

TEHNIKE ANALIZE VIZUALNIH PODATAKA ZA RANO OTKRIVANJE I KLASIFIKACIJU ŠTETNIH ORGANIZAMA I BILJNOG STRESA

Tomislav KOS, Zoran ŠIKIĆ, Anđelo ZDRILIĆ, Šime MARCELIĆ, Ana GAŠPAROVIĆ
PINTO, Marko ZORICA, Kristijan FRANIN, Šimun KOLEGA

Odjel za ekologiju, agronomiju i akvakulturu, Sveučilište u Zadru, Trg Kneza
Višeslava 9,
Relja, 23 000 Zadar, Hrvatska
tkos@unizd.hr
Prijhvaćeno: 22-04-2021

SAŽETAK

Poljoprivredna je proizvodnja od velike važnosti za prehranu ljudi i životinja. Budući da su potrebe za hranom svaki dan sve veće, a razina šteta se, ovisno o kulturi, umnogome ne mijenja, potrebno je naći nova rješenja. Svaki uzgoj bilja prati i njegova problematika ekonomski značajnih štetnih organizama i stresa uzrokovanog vanjskim i unutrašnjim čimbenicima. Takvi se problemi ne mogu više nadgledati samo ljudskim okom, pogotovu na većim parcelama, pa se rješenja traže u područjima precizne poljoprivrede. Suvremene tehnike uzimanja i obrade vizualnih podataka usmjerene su prema automatskom analiziranju usjeva preko slika i tako uvelike skraćuju vrijeme i rad inače potreban za otkrivanje prve pojave štetnih organizama i abiotskog stresa. Tehnike analize slika omogućuju lakše određivanje stupnja razvoja štetnog organizma (štetnika, biljnih bolesti, korova), klasifikaciju biljaka na zdrave i zaražene te otkrivanje biljnog stresa. Cilj je ovih analiza provjeriti zdravstveno stanje većeg broja biljaka u kraćem vremenu te predvidjeti mogućnost razvoja štetnog organizma i stresa bilja. U tu se svrhu danas koristi umjetna inteligencija kao najbolje rješenje. Ove tehnike i metode moraju biti brže, bolje i ekonomičnije od ljudskog rada. Rad rasvjetljuje nove spoznaje u području istraživanja i primjena tehnika detekcije štetnih organizama i stresa biljaka obradom vizualnih podataka usmjerenih kao alat za pomoć agronomu te pregledom dostupnih istraživanja u fitomedicini.

Ključne riječi: biljni stres, hiperspektralna analiza (HSY), neuronske mreže, štetni organizmi, vidljivi spektar (RGB)

VISUAL DATA ANALYSIS TECHNIQUES FOR EARLY DETECTION AND CLASSIFICATION OF PESTS AND PLANT STRESS

SUMMARY

Agricultural production is of great importance for human and animal nutrition. Since the need for food increases every day and the level of damage does not change much depending on the culture, new solutions need to be found. Every cultivation of plants is accompanied by the problem of its economically significant harmful organisms and stress caused by external and internal factors. The human eye can no longer track such problems, especially on larger plots, therefore solutions are being sought in areas of precision agriculture. Modern techniques of taking and processing visual data are aimed at the automatic analysis of crops through images and thus greatly shorten the time and work that are otherwise required to detect the first appearance of pests and stress. Image analysis techniques make it easy to determine the degree of development of a harmful organism (pests, plant diseases, weeds), classify plants as healthy and infected, and detect plant stress. The aim of these analyses is to check the health of a large number of plants in a shorter time, and to predict the possibility of the development of a harmful organism and stress on plants. Artificial intelligence is used for this purpose today, as the best solution. These techniques and methods must be faster, better and more economical than human labour. This paper sheds light on new findings in the field of research and application of techniques for detecting pests and plant stress, by processing visual data directed as a tool to help the agronomist, and by reviewing available research in phytomedicine.

Key words: hyperspectral analysis (HSY), neural networks, pests, plant stress, visible spectrum analysis (RGB)

UVOD

Precizna poljoprivreda predstavlja nove metode u uzgoju koje postupno mijenjaju tradicionalnu poljoprivredu. U njoj se promatraju svi čimbenici uzgoja - od okoliša, vode i tla, do vjerojatnosti pojave štetnih organizama. Godišnje propada između 30 % i 40 % usjeva kroz biljnu proizvodnju (Savary i sur., 2012), među ostalim i zbog pojave štetnih organizama. Bez obzira na mjeru njihovog suzbijanja, najvažniji postupak u zaštiti bilja i dalje je što ranije prepoznati pojavu štetnog organizma. Kao što je prije navedeno, ljudi ne mogu pregledati velike površine u kratkom vremenu niti mogu postići konstantnu preciznost pri prepoznavanju simptoma, a tako i štetnih organizama. Računala s druge strane mogu i prepoznati i klasificirati štetni organizam i stres biljaka s visokom preciznosti u kratkom vremenu. Precizna se poljoprivreda danas razvija prema konceptu *Agronomija 5.0*. Svrha je ovog koncepta implementirati brze sustave koji se temelje na umjetnoj inteligenciji i čija je produktivnost veća i brža od

ljudske. Potreba za *Agronomijom 5.0* javlja se najviše zbog potrebe za radnom snagom na farmama i plantažama. Današnje se društvo odmaklo od agrarnog stila života, što rezultira znatno manjim brojem ljudi zaposlenih u primarnom sektoru (Saiz-Rubio i Rovira-Más, 2020). Prema istraživanjima Smart Agriculture Market (2021), procjenjuje se da će vrijednost tržišta precizne poljoprivrede u 2022. godini iznositi 13,27 mlrd USD, uz godišnju stopu rasta od 9,8 % do 2025. Primarni sektor, uključujući i poljoprivredu, konstantno se mijenja dolaskom novih tehnologija. Jedna od tih tehnologija je i hiperspektralna analiza slika (HSY) temeljena na tehnikama koje provodi autonomna umjetna inteligencija – *Artificial intelligence* (AI), neovisna o čovjeku. Ove tehnologije pokazuju bržu obradu podataka i detaljniji pregled bilja, znatno precizniji od pregleda „golim okom“. Upravo se zbog toga precizna poljoprivreda ubraja u treći val agronomске revolucije. Prvi je val došao s pojavom mehanizacije, a drugi val sa zelenom revolucijom i genetskom modifikacijom biljaka (Saiz-Rubio i Rovira-Más, 2020).

Što je HSY slika?

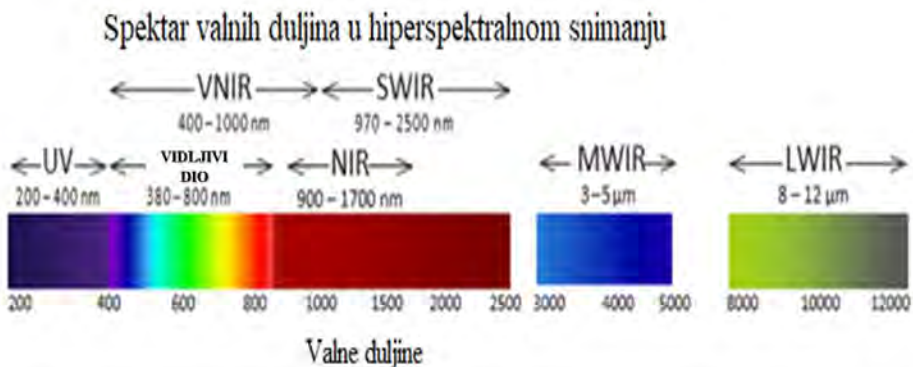
Kako bi se proces pregledavanja, klasifikacije i otkrivanja štetnih organizama, pogotovu u ranijim stadijima njihova razvoja, ubrzao i poboljšao, osmišljene su tehnike HSY analize slike. Ljudski spektar vidljivosti kreće se od 400 do 700 nm, to je tzv. „Red, Green, Blue“ (RGB) spektar. HSY snimanje slike ima mnogo veći spektar očitavanja valnih duljina koji je često promjenjiv i podijeljen u više sekcija (50 do 250 spektralnih snopova). Budući da se radi o biljkama, taj se spektar najčešće proteže od ultraljubičastog svjetla na 250 nm do kratkovalnog infracrvenog svjetla na 2.500 nm. Prednost HSY snimanja naspram ostalih vrsta daljinskog snimanja je količina podataka koja se može prikupiti, što omogućuje sastavljanje spektralnih potpisa visoke detaljnosti. Otkrićem ove tehnologije mogućnost identifikacije i klasifikacije biljnih bolesti znatno je porasla. S druge strane, dolazak nove tehnologije značio je i stvaranje novih metoda procesiranja podataka.

