigaciju, mapiranje polja, stvarajući osnovu za primjenu precizne poljoprivrede.
- **Precizna poljoprivreda (2000-te)**, faza koja obuhvata korištenje savremenih alata baziranim na prikupljanju podataka, donošenju odluka o upravljanju usjevima, zdravlju tla, biljaka, te efikasnom korištenju resursa, pored toga započinje i primjena tehnologija precizne prihrane i zaštite, odnosno optimizirajući korištenje resursa, gnojiva i pesticida.
- **Integracija IoT i senzora (2010)**, faza razvoja različitih setova senzora za praćenje vlažnosti tla, temperature i zdravlja usjeva u stvarnom vremenu, te korištenje povezanih uređaja za prikupljanje i analizu podataka omogućujući preciznije praćenje i kontrolu poljoprivrednih operacija.
- **Prikupljanje setova podataka (2010)**, faza u kojoj se fokus daje analizama setova podataka (*big data*), kalibracijama modela, praćenju tržišnih trendova, ali i klimatskim promjenama, korištenjem različitih modela počinje primjena prediktivnih modela za predviđanje prinosa, pojave štetočina i vremenskih obrazaca.
- **Umjetna inteligencija i mašinsko učenje (*Artificial Intelligence and Machine Learning*) (kasne 2010 – danas)**, primjena AI algoritama za automatizaciju operacija, praćenje usjeva, otkrivanje štetočina i predviđanje prinosa, poboljšanje procesa donošenja odluka na temelju podataka, historijskih i trendova.
- **Pojava dronova i robotike (2020)**, upotreba dronova za snimanje iz zraka, praćenje usjeva i preciznu primjenu unosa, razvoj robotskih sistem za radno intenzivne operacije kao što su sadnja, suzbijanje korova i žetva.
- **Fokus na održivost i otpornost (danas)**, ovo je faza koja se trenutno odvija gdje se poseban naglasak stavlja na održive prakse korištenja digitalnih tehnologija za efikasniju upotrebu resursa i smanjenje negativnog uticaja na okoliš, odnosno povećanje otpornosti na klimatske promjene.
- **Budući trendovi (u razvoju)**, *blockchain* tehnologija je u drugim sektorima uveliko zastupljena (npr bankarski sektor), dok je u poljoprivredi i prehrambenoj industriji tek u početnim fazama razvoja, ali pokazujući snažni doprinos u postizanju transparentnog cjelokupnog lanca snabdijevanja hranom, unapređenja sljedivosti i poboljšanja povjerenja između proizvođača i potrošača.


Skok u primjenama savremenih tehnologija je najbolje zabilježen na narednoj slici, a ujedno je i podcrtao izazov koji se odnosi na ravnomjerni razvoj i primjenu tehnologija u urbanim i ruralnim zonama. Istraživanja i brojni izvještaji jasno naglašavaju da primjena pametnih tehnologija u ruralnim sredinama zaostaje značajno u odnosu na urbane, prvenstveno zbog nedostatka odgovarajuće infrastrukture, a onda i zbog manjka humanog kapitala, nedostatak posebnih treninga koji omogućavaju podizanje nivoa znanja o primjeni datih tehnologija i sl.



Slika 94. Šematski prikaz tehnološkog napretka i nejednakost urbanih i ruralnih sredina (UNCTAD, 2020)

Istraživanja o uticaju savremenih tehnologija u poljoprivredi sve više dobijaju na značaju, broj radova koji govori o tome raste munjevitom brzinom, jasno podcrtavajući važnost aplikacije različitih savremenih rješenja na poljoprivrednim gazdinstvima. Zajedničko za sva istraživanja jeste da savremene tehnologije predstavljaju priliku za poboljšanje produktivnosti i dobrobiti za okoliš, a kroz bolje korištenje raspoloživih resursa (Newell & Taylor, 2018; Rose & Chilvers, 2018). Neke od prednosti digitalne poljoprivrede su povećani prinosi s manje inputa, bolje upravljanje okolišem i društvene koristi kao što je manje ručnog rada na farmama (Edwards *et al.*, 2020). S druge strane, postoje i određeni izazovi. Weersink (2018) tvrdi da je digitalizacija dovela do smanjenja broja “prosječnih farmi” u Kanadi i kasnijeg povećanja velikih farmi zbog tehnoloških inovacija koje ubrzavaju proizvodne operacije. Stariji poljoprivrednici i ruralne poljoprivredne zajednice mogli bi biti isključeni iz „digitalne revolucije“ zbog nedostatka pristupačne obuke i internetske povezanosti. Poljoprivrednici možda neće uvijek razumjeti podatke dobivene s digitalnih uređaja, a postoje