Obrada vizualnih podataka nimalo nije jednostavna. Ti složeni programski algoritmi koji uključuju analizu velikog broja podataka mogu se procesuirati uz pomoć AI-a. Umjetne neuronske mreže ubrajamo u metode AI-a. Umjetna inteligencija dio je znanosti o računalima koja se bavi projektiranjem inteligentnih računalnih sustava koji predočavaju karakteristike koje povezujemo s inteligencijom u ljudskom ponašanju. Tijekom evolucije ljudski je mozak poprimio niz karakteristika koje se povezuju s inteligencijom. Neke od karakteristika ljudi koje se povezuju s inteligencijom jesu: paralelno obavljanje više operacija, sposobnost učenja, sposobnost generaliziranja (uopćavanja), sposobnost prilagođavanja, suvislo postupanje s informacijama, tolerancija na pogreške i nepotpune informacije. Karakteristike računalnih sustava jesu brza provedba numeričkih složenih proračuna te rad s velikom količinom podataka (Ujević Andrijić, 2019).

Cilj je rada, uz dostupnu literaturu, prikupiti podatke o tehnikama HSY analize slike za otkrivanje ranih stadija štetnih organizama i stresa bilja te o metodama njihove klasifikacije. Svrha je ovog rada, temeljem dostupne literature, objasniti tehnike kojima HSY analize unaprjeđuju prognozu rane pojave štetnih organizama, a samim time poboljšavaju poljoprivredu sadašnjosti i budućnosti u području precizne poljoprivrede.

Digitalno snimanje slika

Za lakše razumijevanje hiperspektralnog (HSY) snimanja slika potrebno je prvo shvatiti što je standardno, odnosno digitalno snimanje. Boje dolaze iz raznih valnih duljina svjetla. Spektar boja vidljiv ljudskom oku (RGB) kreće se između 400 i 700 nm (Slika 1.), gdje plava boja ima valnu duljinu od otprilike 475 nm, zelena oko 520 nm i crvena oko 650 nm. Obojenost slike dolazi iz rasporeda tih triju boja i njihovog miješanja. Isto tako ljudsko se oko sastoji od triju vrsta specijaliziranih stanica – čunjića, osjetljivih na te boje. Intenzitet boje ovisi o energiji valnih duljina, pa tako kao rezultat imamo svjetlije ili tamnije nijanse boje. Sve te informacije odlaze u mozak gdje se spajaju u jednu sliku u boji. Po uzoru na sustav ljudskog oka, digitalno snimanje imitira hvatanje istih tih valnih duljina (Dhingra i sur., 2017). **Piksel** je osnovna jedinica (zapis) koja čini sliku u digitalnom snimanju. Vrijednost se valne duljine zapisuje u informatičkom obliku na piksel (Lowe i sur., 2017).



UV (ultraviolet) – ultraljubičasti spektar; VNIR (visible infrared) – vidljivi infracrveni spektar; SWIR (short-wavelength infrared) – kratkovalni infracrveni spektar; NIR (near-visible infrared spectre) – gotovo vidljiv infracrveni spektar; MWIR (mid-wavelength infrared) – srednjevalni infracrveni spektar; LWIR (long-range infrared) – dugovalni infracrveni spektar

Slika 1. Valne duljine za HSY snimanje (Izvor: Middleton Spectral Vision, 2020)
Figure 1 Wavelength display for HSY recording (Source: Middleton Spectral Vision, 2020)

HSY snimanje slike ima mnogo veći spektar očitavanja valnih duljina (Xia i sur., 2011), a koji je često promjenjiv i podijeljen u više sekcija. Budući da se radi o biljkama, taj se spektar najčešće proteže od ultraljubičastog svjetla na 250 nm do kratkovalnog infracrvenog svjetla na 2.500 nm. Kako bi se stvaranje


slike ubrzalo i poboljšalo, HSY kamere često su fokusirane samo na pojedine dijelove tog spektra, ili se koristi više kamera kako bi se uhvatio čitav spektar. Uz ultraljubičasto i kratkovalno infracrveno svjetlo, najčešće se promatra još kombinacija gotovo vidljivog i vidljivog infracrvenog na duljinama od 400 do 1.300 nm za očitavanje refleksije krutih predmeta, a u ovom se rasponu nalazi i područje klasifikacije štetnih organizama. Dehidracija biljke može poremetiti mezofilnu strukturu, stoga se za razinu vode u biljnoj stanici analiziraju duljine od 1.300 do 2.500 nm (Peñuelas i Filella, 1998). Valne duljine srednjeg, od 3.000 do 5.000 nm, a ponekad i dugovalnog infracrvenog spektra, od 8.000 do 12.000 nm, služe za proučavanje emisije plinova (Lowe i sur., 2017). RGB slika je primjer slike dobivene iz triju različitih i udaljenih pojaseva vidljive svjetlosti od kojih svaka ima podatak o plavoj, zelenoj ili crvenoj boji. HSY snimljena slika sastoji se od stotina pojaseva spektralne svjetlosti koji se nalaze neprekidno jedan do drugoga, što rezultira gustim skupom podataka s dovoljno prostorne rezolucije kako bi se jedan list uspješno prikazao stotinama piksela (Lowe i sur., 2017).

Crvena boja na nekom crvenom predmetu vidljiva je jer se sve valne duljine apsorbiraju, osim valne duljine za crvenu boju koja se reflektira u naše oči i dolazi do mozga gdje se interpretira u sliku. Samim time već dobijemo veliku količinu podataka, a HSY analizom dobijemo još više podataka o objektu, izvan našeg vidljivog spektra, što omogućuje stvaranje još preciznije slike. HSY slika nastaje tako što svjetlost različitih valnih duljina udara u objekt, apsorbira se, prenosi i raspršuje ovisno o kemijskom sastavu tog objekta. Ono što je vidljivo zapravo su odbijene valne duljine koje ovise o indeksu loma materijala.

HSY analizi slika prethodila je multispektralna analiza, i dalje pouzdana metoda u poljoprivredi. Za razliku od HSY, multispektralno slikanje fokusira se na trenutno stanje biljaka, što znači da se ne može koristiti za predviđanje razvoja najčešćih biljnih bolesti. Također se multispektralnom analizom promatra manji broj valnih snopova koji su širi, a slike su manje rezolucije i algoritmi za obradu podataka jednostavniji su. Cilj je multispektralne analize uzeti što manje ulaznih podataka i što prije ih obraditi kako bi se dobilo stanje biljaka na nekoj parceli u stvarnom vremenu (Qin i sur., 2013).

HSY slikanje proces je kojim se slikama, odnosno pikselima dodaju brožčane vrijednosti. One se dalje, pomoću raznih softvera i raznih matematičkih analiza, sortiraju i koriste za klasifikaciju stanja biljke kako bi se moglo razlikovati između stvarne pojave štetnih organizama (biljne bolesti) i okolišnih čimbenika (Mishra i sur., 2016). Lakše interpretiranje podataka moguće je jer su oni podijeljeni po snopovima određenih valnih duljina i skupa sastavljeni u takozvanu HSY informacijsku kocku, ili skraćeno „hiperkocku“, za procesiranje i daljnju analizu (Paoletti i sur., 2018). Takva je kocka sastavljena od slojeva slika, a svaki piksel pojedine slike predstavlja skup informacija za određenu valnu duljinu. Svaki je objekt opisan različitim snopovima valnih duljina, pa se kaže da on ima svoj jedinstveni spektralni potpis (Shaw i sur., 2003). Na slici 2. prikazan

je primjer HSY kocke gdje X i Y prikazuju prostorne osi, dok Z prikazuje spektralnu os u kojoj se nalazi HSY zapis slike.

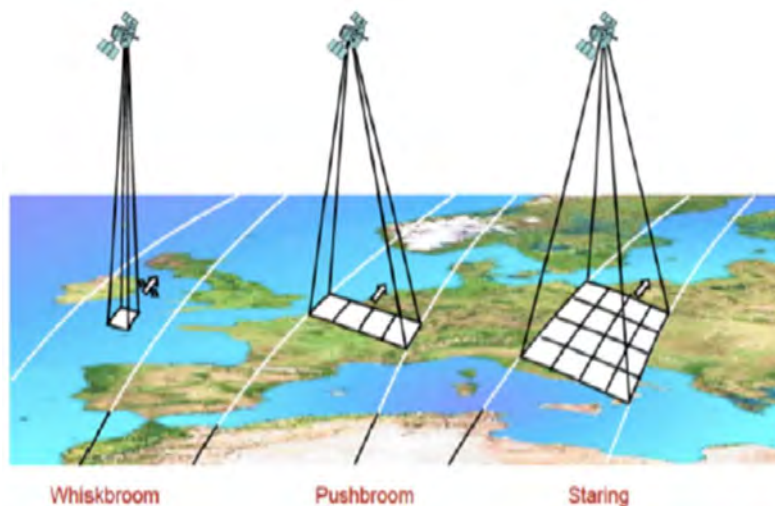


Slika 2. HSY informacijska kocka (hiperkocka), (Izvor: Bock i sur., 2010)

Figure 2 HSY information cube (hypercube), (Source: Bock et al., 2010)

HSY vizualni podatci sastavljeni su od 50 do 250 spektralnih snopova uske propusnosti, širine uglavnom od 5 do 20 nm, dok su tradicionalni, prije korišteni, multispektralni podatci sastavljeni u manje, 5 do 10, ali šire snopove, od 70 do 400 nm (Crespo i sur., 2003).

HSY kamera uređaj je koji se koristi za HSY snimanje. Sastoji se od objektiva, spektrografa i digitalne kamere koja obrađuje podatke. Spektrograf je najvažniji dio kamere jer o njegovoj građi ovisi koje će se valne duljine snimati i na koji način. Svjetlo u spektrografu prolazi kroz konveksnu rešetku ili prizmu na leći te se dijeli na uske valne duljine i njihova se vrijednost zapisuje na svjetlosni čip u digitalnom dijelu kamere (Polder i sur., 2003). HSY senzori međusobno se razlikuju po broju snopova i rasponu valnih duljina koje obuhvaćaju, po propusnosti, prostornoj rezoluciji i površini koju obuhvaćaju te načinu dobavljanja podataka. Postoje tri načina kojima se slika raspršuje s leće objektiva u spektrograf, odnosno tri tipa senzora u spektrografu, a to su *whiskbroom*, *pushbroom* i *staring (focal-plane array, FPA, niz žarišnih ravnina)*, (Licciardi, 2010), (Slika 3.).



Slika 3. *Whiskbroom*, *Pushbroom* i *Staring* (FPA) senzori i površine koje obuhvaćaju tijekom skeniranja (Izvor: Licciardi, 2010)

Figure 3 *Whiskbroom*, *Pushbroom*, and *Staring* (FPA) sensors and the area they cover during scanning (Source: Licciardi, 2010)

Whiskbroom senzore ili elektromehaničke senzore karakteriziraju manji, jednolinijski detektoro, a koji koriste optiku na osi ili teleskope sa zrcalima koji se kreću cijelom dužinom parcele (Ortenberg i sur., 2011). Upravo su po toj kretnji i dobili ime jer podsjećaju na manju metlu koja čisti.

Pushbroom senzori nastali su kao nadogradnja na *whiskbroom* senzore, sadrže spektrometre za dobivanje slika u visokoj rezoluciji te su zbog toga jedni od najčešće upotrebljivanih senzora u HSY slikanju (Kurz i Buckley, 2016).

Staring senzori, ili niz žarišnih točaka (focal-plane array, FPA) djeluju na principu sličnom kao *pushbroom* senzori. Oni ne skeniraju samo dužinu, već i širinu parcele, što obuhvaća dosad najveću površinu koja se može skenirati u određenom vremenu (Licciardi, 2010).

Metode spektralnog odabira u HSY snimanju

HSY spektrometri također se razlikuju po spektralnim načinima odabira (uzimanje slike iz prostora). Oni mogu biti *disperzijski elementi* koji stvaraju sliku pomoću rešetke ili prizme (Fong, 2008). *Sustavi bazirani na filtrima* djeluju tako da se uski pojas spektra može odabrati pomoću optičkog propusnog filtra. Najčešće se koristi linearni varijabilni filtar (LVF), ponekad u kombinaciji s konveksnom rešetkom koja svjetlost rastavlja na snopove (Ksendzov i sur., 1998). Treći je *spektrometar s Fourierovom transformacijom (FTS)* - ovo je adaptacija gdje je zraka iz izvora svjetlosti razdvojena u dva snopa pomoću razdjelnika koji se dalje šalju u zrcala (Linker, 2010). Ta zrcala šalju zrake natrag, one se sastaju na mjestu gdje su se razdvojile i dolazi do njihove

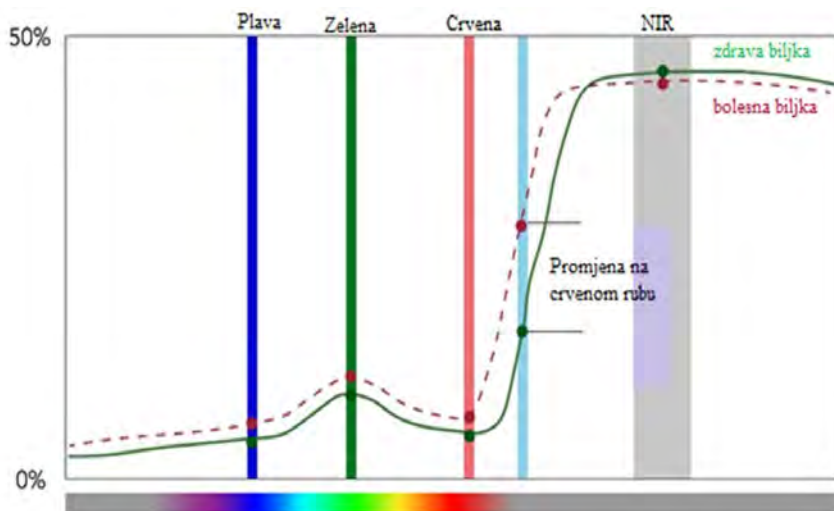
interferencije. Asfarian i sur. (2013) koristili su se ovom metodom za detekciju bolesti truljenja lista riže (*Pyricularia grisea*), crne truleži (*Xanthomonas campestris*) i tungrovirusa (*Tungro Bacilliform Virus*).

Mogućnosti primjene HSY obrade podataka kod prepoznavanja biljnih bolesti

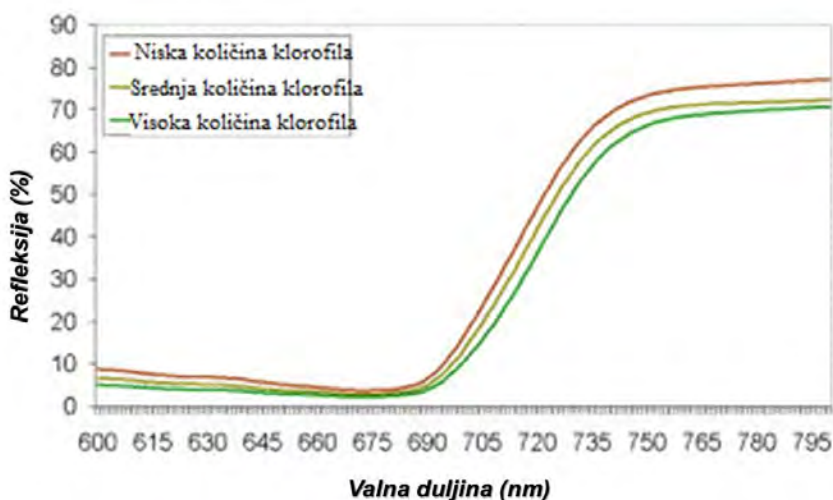
Bolesti lista mogu se kategorizirati ovisno o tome o kakvu se uzročniku radi, odnosno je li on zarazan ili nezarazan. Infektivni inokulum ima svojstvo razmnožavanja unutar domaćina ili na domaćinu i širi se s jednog domaćina na drugog. Za uspješnu zarazu zaraznim patogenima potrebno je imati povoljne ekološke čimbenike. Nezarazne ili neinfektivne bolesti lista jesu bolesti nastale zbog nepovoljnih uvjeta rasta. Kao što i samo ime kaže, nezarazne bolesti ne prenose se na druge biljke i ne razmnožavaju se unutar domaćina (Naikawadi i Amoda, 2013). Simptomi se bolesti znatno razlikuju ovisno o patogenu. Primjerice virusne bolesti karakterizira jedan tip (Garcia-Ruiz, 2019), bakterioze drugi (Sundin i sur., 2016), a gljivične bolesti treći tip simptoma (Jain i sur., 2019). Kvaliteta lista na nekoj biljci ovisi o mnogim čimbenicima iz kojih je nastao ili koji utječu na njega: sjeme iz kojeg je rastao, uvjeti presađivanja, tehnologija, rokovi branja i tako dalje (Dhingra i sur., 2017).