problemi u vezi sa nivoom povjerenja u pogledu vlasništva nad podacima i privatnosti, kao i rastući digitalni jaz (Rotz *et al.*, 2019; Weersink, 2018; Bronson & Knezevic, 2019). Ono što je neupitno, to je da savremene tehnologije imaju transformativni potencijal za pretvaranje izazova u prilike (Lioutasa & Charatsari, 2020), pružajući potencijal za budući razvoj poljoprivredno-prehrambenog sistema smanjenjem različitih vrsta neizvjesnost (Leng *et al.*, 2020). Dosadašnji tehnološki napredak pokazao se ekološki održivim, ali i društveno održivim sa stajališta radne snage (Bianco, 2016). Povećava se povezanost i povjerenje među ljudima i institucijama “otključavajući” kapacitet za rješavanje vrlo složenih izazova jačanjem održivosti kroz razvoj atraktivnih poslova, te se otvara prostor za nove poslovne modele koji preoblikuju strukturu, ulogu, poslovni i društveni kontekst, vrijednosti i sredstva proizvodnje (MacPherson *et al.*, 2022). U suštini savremene tehnologije u poljoprivredi olakšavaju informirano donošenje odluka i optimizirano korištenje resursa (Fountas *et al.*, 2020; Rose & Chilvers, 2018), a detaljan prikaz rezultata primjene digitalnih alata u poljoprivrednoj proizvodnji je prikazan slikom 95.



Slika 95. Šematski prikaz koristi od primjene savremenih tehnologija u lancu snabdijevanja hranom (Nikolić *et al.*, 2020)

Primjena navedenih alata usklađena je i sa globalnim ciljevima održivosti i sigurnosti hrane, posebno u okviru Europskog zelenog plana i strategije „Od farme do stola”. Ove inicijative imaju za cilj radikalnu transformaciju prehrambenog sistema u pravcu postizanja održivosti, a posebno u pravcu postavljenih ciljeva za smanjenje sintetskih pesticida i gnojiva, te širenje organske poljoprivrede.

Prednosti i izazovi primjene digitalnih tehnologija u poljoprivredi

Korištenje digitalnih tehnologija u poljoprivredi može donijeti nekoliko prednosti:


- Optimizacija proizvodnje: donošenje boljih/preciznijih odluka, optimizacija poslovanje i povećanje produktivnost, rast prihoda i stabilniji poljoprivredni sektor. Kao rezultat navedenog dolazi do smanjenja upotrebe inputa i troškova proizvodnje, te smanjenja ekološkog otiska poljoprivrednih aktivnosti.
- Poboljšana dobrobit životinja: digitalne aplikacije mogu povećati dobrobit životinja, npr. praćenjem zdravstvenog stanja.
- Poboljšani radni uvjeti: Automatizacija i optimizacija putem digitalnih tehnologija, uključujući robotiku, smanjuju fizičko i mentalno opterećenje poljoprivrednika, što dovodi do poboljšanih radnih uvjeta.
- Povećana transparentnost: specifične digitalne tehnologije, kao što je blockchain, poboljšavaju sljedivost i transparentnost poljoprivrednih proizvoda u lancu vrijednosti, omogućujući potrošačima da donose bolje informirane odluke.
- Povećana konkurentnost: digitalizacija pomaže europskom poljoprivrednom sektoru da ostane konkurentan na globalnoj razini pružanjem inovativnih rješenja i stvaranjem novih poslovnih prilika za sve sudionike u lancu vrijednosti.