Mogućnosti primjene HSY obrade podataka kod prepoznavanja biljnih bolesti

Za prepoznavanje spektralnih značajka koje su jedinstvene po kemijskim i fizičkim svojstvima za objekt koji se promatra, HSY spektrometri dobivaju podatke u području visokospektralne rezolucije. To je od velike koristi za agronomiju, pogotovu u područjima praćenja rasta usjeva, otkrivanja bolesti i procjenjivanja kvalitete vode. Listovi sadrže stanice spužvastog mezofila koji snažno reflektira infracrvene valne duljine u području gotovo vidljivog infracrvenog spektra (NIR). U vidljivom području refleksija je jako mala zbog apsorpcije svjetla potrebnog za fotosintezu od strane klorofila. Koristeći spektrometar, na granici vidljivog i gotovo vidljivog spektra, od 650 do 800 nm, može se pronaći linija maksimalnog gradijenta poznata pod nazivom crveni rub (Slika 4). Pomoću refleksije na tom se rubu može odrediti količina klorofila u listu (Slika 5.) i koncentracija dušika, pa se stoga može osim biljnih bolesti odrediti i razina dušičnog stresa (Ahmed i sur., 2016).



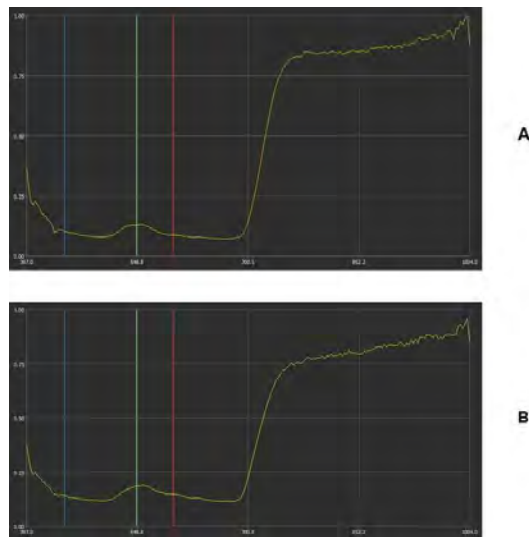
Slika 4. Crveni rub i razlike u refleksiji zdrave i bolesne biljke (Izvor: Ahmed i sur., 2016)
Figure 4 Red edge and differences in the reflection of healthy and diseased plants
 (Source: Ahmed et al., 2016)



Slika 5. Odnos refleksije lista i količine klorofila u njemu (Izvor: Ahmed i sur., 2016)
Figure 5 The relationship between leaf reflection and the amount of chlorophyll in it
 (Source: Ahmed et al., 2016)

Haboudane i sur. (2002) ustanovili su da prisutnost klorofila u tkivu lista znatno utječe na elektromagnetski spektar u RGB-u, pogotovu na području plavih (450 nm) i crvenih (670) valnih duljina. Također uspostavlja vezu između koncentracije dušika u listu i količine klorofila. U posljednjih nekoliko godina HSY tehnologija koristi se u otkrivanju gorkih pjega na plodovima jabuke (Nicolai i sur., 2006). Abu-Khalaf i Salman (2014) u svom radu koriste se

spektroskopijom vidljivog i gotovo vidljivog infracrvenog spektra za predviđanje razvoja bolesti paunovog oka (*Spiloacea oleaginea*) na maslini. Primjenjujući više metoda klasifikacije, u 91 % slučajeva uspješno su predvidjeli bolest. Na slici 6. prikazane su promjene u refleksiji na crvenom rubu kod zdrave masline i masline zaražene paunovim okom, *S. oleagina*, dobivene istraživanjima u sklopu projekta Smart Agriculture Network, 2019.



Slika 6. Razlike u refleksiji na crvenom rubu između zdrave masline (A) i masline zaražene paunovim okom (B), (Izvor: Smart Agriculture Network (2019), interni materijal)


Figure 6 Difference in reflection at the red edge between a healthy olive (A) and an olive infected with a peacock eye (B) (Source: Smart Agriculture Network (2019), internal material)

Bauriegel i Giebel (2011) u svom radu navode kako je primjena HSY snimanja pomoglo pri uočavanju ranih stadija razvoja gljivica iz roda *Fusarium* na žitaricama, pogotovu u stadiju mliječne zriobe. Autori su proučavali valne duljine od 500 do 533 nm, 560 do 675 nm, 682 do 733 nm i 927 do 931 nm. Klasifikacija je izvršena SAM metodom, koja će biti detaljnije objašnjena u nastavku ovog rada. Preciznost klasifikacije bila je 87 %. Ahmed i sur. (2016) navode kako se razmnožavanje patogena može vidjeti još u vidljivom spektru, dok se degradacija klorofila može vidjeti na crvenom rubu. U kratkovalnom infracrvenom spektru (680 do 800 nm) mogu se vidjeti prvi simptomi promjene boje, odnosno posmeđivanje lista, a na gotovo vidljivom infracrvenom spektru (1.400 do 1.600 nm i 1.900 do 2.100 nm) vide se znakovi suhoće i stresa biljke.

Mogućnosti primjene HSY obrade podataka kod prepoznavanja biljnog stresa

Odstupanja od prosječnih ekoloških uvjeta, poput suše, mogu izazvati stres biljaka. Biljke u stresu imaju do 22 % manji prinos u usporedbi sa zdravim biljkama (Behmann i sur., 2014). Suša je glavni čimbenik koji uzrokuje stres biljaka. Ovisno o vrsti biljke, taj stres dolazi ranije ili kasnije do izražaja. Suša je stanje u kojem u biljci nedostaje manji ili veći dio vode potrebne za njen daljnji rast i/ili razvoj (Römer i sur., 2012). Prepoznatljiv je simptom stresa izazvanog sušom kloroza lista koja se vidi u promjeni lista iz zelene u žutu. Do ove promjene dolazi jer su razine refleksije zelenog i crvenog svjetla na istoj razini, te dolazi do njihovog miješanja u nijanse žute boje (VetriDeepika i sur., 2016). Ove se promjene mogu prije uočiti HSY analizom nego ljudskim okom. Stres također može biti izazvan nedostatkom hraniva, zbog bolesti ili napada štetočina, stoga ga je korisno proučavati i u fitomedicini.

Novija metoda koja se koristi za analizu stresa je maksimalizacija volumena simpleksa ili SiVM (*Simplex Volume Maximization*). Ubraja se u skupinu nenadgledanih metoda koje se koriste podacima iz cijelog spektra (Römer i sur., 2012). Metoda analizira čitav spektar i postupno ga skraćuje dok ne ostanu valne duljine između 400 i 900 nm u kojima se mogu pronaći podatci o stresu. VetriDeepika i sur. (2016) u svom su radu opisali prepoznavanje stresa u tropskih biljaka pomoću HSY analize. Na slici 7. prikazana je razlika između zdravog lista (A) i lista u stresu (B) u HSY dijelu. Zdravi list je svježije otkinut, dok je drugi list izložen sušenju tijekom 12 sati na sobnoj temperaturi. Autori su promatrali biljke u punom spektru od 380 do 1.023 nm, s time da su se za istraživanje koristile valne duljine od 400 do 1.000 nm posložene u 477 snopa. Refleksija zdravih biljaka bila je mnogo veća u spektru od 750 do 1.000 nm zbog veće količine vode u njima.



Slika 7. Zdravi list (1A) i list u stresu (1B). Isto lišće u HSY slici prikazano je u desno (2A, 2B) (Izvor: VetriDeepika i sur., 2016)

Figure 7 Healthy leaf (1A) and a stressed leaf (1B). The same leaves in the HSY image are right (2A, 2B) (Source: VetriDeepika et al., 2016)

Kim i sur. (2011) također su provodili istraživanje o biljnom stresu na mladim stablima jabuke u stakleničkom uzgoju. Stabla su bila izložena različitim količinama poljskog kapaciteta vode (100 %, 90 %, 75 %, 60 % i 40 %). Rezultati

analize HSY slika pokazali su da je došlo do povećanja refleksije zelene i crvene boje na duljinama između 750 i 1.000 nm kod 60 % i 40 % poljskog kapaciteta, dok ostala stabla nisu pokazala znakove stresa i označena su zdravima.

Mogućnosti primjene HSY obrade podataka kod prepoznavanja napada štetnika

Najveće je područje primjene HSY obrade podataka u otkrivanju zaraza štetnicima na uskladištenim žitaricama. Singha i sur. (2009) postižu klasifikaciju od 85 do 100 % preciznosti u utvrđivanju razlike između zdravih zrna pšenice i zrna pšenice koja su vidljivo oštećena štetnicima *Sitophilus oryzae*, *Rhizopertha dominica*, *Cryptolestes ferrugineus* i *Tribolium castaneum*. Zrna su skenirana u valnom području od 1.000 do 1.600 nm pomoću NIR HSY sustava za snimanje. Iduće godine Singha i sur. (2010) klasificiraju zdrava zrna i zrna pšenice oštećena hranjenjem *Sitophilus oryzae*, *Rhizopertha dominica*, *Cryptolestes ferrugineus* i *Tribolium castaneum* pomoću HSY (NIR) u rasponu valnih duljina 700 do 1.100 nm i RGB sustavom. S najvećom preciznošću i točno identificiraju 96,4 % zdravih i 91 do 100 % oštećenih zrna pšenice. Kalirameshab i sur. (2013) klasificiraju nezaražena zrna mungo graha i zrna zaražena različitim stadijima *Callosobruchus maculatus*, slikana pomoću HSY u blizini infracrvene (NIR) boje u području valnih duljina od 1.000 do 1.600 nm u intervalima od 10 nm. Valne duljine koje smatraju značajnima jer odgovaraju najvećim opterećenjima zaraze bile su 1.100, 1.290 i 1.450 nm. Prosječna točnost klasifikacije za nezaražena zrna bila je veća od 85 %, odnosno 82 % za napadnuta zrna mungo graha. Sa svježim voćem i oštećenjima na plodu, osobito na otvorenom, ima malo istraživanja. Wang i sur. (2011) mjerenjem HSY refleksije u spektralnom području valnih duljina od 400 do 720 nm otkrivaju vanjska oštećenja od kukaca na plodovima žižule. Više od 98 % netaknutih žižula i 94 % žižula napadnutih kukcima točno je prepoznato analizom vizualnih podataka, a ukupna točnost klasifikacije bila je oko 97 %. Mehanička su oštećenja pomoću HSY tehnologije pogodna za prepoznavanje, međutim nije uvijek jednostavno potvrditi uzrok tog oštećenja. HSY tehnologija obrade vizualnih podataka može imati primjenu u uskladištenim prostorima, sortirkama voća i povrća, ali za primjenu na otvorenom, zasad, manje. U sklopu projekta SAN (2019.) otpočela su istraživanja plodova masline oštećenih maslininom muhom *Bactrocera oleae* koja su specifična po izgledu mehaničkog oštećenja. Rezultati se očekuju.


Tehnike korištene/upotrebljavane/primjenjivane u HSY analizi slika

Najvažnije tehnike primjenjivane u HSY analizi, a koje su pod nadzorom umjetne inteligencije, jesu daljinsko istraživanje, umjetne neuronske mreže i konvolucijske neuronske mreže.

Daljinska istraživanja – *Remote sensing* omogućuju učinkovit pregled površina većih razmjera koje su zahvatile bolesti. Za detekciju postoje dva glavna

pristupa: spektrometrima i optičkim, odnosno vizualnim instrumentima. Spektrometrijske metode omogućuju jako rano otkrivanje razvoja bolesti. Primjerice razvoj fitofitore (*Phytophthora infestans*) u krumpiru može se vidjeti mnogo ranije u infracrvenom dijelu spektra zbog promjene reflektivnih svojstava krumpira, dok se te promjene uočavaju znatno kasnije u vizualnom dijelu spektra (Ganchenko i sur., 2012). Optičke se metode mogu provoditi zasebno ili u kombinaciji sa spektrometrima, što daje najbolje rezultate. Daljinska istraživanja nastala su na principu globalnog položajnog sustava (GPS), uz dodatak posebnih senzora, zračnih slika i satelitskog snimanja te posebnih softwera temeljenih na geografsko-informacijskom sustavu (GIS), napravljenih specifično za obradive površine (Zurmotai, 2016). Osnovni nedostatak ove tehnologije izazivaju atmosferski čimbenici između objekta koji se snima i senzora, odnosno spektrometra (Audebert i sur., 2019).


Sastavni dijelovi uspješnog prepoznavanja objekata (štetnih organizama) jesu metode i algoritmi za predprocesiranje i selekciju značajka objekata u uzgojnom prostoru uz modele umjetne neuronske mreže (*Artificial neural network* – ANN) za grupiranje podataka i klasifikaciju bolesti (Naikawadi i Amoda, 2013). ANN napravljanje su od mreže umjetnih neurona koji su nastali po uzoru na biološke procese ljudskog mozga i svrstavaju se u nadgledane mreže. Neuronsku mrežu dovoljno je jednom naučiti da se zna što treba napraviti kako bi uspješno odrađivala svoje aktivnosti. Sve informacije koje mreža nauči, koristi u prepoznavanju budućih zadataka, što omogućuje pronalaženje odgovora čak i kad su ulazni podatci nepotpuni ili djelomice netočni. Budući da je mreža sposobna koristiti starije podatke za pronalaženje uzoraka i odgovora u novijim problemima, logično je zaključiti da njena uspješnost eksponencijalno raste s većim brojem unesenih podataka (Dahikar i Rode, 2014). Mreža se sastoji od ulazne i izlazne komponente između kojih se nalaze višeslojne mreže ili skriveni slojevi. Budući da su slične mozgu, mreže djeluju na sustavu pamćenja točnih i netočnih odgovora, pa tako točne šalju naprijed prema izlaznom sloju neurona, dok netočne vraćaju natrag i njima se koriste za primjer negativnog procesiranja podataka. ANN mogu naći vezu između ulazne i izlazne komponente bilo kojeg procesa, čak i ako podatci nisu u izravnoj linearnoj vezi. S obzirom na ulazne podatke i vrstu problema, ANN može naći jedan ili više odgovora (Raju i sur., 2011). Na slici 8. prikazan je primjer konfiguracije ANN-a s trima slojevima: ulaznim, skrivenim i izlaznim, skupa sa sinapsama između njih. Ovakve mreže imaju bolje vještine procesiranja podataka od bilo kakvih ostalih vrsta računala, a mreža sama može pronaći algoritme za rješavanje sličnih problema. ANN je posebno prikladan za situacije kada imaju više vremena za pronalaženje odgovora, primjerice za predviđanje napada štetnika u realnom vremenu tijekom vegetacije.



Slika 8. Konfiguracija neuronske mreže s ulaznim, skrivenim i izlaznim slojevima, skupa sa sinapsama (weights) koje ih povezuju (Izvor: Raju i sur., 2011)

Figure 8 Neural network configuration with input, hidden, and output layers, along with the synapses (weights) that connect them (Source: Raju et al., 2011)

Na grafu 1. prikazani su koraci u HSY analizi slike. Analiza započinje slikanjem uzorka HSY kamerom. Nakon toga slike idu na predprocesiranje, što uključuje filtriranje i segmentaciju te na izdvajanje značajka poput boje i teksture. Posljednji dio metode uključuje klasifikaciju pomoću ANN-a.



Grafikon 1. Analiza HSY slika koristeći ANN (Izvor: A. Zdrilić)

Figure 1 HSY image analysis using ANN (Source: A. Zdrilić)

Ulazne slike su one koje na sebi sadrže podatke predmeta analize, pri čemu se obavlja filtracija korisnih od nekorisnih slika. Zatim se slike uzorka unose u bazu podataka.

Baza podataka sadrži sve slike koje se koriste za vježbanje ANN-a i za testiranje prepoznavanja zaraženih biljaka. Ovisno o veličini uzorka, broj slika može varirati od stotine do gotovo tisuću. Baza podataka ima ključnu ulogu u analizi slike jer kvaliteta klasifikatora ovisi o količini podataka koju uzme iz baze.

Predprocesiranje slike uključuje skup operacija kojima se poboljšavaju slike tako što se neželjeni čimbenici na slici, poput distorzije ili zamućenosti, uklanjaju, a poželjni se čimbenici pojačavaju kako bi došli do izražaja. Važno je napomenuti kako se ovim procesima ne povećava količina podataka u slici koja se šalje u klasifikator, već se samo manipulira određenim značajkama slike. Postoje tri koraka predprocesiranja i koriste se ovisno o vrsti analize koju provodimo (Badnakhe i Deshmukh, 2011).

1. Rezanje slike služi za odvajanje objekta interesa od ostatka pozadine, odnosno odvajanje važnog dijela slike od nevažnog.

2. Izravnavanje slike pretvara slike niske kvalitete u visokokvalitetne pomoću raznih računalnih softvera, opet ovisno o analizi koja se provodi.

3. Poboljšanje slike jedan je od najvažnijih postupaka u analizi slike. Glavna je svrha istaknuti detalje koji se slabije vide na slici ili izmijeniti kontrast slike dok se ne dobije željeni rezultat koji se može dalje obrađivati.