Unatoč prednostima, izazovi ostaju:

- Nedostatak svijesti i vještina: Mnogi poljoprivrednici nisu svjesni potencijalnih prednosti digitalizacije i nemaju potrebne vještine i resurse za korištenje novih tehnologija.
- Digitalne podjele: Mnoga ruralna područja još uvijek nemaju pouzdan i pristupačan pristup internetu, što ometa usvajanje digitalnih tehnologija, što je jedan od ključnih faktora koji uzrokuje „digitalne podjele” među poljoprivrednicima.
- Nedostatak isplativosti: Trošak implementacije određenih digitalnih tehnologija može biti veći od potencijalnih koristi, posebno za male poljoprivrednike.
- Potreba za povjerenjem u dijeljenje podataka: Zabrinutost oko privatnosti podataka i vlasništva među poljoprivrednicima može spriječiti dijeljenje podataka između različitih aktera u poljoprivrednom sektoru.
- Nedostatak interoperabilnosti između različitih sistema, budući da mnoge digitalne aplikacije ili uređaji različitih marki možda nisu kompatibilni, što otežava dijeljenje podataka i integraciju podataka.

Mnoge su studije analizirali faktore koji utiču na primjenu inovacija u poljoprivrednom sektoru (za više informacija posjetiti npr. Cisternas *et al.*, 2020; Khan *et al.*, 2021; Nowak, 2021), njihov uticaj na poboljšanje kvaliteta života kod ruralnog stanovništva (Mendola, 2007), i efikasnosti korištenja resursa u poljoprivredno-prehrambenom sektorur (DeLay *et al.*, 2022; Song *et al.*, 2022).

Posljednjih godina, najveći broj studija je fokusiran na potencijalni doprinos digitalnih tehnologija u smanjenju okolišnog otiska (Balafoutis *et al.*, 2017; 2020; Medel-Jiménez *et al.*, 2024). Teorijska je pretpostavka da brojni faktori utiču na odluke poljoprivrednih proizvođača, a interakcija, međudjelovanje i međuovisnost tih faktora čini odluku kompleksnijom, a samim time i rizičnijom. Kao najčešće spominjanje barijere u primjeni inovativnih tehnologija u poljoprivrednom sektoru jesu nedostatak interesnih grupa i trenutnih politika koje nisu usmjerene na razvoj i promociju primjene tehnologija, manjak informacija i znanja, slaba infrastruktura i druge ekonomske barijere, ali i neshvaćanje i kulturološki problemi. Kombinacija ranije navedenih faktora može uveliko umanjiti efekte, odnosno stepen primjene određene inovacije, a teorija difuzije inovacije (za detaljne informacije konsultovati Rogers, 2003) upravo u obzir uzima spomenute elemente (slika 96).




Slika 96. Šematski prikaz procesa donošenja odluka o inovaciji - difuzija inovacije
(prilagođeno iz Rogers, 2003)

Iz navedene šeme, jasno je uočiti nekoliko ključnih faktora neophodnih kako bi se inovacije brže usvajale u određenoj sredini. Nivo znanja korisnika inovacije, te karakteristike sredine su od ključne važnosti, a sumarno, može se reći da su sljedeći elementi neophodni kako bi primjena inovacija zaživjela u određenoj sredini:

- **svijest i vještine** – kao što je to ranije elaborirano i prikazano na šemi iznad, nivo svjesnosti poljoprivrednog proizvođača o savremenoj tehnologiji, koristima kao i problemima koji se mogu javiti sa primjenom iste su od ključne važnosti za primjenu inovacije. U tom smislu, tehnička podrška prilikom uspostave date tehnologije ali i naknadne usluge (održavanja i korištenja) su neophodne;
- **infrastruktura** – kako bi primjena tehnologija bila moguća, neophodno je imati odgovarajuću infrastrukturu, npr. pristup vodi, dostupnost puteva za transport proizvoda do tržišta, pristup skladišnim i rashladnim kapacitetima. Privatni i javni sektor imaju važnu ulogu u uspostavi date infrastrukture.