Na HSY slici svaki piksel predstavlja određenu valnu duljinu, što omogućuje popravljavanje deformiranih piksela tako da se takvom pikselu pridodaje srednja vrijednost valnih duljina susjednih piksela. Pošto je predprocesiranje gotovo, slika se sprema u popravljenom obliku i šalje natrag u bazu podataka. Postupak se ponavlja sve dok slika u potpunosti nije spremna za sljedeći korak analize, a to je segmentacija slike.


Segmentacija je proces koji pojednostavnjuje ili mijenja prikaz slike u oblik koji ima više smisla i lakši je za analizirati za neuronsku mrežu. Također se procesom segmentacije izdvajaju značajke koje su predmet analize od pozadine, primjerice odvajanje zaraznih pjega na listu od zdravog dijela lista. Budući da je od tako velikog značaja, segmentacija ima ključnu ulogu u procesiranju slike. Na slici 9. prikazan je primjer ulazne i segmentirane slike lista graha zaraženog bolesti *Alternaria* spp., to jest koncentričnom pjegavosti (Singh i Misra, 2017).



Slika 9. Ulazna slika lista graha zaraženog gljivičnom bolesti koncentrična pjegavost (*Alternaria* spp.), (lijevo) i segmentirana slika istog lista (desno), (Izvor: Singh i Misra, 2017)
Figure 9 Input image of a bean leaf infected with the fungal disease concentric spotting (*Alternaria* spp.) (left) and a segmented image of the same leaf (right) (Source: Singh and Misra, 2017)

Izdvajanje značajka slike slijedi nakon segmentacije. Ovisno o segmentiranim informacijama, potrebno je izolirati važne podatke. Važnost je ovog postupka u tome što omogućuje odabir važnijih od manje važnih značajka i smanjivanje ukupne količine podataka tako što se dijele u nekoliko setova (Gawande, 2014).

Klasifikacija značajka slike posljednji je korak. Koristeći se znanjem iz prijašnjih testova, ANN traži sličnosti između starih i novih podataka i određuju koji dijelovi slike opisuju zaraženi, a koji zdravi dio biljke na slici. Na slici 10. prikazan je konačni rezultat analize slike za bolest koncentrične pjegavosti (*Alternaria* spp.) na listu graha (Singh i Misra, 2017).



Slika 10. Konačna analiza slike lista graha zaraženog koncentričnom pjegavosti (*Alternaria* spp.). Desno je prikazana izlazna slika na kojoj su označeni samo zaraženi dijelovi lista (Izvor: Singh i Misra, 2017)


Figure 10 Final image analysis of bean leaf infected with concentric spot (*Alternaria* spp.). The output image on which only the infected parts of the leaf are marked is shown on the right (Source Singh and Misra, 2017)

Kulkarni i Patil. (2012) također su predstavili metodologiju za rano i precizno otkrivanje zaraza s koncentričnom pjegavosti (*Alternaria* spp.), bakterijskom

pjegavosti izazvanom bakterijom *Xanthomonas campestris* i crnom pjegavosti koju izaziva gljiva *Colletotrichum lindemuthianum*. Za klasifikaciju su se koristili klasifikatorom temeljenim na umjetnoj mreži, a za izdvajanje značajka koristili su se filtrom.

Budući da tehniku iz teorije nije u potpunosti moguće prenijeti u stvarnost zbog nedovoljno razvijene tehnologije, kao najveći problem navodi se potrošnja velike količine vremena. Naime klasifikatorima je potrebno mnogo vremena za analizu spektralnih snopova, obradu slika i podjelu biljaka na zdrave i zaražene.

Konvolucijske neuronske mreže (*Convolutional neural network* - CNN) naprednije su mreže i imaju širok spektar primjene - od prepoznavanja teksta i objekata do čitanja dokumenata i često se koriste u društvenim mrežama (Nagasubramanian i sur., 2018). Tijekom nekoliko posljednjih godina trodimenzionalni CNN koristi se za klasifikaciju HSY slika. Ove su mreže nastale kao nadogradnja nad višeslojnim ANN-om. CNN može naučiti probleme osobito brzo i može se koristiti mnogo kompleksnijim algoritmima za razliku od ANN-a. Rješenje problema traži se po slojevima, a ne istodobno na svim neuronima, što uvelike smanjuje vrijeme obrade podataka. Za poljoprivredu to znači da se mogu ranije i točnije pronaći rani simptomi razvoja bolesti na biljkama i uspješnije predvidjeti njihov razvoj (Kamilaris i Prenafeta-Boldú, 2018). Kao i ANN, CNN se također sastoji od ulaznog i izlaznog sloja između kojih se nalaze skriveni slojevi. Glavna razlika leži u konvolucijskim slojevima, slojevima sažimanja i potpuno povezanim slojevima. Mreža započinje s ulaznim slojem, nakon čega dolazi do izmjene jednog ili više konvolucijskih slojeva sa slojevima sažimanja (*max-pooling layers*). Mreža završava s jednim ili više potpuno povezanih slojeva koji dalje odlaze na klasifikaciju (Kopljar, 2016) Jedna od najpoznatijih arhitektura CNN-a je "LeNet-5", prikazana na slici 11.




Slika 11. LeNet-5 arhitektura konvolucijske mreže (Izvor: Wang i sur., 2017)

Figure 11 LeNet-5 convolutional network architecture (Source: Wang et al., 2017)

Konvolucijski slojevi sadrže filtere i različiti broj skrivenih slojeva, ovisno o vrsti analize slike, koji sadrže neurone. Svi su neuroni međusobno povezani u svakom skrivenom sloju, a filter omogućuje da svi neuroni dijele svoje vrijednosti, odnosno težine (*weights*). Ovim mehanizmom neuroni mogu

pretražiti cijeli sloj slike za istu značajku mnogo brže od ANN-a. Izlazna komponenta skrivenog sloja aktivacijska je mapa koja sadrži podatke filtra, odnosno podijeljene vrijednosti neurona (Hu i sur., 2015). Glavna je prednost CNN-a ta što mu treba manje parametara za učenje uzoraka od uobičajene neuronske mreže, brži je i ima veći postotak uspješnosti. Najveći je nedostatak ovih mreža njihova kompleksnost koja se očituje u procesima obrade i klasifikacije podataka. U radu Nagasubramanian i sur. (2018) koristili su se CNN-om za otkrivanje ugljenaste truleži (*Macrophomina phaseolina*) na stabljici soje. Uzorci su prikupljeni 3, 6, 9, 12 i 15 dana nakon početka zaraze te su njihove HSY slike, isto kao i slike zdravih biljaka, sastavljene u HSY informacijsku kocku. Sve biljke slikane za ovaj eksperiment imale su razvijene crvenosmeđe lezije na vrhu stabljike zbog činjenice da se bolest više širi unutrašnjim dijelom stabljike nego vanjskim. Slika 12. prikazana je u RGB formatu kako bi se jasnije vidio razvoj bolesti na stabljici soje i unutar nje.



Slika 12. HSY slika razvijene bolesti truleži soje snimljena//obrađena//klasificirana pomoću konvolucijske neuronske mreže CNN-a konvolucijske neuronske mreže (Izvor: Nagasubramanian i sur., 2017)

Figure 12 HSY image of soybean rot disease development recorded//processed//classified using CNN convolution neural network (Source: Nagasubramanian et al., 2017)

Mreža je uspjela prepoznati, odvojiti i klasificirati zaražene biljke s prosječnom uspješnošću od 95,73 % za sve stadije razvoja bolesti.


Klasifikacija

Klasifikacija snimaka proces je grupiranja određenih dijelova slike u kategorije. Za HSY snimanje to je proces dodjeljivanja vrijednosti individualnim pikselima ili podjela u određene klase. Jedan primjer je podjela piksela koji označavaju zdravi dio biljke na slici i piksela koji označavaju zaraženi dio u

različite klase. Klasifikacija u daljinskom istraživanju znači podjelu terena u klase, primjerice podjele parcele na biljke koje se na njoj nalaze i na dio koji nije bitan za analizu, poput nežive prirode. Zadatak je klasifikatora uspoređivati te vrijednosti piksela i na račun vrijednosti podijeliti ih u određene kategorije. Postoji više vrsta klasifikacija. U radu je predstavljena podjela klasifikacijskih metoda na metode koje se koriste *podatcima odabranih valnih duljina* i metode koje se koriste *podatcima iz cijelog spektra valnih duljina*.

Metode klasifikacije koje se koriste podatcima iz odabranih valnih duljina uzimaju uzorke s poznatim podatcima za klasifikaciju piksela s nepoznatim podatcima. Najčešće se koriste prije opisane neuronske mreže. Prije klasifikacije mreže su podvrgnute poduci tako što im se daju slike s uzorcima biljnih bolesti kako bi one mogle prepoznati iste bolesti na novim slikama, odnosno kako bi vrijednosti piksela sa slika za poduku mogle prepoznati u novim pikselima. Slike koje se koriste za poduku moraju sadržavati poznate biljke s poznatim bolestima kako ne bi došlo do greške pri prepoznavanju (Xie i sur., 2015). Ove metode ovise o ljudskom odabiru pa za njih kažemo da pripadaju nadziranoj klasifikaciji. Odabir određenih valnih duljina ima prednost nad pretraživanjem cijelog spektra jer se pregledava manji broj piksela, što znatno ubrzava proces klasifikacije. Također je cijeli proces analize, identifikacije i klasifikacije bolesti mnogo jednostavniji i brži kad analitičar zna koju bolest traži i na kojem se rasponu valnih duljina može očitati njena prisutnost. Primjerice za otkrivanje bolesti bijele truleži (*Sclerotinia sclerotiorum*) u celeru dovoljno je pregledati samo valne duljine između 1.481 i 1.524 nm, i između 2.022 i 2.395 nm (Huang i Apan, 2006). Dvije najčešće primjenjivane metode koje klasificiraju određene valne duljine jesu klasifikacija *metodom mapiranja spektralnog kuta* i klasifikacija *metodom koeficijenta korelacije*.

Metoda mapiranja spektralnog kuta ili SAM metoda (*Spectral Angle Mapper*) koristi se algoritmom koji uspoređuje spektar nove slike s prije poznatim spektrom odabranim od strane analitičara. Kao rezultat izlazi takozvani „raster“ koji sadrži matricu piksela s vrijednostima spektralnog kuta (Ghaiwat i Arora, 2014). Koristeći se ovom metodom, Rumpf i Mahlein (2010) u svom su istraživanju uspjeli raspoznati bolesne listove šećerne repe od zdravog lišća s prosjekom točnosti od 97 %. Lišće je bilo zaraženo jednom od triju bolesti: hrđom šećerne repe (*Uromyces betae*), pjegavosti lišća (*Cercospora beticola*) ili pepelnicom šećerne repe (*Erysiphe betae*). Na slici 13. prikazane su razlike u refleksiji između zdravog lišća i ranog stadija, kada je manje od 10 % lista zaraženo jednom od navedenih bolesti. Najteže je bilo prepoznati hrđu, jer se u njenom slučaju refleksija ne mijenja mnogo u ranom stadiju razvoja bolesti.



Slika 13. Razlike u refleksiji između zdrave biljke i biljaka zaraženih bolestima *C. beticola*, *U. betae* i *E. betae* (Izvor: Rumpf i Mahlein, 2010)

Figure 13 Differences in the reflection of a healthy plant and plants infected with diseases caused by *C. beticola*, *U. betae* and *E. betae* (Source: Rumpf and Mahlein, 2010)

Metoda koeficijenta korelacije temelji se na izračunu linearnog koeficijenta korelacije između piksela korištenih za poduku i piksela novih slika. Vrijednost korelacije izražava se u rasteru, gdje se svakom paru piksela dodaje vrijednost od 0 do 1. Vrijednost 1 označava potpuno podudaranje piksela (Janeš, 2019). Drugim riječima, pikseli određenih valnih duljina međusobno su uspoređeni koeficijentom linearne korelacije. Što je podudarnost veća, to znači da pikseli sadrže slične ili iste podatke. Moshou i sur. (2004) primijenili su ovu metodu za otkrivanje ranog razvoja žute hrđe pšenice (*Puccinia striiformis*). Pregledavajući jedino valne duljine između 460 i 900 nm, uspješno su prepoznali rani razvoj bolesti u 96 % slučajeva.

Metode koje koriste podatke iz cijelog spektra valnih duljina pregledavaju cijelu HSY sliku. Ideja se temelji na podjeli podataka iz cijelog spektra u klase slične po svojstvima. Neuronska mreža koja ima klasifikator ili računalo uglavnom provodi cijeli postupak, pa se ovakve klasifikacije nazivaju i nenadziranim. Jedina je uloga analitičara odrediti u koliko klasa želi podijeliti podatke (Janeš, 2019).

Ovakve metode traže bolje neuronske mreže koje imaju algoritme za samostalnu obradu, identifikaciju i mapiranje podataka u obliku piksela.

Analiza kvadratne diskriminante metoda je koja klasificira piksele novih slika uspoređujući njihov sadržaj sa slikama s poduke koristeći metodu kvadratne analize diskriminante. Ova je metoda slična metodi koeficijenta korelacije jer se temelji na međuovisnosti klasa. Kvadrirana euklidska udaljenost vektora

između svake klase (udaljenost između dva objekta određuje se kao zbroj kvadriranih razlika vrijednosti za svaku varijablu) učitava se, računalno obradi pomoću algoritma i kao izlaznu vrijednost daje ovisnost varijabla između nula i jedan. Manja euklidska udaljenost znači da je ovisnost dviju klasa veća, što znači da su i podatci u njima sličniji (Šimićev, 2015). Sankaran i Ehsani (2012) koristili su se ovom metodom u svom istraživanju o otkrivanju sušenja kore avokada (*Raffaëlea lauricola*). Metoda se pokazala uspješnom u otkrivanju i predviđanju bolesti u 94 % slučajeva.

ZAKLJUČAK

Precizna poljoprivreda jedna je od najbrže rastućih grana gospodarstva. Nove metode suzbijanja štetnih organizama trebaju se temeljiti na pravovremenoj i u realnom vremenu prognoziranoj pojavi štetnika. Precizna poljoprivreda u jednom svojem segmentu – vizualnoj obradi podataka uz primjenu AI-a - daje sve bolje rezultate kao odgovor na prethodnu potrebu. Obrada RGB i HSY vizualnih zapisa najviše se u fitomedicini primjenjuje u fitopatologiji, herbologiji i u području biljnog stresa, manje u prognozi pojave štetnika. Ako i da, onda više u uskladištenim i zaštićenim prostorima. Metode analize vizualnih podataka razlikuju se ovisno o vrsti istraživanja i osobi koja ih provodi, a najčešće uključuju umjetne neuronske mreže ANN i konvolucijske neuronske mreže CNN. HSY analiza slike još uvijek je novi način obrade podataka u agronomiji. Usprkos tomu pokazala se zasad najboljim i najbržim rješenjem za problem otkrivanja biljnih bolesti i stresa. Utjecaj napada štetnika na biljke zasad ostaje za buduća istraživanja jer još nije razvijena dovoljno dobra HSY tehnologija koja može razlikovati mehanička oštećenja tkiva čije je podrijetlo nepoznato.

Zahvala

Rad je izrađen u sklopu projekta SAN (Smart Agriculture Network), odobrenog na natječaju IRI (istraživanje, razvoj i inovacije) „Povećanje razvoja novih proizvoda i usluga koji proizlaze iz aktivnosti istraživanja i razvoja (KK.01.2.1.01.0100)“. Projekt je sufinancirao EU iz Europskog fonda za regionalni razvoj (ERDF). Zahvaljujemo Alenu Dabčeviću koji je pomogao kod strukturiranja pregleda literature s obzirom na zahtjeve koji su stavljeni pred projekt SAN u dijelu fitomedicine. Ovaj je pregledni rad proizašao iz završnog rada studenta Anđela Zdrilića „Tehnike hiperspektralne analize za rano otkrivanje i klasifikaciju uzročnika biljnih bolesti“ obranjenog 21. rujna 2020. na Sveučilištu u Zadru pri Odjelu za ekologiju, agronomiju i akvakulturu.

LITERATURA

ABU-KHALAF, N., SALMAN, M. (2014). Visible/Near infrared (VIS/NIR) spectroscopy and multivariate data analysis (MVDA) for identification and quantification of olive leaf spot (OLS) disease. Palest. Tech. Univ. Res. J., Vol. 2, 1: 1-8.

AHMED, M. R., YASMIN, J., MO, C., LEE, H., KIM, M. S., HONG, S. J., CHO, B. K. (2016). Outdoor Applications of Hyperspectral Imaging Technology for Monitoring Agricultural Crops. *Biosyst. Eng.*, Vol. 41, 4: 395-407.

ASFARIAN A., HERDIYENI, Y., AUNU R., KIKIN HAMZAH M. (2013). Paddy diseases identification with texture analysis using fractal descriptors based on fourier spectrum. *Proceedings of The International Conference on Computer, Control, Informatics and its Applications (IC3INA)*. Jakarta, Indonesia, 19. – 20. November, 77-81. doi: 10.1109/ic3ina.2013.6819152

AUDEBERT, N., LE SAUX, B., LEFÈVRE, S. (2019). Deep learning for classification of hyperspectral data: A comparative review. *IEEE Trans. Geosci. Remote Sens.*, Vol. 7: 2: 159-173.