- **zakonodavni okvir** – zakoni, strategije, akcioni planovi treba da budu kreirani i implementirani kako bi se poticao transfer znanja i tehnologija i doprinijelo primjeni inovacija. Ujedno, zakonodavni okvir predstavlja temelj za strane direktne investicije u sektoru.
- **pristup inputima** – dostupnost i kvalitet inputa, sjemena i sadnog materijala, đubriva, pesticida, mašinerije može uticati, te značajno ubrzati proces primjene datih tehnologija. Suprotno tome, u nedostatku razvijenosti tržišta inputa, proces može biti značajno usporen.
- **pristup tržištu** – razvijenost tržišta je u direktnoj povezanosti sa nivoom primjene inovacija u sektoru, u uslovima gdje ima veliki broj kupaca, cijene manje fluktuiraju, te se osigurava bolja otkupna cijena za proizvođače i stabilniji uslovi poslovanja.
- **pristup finansijama** – raznovrsna paleta finansijskih stimulansa proizvođačima ubrzava protok inovacija u sektoru, ukoliko je ponuda limitirana na vladinu podršku ili podršku nevladinog sektora, onda je protok inovacija značajno usporen. Sa većom paletom finansijskih mogućnosti, otvara se prostor za javno-privatno prartnerstvo između privatnih finansijskih institucija i donatora.

Promicanje primjene inovativnih tehnologija u Bosni i Hercegovini može biti ostvareno kroz izgradnju infrastrukture za digitalnu transformaciju u poljoprivredi kao što je prikazano slikom 97.



Slika 97. Šematski prikaz vizuelnog prikaza modernizacije i unapređenja lanca snabdijevanja hranom (Mujčinović, 2023).

LITERATURA:

- 1) Annosi, M. C., Brunetta, F., Bimbo, F., & Kostoula, M. (2021). Digitalization within food supply chains to prevent food waste. Drivers, barriers and collaboration practices. *Industrial Marketing Management*, 93, 208-220. <https://doi.org/10.1016/j.indmarman.2021.01.005>
- 2) Bajramović, S., Bogdanov, N., Butković, J., Dimitrovski, D., Erjavec, E., Gjerci, G., Kotevska, A. (2016). Analysis of the agricultural and rural development policies of the Western Balkan countries (No. JRC101320). Joint Research Centre (Seville site).
- 3) Balafoutis, A. T., Evert, F. K. V., & Fountas, S. (2020). Smart farming technology trends: Economic and environmental effects, labor impact, and adoption readiness. *Agronomy*, 10(5), 743. <https://doi.org/10.3390/agronomy10050743>
- 4) Balafoutis, A., Beck, B., Fountas, S., Vangeyte, J., Van der Wal, T., Soto, I., & Eory, V. (2017). Precision agriculture technologies positively contributing to GHG emissions mitigation, farm productivity and economics. *Sustainability*, 9(8), 1339. <https://doi.org/10.3390/su9081339>
- 5) Bianco, A. (2016). Green jobs and policy measures for a sustainable agriculture. *Agriculture and agricultural science procedia*, 8, 346-352. <https://doi.org/10.1016/j.aaspro.2016.02.030>
- 6) Braun, A. T., Colangelo, E., & Steckel, T. (2018). Farming in the Era of Industrie 4.0. *Procedia Cirp*, 72, 979-984. <https://doi.org/10.1016/j.procir.2018.03.176>
- 7) Bronson, K., & Knezevic, I. (2019). The digital divide and how it matters for Canadian food system equity. *Canadian Journal of communication*, 44(2), PP-63. <https://doi.org/10.22230/cjc.2019v44n2a3489>
- 8) Charania, I., & Li, X. (2020). Smart farming: Agriculture's shift from a labor intensive to technology native industry. *Internet of Things*, 9, 100142. <https://doi.org/10.1016/j.iot.2019.100142>
- 9) Cisternas, I., Velásquez, I., Caro, A., & Rodríguez, A. (2020). Systematic literature review of implementations of precision agriculture. *Computers and Electronics in Agriculture*, 176, 105626. <https://doi.org/10.1016/j.compag.2020.105626>
- 10) Clapp, J., & Ruder, S. L. (2020). Precision technologies for agriculture: Digital farming, gene-edited crops, and the politics of sustainability. *Global Environmental Politics*, 20(3), 49-69. https://doi.org/10.1162/glep_a_00566
- 11) DeLay, N. D., Thompson, N. M., & Mintert, J. R. (2022). Precision agriculture technology adoption and technical efficiency. *Journal of Agricultural Economics*, 73(1), 195–219. <https://doi.org/10.1111/1477-9552.12416>
- 12) Djekic, I., Mujčinović, A., Nikolić, A., Jambrak, A. R., Papademas, P., Feyissa, A. H., ... & Tonda, A. (2019). Cross-European initial survey on the use of mathematical models in food industry. *Journal of food engineering*, 261, 109-116. <https://doi.org/10.1016/j.jfoodeng.2019.06.007>
- 13) Djekic, I., Nikolić, A., Uzunović, M., Marijke, A., Liu, A., Han, J., ... & Tomasevic, I. (2021). Covid-19 pandemic effects on food safety-Multi-country survey study. *Food control*, 122, 107800. <https://doi.org/10.1016/j.foodcont.2020.107800>

- 14) Duong, L. N., Al-Fadhli, M., Jagtap, S., Bader, F., Martindale, W., Swainson, M., & Paoli, A. (2020). A review of robotics and autonomous systems in the food industry: From the supply chains perspective. *Trends in Food Science & Technology*, 106, 355-364. <https://doi.org/10.1016/j.tifs.2020.10.028>
- 15) Edwards, J. P., Kuhn-Sherlock, B., Rue, B. D., & Eastwood, C. R. (2020). Technologies and milking practices that reduce hours of work and increase flexibility through milking efficiency in pasture-based dairy farm systems. *Journal of Dairy Science*, 103(8), 7172-7179. <https://doi.org/10.3168/jds.2019-17941>
- 16) Eyhorn, F., Muller, A., Reganold, J. P., Frison, E., Herren, H. R., Luttikholt, L., ... & Smith, P. (2019). Sustainability in global agriculture driven by organic farming. *Nature Sustainability*, 2(4), 253-255. <https://doi.org/10.1038/s41893-019-0266-6>
- 17) FAO. (2018). The future of food and agriculture – Alternative pathways to 2050. Rome. 224 pp. Licence: CC BY-NC-SA 3.0 IGO. Dostupno na: <http://www.fao.org/publications/fofa/en/>
- 18) Farmery, A. K., Brewer, T. D., Farrell, P., Kottage, H., Reeve, E., Thow, A. M., & Andrew, N. L. (2021). Conceptualising value chain research to integrate multiple food system elements. *Global Food Security*, 28, 100500. <https://doi.org/10.1016/j.gfs.2021.100500>
- 19) Forssell, S., & Lankoski, L. (2015). The sustainability promise of alternative food networks: an examination through “alternative” characteristics. *Agriculture and human values*, 32(1), 63-75. <https://doi.org/10.1007/s10460-014-9516-4>
- 20) Fountas, S., Espejo-García, B., Kasimati, A., Mylonas, N., & Darra, N. (2020). The future of digital agriculture: technologies and opportunities. *IT professional*, 22(1), 24-28,
- 21) Fritsche UR, Eppler U. Global Land Use Scenarios: Findings from a review of key studies and models. GLOBALANDS Working Paper AP 1.3. International Institute for Sustainability Analysis and Strategy. Darmstadt: IINAS; 2013. Available from: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.707.8225&rep=rep1&type=pdf>
- 22) Gomez, K. A. (1977). On farm assessment of yield constraints: methodological problems. Constraints to High Yields on Asian Rice Farms; International Rice Research Institute.
- 23) Grunert, K. G. (2005). Food quality and safety: consumer perception and demand. *European review of agricultural economics*, 32(3), 369-391. <https://doi.org/10.1093/eurrags/jbi011>
- 24) Karunathilake, E. M. B. M., Le, A. T., Heo, S., Chung, Y. S., & Mansoor, S. (2023). The path to smart farming: Innovations and opportunities in precision agriculture. *Agriculture*, 13(8), 1593. <https://doi.org/10.3390/agriculture13081593>
- 25) Kayikci, Y., Subramanian, N., Dora, M., & Bhatia, M. S. (2022). Food supply chain in the era of Industry 4.0: Blockchain technology implementation opportunities and impediments from the perspective of people, process, performance, and technology. *Production planning & control*, 33(2-3), 301-321. <https://doi.org/10.1080/09537287.2020.1810757>
- 26) Khan, N., Ray, R. L., Sargani, G. R., Ihtisham, M., Khayyam, M., & Ismail, S. (2021). Current progress and future prospects of agriculture technology: Gateway to sustainable agriculture. *Sustainability*, 13(9), 4883. <https://doi.org/10.3390/su13094883>

- 27) Leng, J., Ruan, G., Jiang, P., Xu, K., Liu, Q., Zhou, X., & Liu, C. (2020). Blockchain-empowered sustainable manufacturing and product lifecycle management in industry 4.0: A survey. *Renewable and sustainable energy reviews*, 132, 110112. <https://doi.org/10.1016/j.rser.2020.110112>
- 28) Lezoche, M., Hernandez, J.E., Díaz, M.D.M.E.A., Panetto, H. and Kacprzyk, J., 2020. Agri-food 4.0: a survey of the supply chains and technologies for the future agriculture. *Computers in Industry*, 117, p.103187.
- 29) Lioutas, E. D., & Charatsari, C. (2020). Smart farming and short food supply chains: Are they compatible?. *Land use policy*, 94, 104541. <https://doi.org/10.1016/j.landusepol.2020.104541>
- 30) Luning, P. A., & Marcelis, W. J. (2007). A conceptual model of food quality management functions based on a techno-managerial approach. *Trends in Food Science & Technology*, 18(3), 159-166. <https://doi.org/10.1016/j.tifs.2006.10.021>
- 31) MacPherson, J., Voglhuber-Slavinsky, A., Olbrisch, M., Schöbel, P., Dönitz, E., Mouratiadou, I., & Helming, K. (2022). Future agricultural systems and the role of digitalization for achieving sustainability goals. A review. *Agronomy for Sustainable Development*, 42(4), 70. <https://doi.org/10.1007/s13593-022-00792-6>
- 32) Martinovska Stojcheska, A., Kotevska, A., Janeska Stamenkovska, I., Dimitrievski, D., Zhllima, E., Vaško, Ž., Bajramović, S., Kerolli Mustafa, M., Spahić, M., Kovačević, V., Koç, A.A., Bayaner, A., Ciaian P., (2021). Recent agricultural policy developments in the context of the EU approximation process in the pre-accession countries, Martinovska Stojcheska, A., Kotevska, A., Ciaian, P., Ilic, B., Pavloska-Gjorgjieska, D., Salputra G., eds., EUR 30687 EN, Publications Office of the European Union, Luxembourg, ISBN 978-92-76-37270-7, doi:10.2760/041338, JRC124502.
- 33) Mausch, K., Hall, A., & Hambloch, C. (2020). Colliding paradigms and trade-offs: Agri-food systems and value chain interventions. *Global Food Security*, 26, 100439. <https://doi.org/10.1016/j.gfs.2020.100439>
- 34) Medel-Jiménez, F., Krexner, T., Gronauer, A., & Kral, I. (2024). Life cycle assessment of four different precision agriculture technologies and comparison with a conventional scheme. *Journal of Cleaner Production*, 434, 140198. <https://doi.org/10.1016/j.jclepro.2024.140198>
- 35) Mendola, M. (2007). Agricultural technology adoption and poverty reduction: A propensity-score matching analysis for rural Bangladesh. *Food Policy*, 32(3), 372–393. <https://doi.org/10.1016/j.foodpol.2006.09.004>
- 36) Mujčinović, A. & Bojnec, S. (2023). Rural NEETs and Sustainability: Pathways to Rural Transformation, Policy brief, COST Action CA 18213: Rural NEET YouthNetwork: Modeling the risks underlying rural NEETs social exclusion.
- 37) Mujčinović, A. (2022). Improving the competitiveness of the agri-food sector in Bosnia and Herzegovina: challenges and opportunities, policy brief, The MED Green Growth Community, Cener 21, Sarajevo, BiH
- 38) Mujčinović, A. (2022). Izazovi i perspektive modernizacije poljoprivredno-prehrambenog sektora u BiH, Policy brief, Friedrich-Ebert-Stiftung, Sarajevo, BiH. ISBN 978-9926-482-78-7

- 39) Mujčinović, A., Nikolić, A., Tuna, E., Stamenkovska, I. J., Radović, V., Flynn, P., & McCauley, V. (2021). Is It Possible to Tackle Youth Needs with Agricultural and Rural Development Policies?. *Sustainability*, 13(15), 8410. <https://doi.org/10.3390/su13158410>
- 40) Newell, P., & Taylor, O. (2018). Contested landscapes: the global political economy of climate-smart agriculture. *The Journal of Peasant Studies*, 45(1), 108-129. <https://doi.org/10.1080/03066150.2017.1324426>
- 41) Nikolić, A., Mujčinović, A., & Bošković, D. (2020, June). Get ready for Industry 4.0—tool to support food value chain transformation. In *Central European Congress on Food* (pp. 453-476). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-031-04797-8_39
- 42) Nikolić, A., Uzunović, M., & Mujčinović, A. (2017). Underlying factors shaping level of market orientation of food companies in Bosnia and Herzegovina. *Radovi Poljoprivrednog Fakulteta Univerziteta u Sarajevu\Works of the Faculty of Agriculture University of Sarajevo*, 62(67 (1)), 237-242.
- 43) Nowak, B. (2021). Precision agriculture: Where do we stand? A review of the adoption of precision agriculture technologies on field crops farms in developed countries. *Agricultural Research*, 10(4), 515–522. <https://doi.org/10.1007/s40003-021-00539-4>
- 44) Papadopoulos, G., Arduini, S., Uyar, H., Psiroukis, V., Kasimati, A., & Fountas, S. (2024). Economic and environmental benefits of digital agricultural technologies in crop production: A review. *Smart Agricultural Technology*, 100441. <https://doi.org/10.1016/j.atech.2024.100441>
- 45) Pedzisa, T., Rugube, L., Winter-Nelson, A., Baylis, K., & Mazvimavi, K. (2015). Abandonment of conservation agriculture by smallholder farmers in Zimbabwe. *Journal of sustainable development*, 8(1), 69.
- 46) Reisch, L., Eberle, U., & Lorek, S. (2013). Sustainable food consumption: an overview of contemporary issues and policies. *Sustainability: Science, Practice and Policy*, 9(2), 7-25. <https://doi.org/10.1080/15487733.2013.11908111>
- 47) Richter, B., & Bokelmann, W. (2016). Approaches of the German food industry for addressing the issue of food losses. *Waste management*, 48, 423-429. <https://doi.org/10.1016/j.wasman.2015.11.039>
- 48) Riley, M., (2016). Riley, M. (2016). How does longer term participation in agri-environment schemes [re] shape farmers' environmental dispositions and identities?. *Land use policy*, 52, 62-75. <https://doi.org/10.1016/j.landusepol.2015.12.010>
- 49) Rogers, E.M. (2003). *Diffusion of innovations* (5th ed.). New York: Free Press.
- 50) Rose, D. C., & Chilvers, J. (2018). Agriculture 4.0: Broadening responsible innovation in an era of smart farming. *Frontiers in Sustainable Food Systems*, 2, 87. <https://doi.org/10.3389/fsufs.2018.00087>
- 51) Rotz, S., Gravely, E., Mosby, I., Duncan, E., Finnis, E., Horgan, M., ... & Fraser, E. (2019). Automated pastures and the digital divide: How agricultural technologies are shaping labour and rural communities. *Journal of Rural Studies*, 68, 112-122. <https://doi.org/10.1016/j.jrurstud.2019.01.023>

- 52) Saiz-Rubio, V., & Rovira-Más, F. (2020). From smart farming towards agriculture 5.0: A review on crop data management. *Agronomy*, 10(2), 207. <https://doi.org/10.3390/agronomy10020207>
- 53) Smith, M. D., & Floro, M. S. (2020). Food insecurity, gender, and international migration in low-and middle-income countries. *Food Policy*, 91, 101837. <https://doi.org/10.1016/j.foodpol.2020.101837>
- 54) Song, S., Hou, Y., Lim, R. B., Gaw, L. Y., Richards, D. R., & Tan, H. T. (2022). Comparison of vegetable production, resource-use efficiency and environmental performance of high-technology and conventional farming systems for urban agriculture in the tropical city of Singapore. *Science of the Total Environment*, 807, 150621. <https://doi.org/10.1016/j.scitotenv.2021.150621>
- 55) Sun, F., Yun, D. A. I., & Yu, X. (2017). Air pollution, food production and food security: A review from the perspective of food system. *Journal of integrative agriculture*, 16(12), 2945-2962. [https://doi.org/10.1016/S2095-3119\(17\)61814-8](https://doi.org/10.1016/S2095-3119(17)61814-8)
- 56) Swetnam, R. D., Mountford, J. O., Manchester, S. J., & Broughton, R. K. (2004). Agri-environmental schemes: their role in reversing floral decline in the Brue floodplain, Somerset, UK. *Journal of environmental management*, 71(1), 79-93. <https://doi.org/10.1016/j.jenvman.2004.01.006>
- 57) Tefft, J., Jonasova, M., Adjao, R., & Morgan, A. (2017). Food systems for an urbanizing world. World Bank Report. Dostupno na: <http://documents.worldbank.org/curated/en/454961511210702794/Food-systems-for-an-urbanizing-world-knowledge-product>
- 58) Tijan, E., Aksentijević, S., Ivanić, K., & Jardaš, M. (2019). Blockchain technology implementation in logistics. *Sustainability*, 11(4), 1185. <https://doi.org/10.3390/su11041185>
- 59) UNCTAD. (2021) Technology and Innovation Report, Catching technological waves, Innovation with equity, United Nations Conference on Trade and Development, eISBN:978-92-1-005658-8
- 60) Van der Spiegel, M., Luning, P. A., Ziggers, G. W., & Jongen, W. M. F. (2005). Evaluation of performance measurement instruments on their use for food quality systems. *Critical Reviews in food Science and Nutrition*, 44(7-8), 501-512. <https://doi.org/10.1080/10408690490489350>
- 61) Volk, T., Rednak, M., Erjavec, E., Zhllima, E., Gjerci, G., Bajramovic, S., ... & Gjokaj, E. (2017). Monitoring of agricultural policy developments in the Western Balkan countries (No. JRC105784). Joint Research Centre (Seville site).
- 62) Weersink, A. (2018, March). The growing heterogeneity in the farm sector and its implications. In *Canadian Journal of Agricultural Economics/Revue canadienne d'agroeconomie* (Vol. 66, No. 1, pp. 27-41). <https://doi.org/10.1111/cjag.12163>
- 63) WEF (2012) Driving Sustainable Consumption, World Economic Forum, available on: http://www3.weforum.org/docs/WEF_ENV_SustainableConsumption_Book_2013.pdf
- 64) WEF, (2018). Driving the Sustainability of Production Systems with Fourth Industrial Revolution Innovation, Cologny/Geneva Switzerland, World Economic Forum.
- 65) WEF, (2019). Innovation with a Purpose: Improving Traceability in Food Value Chains through Technology Innovations, Cologny/Geneva Switzerland, World Economic Forum.

- 66) WEF, (2020). Incentivizing Food Systems Transformation, World Economic Forum.
- 67) WEF, (2020). New paradigm for Business of Data Report, Cologny/Geneva Switzerland, World Economic Forum.
- 68) WEF, (2020). Vision Towards a Responsible Future of Consumption: Collaborative action framework for consumer industries COMMUNITY PAPER OCTOBER 2020, World Economic Forum.
- 69) WEF, (2021). Technology Futures: Projecting the Possible, Navigating What's Next, Cologny/Geneva Switzerland, World Economic Forum.
- 70) Willer, H., & Lernoud, J. (2016). The World of Organic Agriculture. Statistics and Emerging Trends. FIBL-IFOAM Report, Research Institute of Organic Agriculture (FIBL) and IFOAM–Organics International, Bonn.
- 71) Zhao, G., Liu, S., Lopez, C., Lu, H., Elgueta, S., Chen, H., & Boshkoska, B. M. (2019). Blockchain technology in agri-food value chain management: A synthesis of applications, challenges and future research directions. *Computers in industry*, 109, 83-99. <https://doi.org/10.1016/j.compind.2019.04.002>



DIZAJN NASLOVNICE
NAPRAVLJEN JE UZ POMOĆ
VJEŠTAČKE INTELIGENCIJE



Projekat finansirali:



Finansira
Evropska unija

EU4Agri



**UN
DP**



**CZECH
AID**

Publikacija se realizuje u sklopu projekta "Pametni sistemi u poljoprivredi – odgovor izazovima 21. stoljeća". Projekat finansira Evropska Unija kroz EU4AGRI - Podršku Evropske Unije konkurentnosti poljoprivrede i ruralnom razvoju u Bosni i Hercegovini". Projekat EU4AGRI zajednički provode Razvojni program Ujedinjenih nacija (UNDP) i Češka razvojna agencija (CzDA). Kreator i implementator projekta je Univerzitet u Sarajevu – Poljoprivredno-prehrambeni fakultet.