BADNAKHE, M., DESHMUKH, P. (2011). An Application of K-Means Clustering and Artificial Intelligence in Pattern Recognition for Crop Diseases, *Proceedings of The International Conference on Advancements in Information Technology With workshop of ICBMG, IPCSIT, IACSIT Press, Singapore*, Vol. 20: 134-138.

BAURIEGEL, E., GIEBEL, A. (2011). Early detection of Fusarium infection in wheat using hyper-spectral imaging. *Comput. Electron. Agr.*, Vol. 75, 2: 304-312.

BEHMANN, J., STREINRÜCKEN, J., PLÜMER, L. (2014). Detection of early plant stress responses in hyperspectral images. *Isprs. J. Photogramm.*, Vol. 93: 98-111.

BOCK C., POOLE G., PARKER P.E., GOTTWALD T. (2010). Plant Disease Severity Estimated Visually, by Digital Photography and Image Analysis, and by Hyperspectral Imaging. *Crit. Rev. Plant. Sci.*, Vol. 29:2, 59-107.

CRESPO, J. L., DURO, R. J., LÓPEZ PEÑA, F. (2003). Gaussian Synapse ANNs in Multi and Hyperspectral Image Data Analysis. *Ieee T. Instrum. Meas.*, Vol. 52, 3: 724-732.

DAHIKAR, S., RODE, S. (2014). Agricultural Crop Yield Prediction Using Artificial Neural Network Approach. *IJIREEICE*, Vol. 2, 1: 683-686.

DHINGRA, G., KUMAR, V., JOSHI, H. D. (2017). Study of digital image processing techniques for leaf disease detection and classification. *Multimedia Tools and Application*, Vol. 77, 15: 19951-20000.

FONG, A. (2008). Advanced photonic tools for hyperspectral imaging in the life sciences, *SPIE Newsroom*. Vol. 10, 2.1200803: 1051.

GANCHENKO, V., DOUDKIN, A., PAWLOWSKI, T., PETROVSKY, A., SADYKHOV, R. (2012). Based on Perceptron Object Classification Algorithms for Processing of Agricultural Field Images. *Modeling and Simulation : MS'2012 : Proc. of the Intern. Conf.*, 2—4 May 2012, Minsk, Belarus. - Minsk: Publ. Center of BSU, 2012. – 178.

GARCIA-RUIZ, H. (2019). When viruses infect plants. *Scientia (Bristol)*, Vol. 123: 40–43.

GAWANDE, U. (2014). An Overview of the Research on Plant Leaves Disease detection using Image. Processing Techniques, *IOSR J. Comput. Eng.*, Vol. 16, 1: 10-16.

GHAIWAT S. N., ARORA P. (2014). Detection and Classification of Plant Leaf Diseases Using Image processing Techniques. *IJRAET*, Vol. 2, 3: 2347 – 2812.

HABOUDANE, D., MILLER, J. R., TREMBLAY, N., ZARCO-TEJADA, P.J. DEXTRAZE, L. (2002). Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote. Sens. Environ.*, Vol. 81, 2-3: 416-426.

HU W., HUANG Y., WEI L., ZHANG, F., HENGCHAO, L. (2015). Deep Convolutional Neural Networks for Hyperspectral Image Classification. *J Sensors*, Vol. 2015: 1-12.

HUANG, J-F., APAN, A. (2016). Detection of Sclerotinia rot disease on celery using hyperspectral data and partial least squares regression. *J. Spat. Sci.*, Vol. 51, 2: 129-142.

JAIN A., SARSAIYA S., WU Q., LU Y., SHI J. (2019). A review of plant leaf fungal diseases and its environment speciation. *Bioengineered.*, Vol. 10: 1, 409–424.

JANEŠ, F. (2019). Klasifikacija hiperspektralnih snimaka metodom mapiranja spektralnog kuta i koeficijenta korelacije. Diplomski rad. Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva.

KALIRAMESHAB S. CHELLADURAI V. JAYASA D.S. ALAGUSUNDARAMB K. WHITE N.D.G. FIELDS P.G. (2013). Detection of infestation by *Callosobruchus maculatus* in mung bean using near-infrared hyperspectral imaging. *J. Stored Prod. Res.*, Vol. 52, 107-111.

KAMILARIS, A., PRENAFETA-BOLDÚ, F. X. (2018.): A review of the use of convolutional neural networks in agriculture. *J. Agr. Sci.*, Vol. 156, 3: 312-322.

KIM, Y., GLENN, D. M., PARK, J., NGUGI, H. K., LEHMAN, B. L. (2011). Hyperspectral image analysis for water stress detection of apple trees. *Comput. Electron. Agr.*, Vol. 77, 2: 55-160.

KOPLJAR, D. (2016). Konvolucijske neuronske mreže. Završni rad. Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva.

KSENDZOV, A., CWIK, T., LA BAW, C., MULLER, R., MAKER, P. (1998). Wedge Filters for Spectral Imaging in the Near IR Using Metal Grids, Proceedings of SPIE. Proceedings of SPIE - The International Society for Optical Engineering, August 1998, Vol. 3354, Infrared Astronomical Instrumentation, Astronomical Telescopes and Instrumentation, Kona, HI, United States doi.org/10.1117/12.317258.

KULKARNI, A., PATIL, R. (2012). Applying image processing technique to detect plant diseases. *Int. J. Mod. Eng. Res. Technol.*, Vol. 2, 5: 3661-3664.

KURZ, T., BUCKLEY S. (2016). A review of hyperspectral imaging in close range applications. *Int. Arch. Photogramm.*, Vol. 41: 865-870.

LICCIARDI, G. (2010). Neural network architectures for information extraction from hyper-spectral images. Doktorska disertacija. University of Rome, 29-36.

LINKER, R. (2010). Application of FTIR Spectroscopy to Agricultural Soils Analysis. In *Fourier Transforms: New Analytical Approaches and FTIR Strategies*, Nikolic, G. (ur.), BoD – Books on Demand, (online press, InTech, 01, April, 2011), 385-404.

LOWE, A., HARRISON, N., FRENCH, A. (2017). Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. *Plant methods*, Vol. 13, 1: 1-12.

MIDDLETON SPECTRAL VISION, <https://www.middletonspectral.com/resources/what-is-hyperspectral-imaging/> (pristupljeno 10.8.2020.)

MISHRA S., MISHRA, D., SANTRA, G. (2016). Applications of Machine Learning Techniques in Agricultural Crop Production: A Review Paper. *Indian IJST*, Vol. 9, 38: 1-14.

MOSHOU, D., BRAVO, C., WEST, J., RAMON, H. (2004). Early Disease Detection in Wheat Fields using Spectral Reflectance. *Biosyst. Eng.*, Vol. 84, 2: 137-145.

NAGASUBRAMANIAN, K., JONES, S., SINGH, A. K., SINGH, A., GANAPATHYSUBRAMANIAN, B., SARKAR, S. (2018). Explaining hyperspectral imaging based plant disease identification: 3D CNN and saliency maps. arXiv preprint arXiv:1804.08831.

NAIKAWADI, S., AMODA, N. (2013). Advances in Image Processing for Detection of Plant Diseases. *IJAIEEM*, Vol 2, 11: 168-172.

NICOLAÏ, B. M., LÖTZE, E., PEIRS, A., SCHEERLINCK, N., THERON, K.I. (2006). Non-destructive measurement of bitter pit in apple fruit using NIR hyperspectral imaging. *Postharvest Biol. Tec.*, Vol. 40, 1: 1-6.

ORTENBERG, F., THENKABAIL, P., LYON, J. HUETE, A. (2011). *Hyperspectral Remote Sensing of Vegetation*. New York, CRC Press. USA.

PAOLETTI, M.E., HAUT, J. M., PLAZA, J., PLAZA, A. (2018). A new deep convolutional neural network for fast hyperspectral image classification. *ISPRS J. Photogramm*, Vol. 145: 120–147.

PEÑUELAS, J, FILELLA, I. (1998). Visible and near-infrared reflectance techniques for diagnosing plant physiological status. *Trends. Plant. Sci.*, Vol. 3, 4: 151-156.

POLDER, G., YOUNG, I., HEIJDEN, G. (2003). Calibration and characterisation of imaging spectrographs. *J. Near. Infrared. Spec.*, Vol. 11, 3: 193-210.

QIN, J., CHAO, C., KIM, M., LU, R., BURKS, T. (2013). Hyperspectral and multispectral imaging for evaluating food safety and quality. *J. Food Eng*, Vol. 18, 2: 157-171.

RAJU, M., SRIVASTAVA, R., BISHT, D., KUMAR, A. (2011). Development of Artificial Neural-Network-Based Models for the Simulation of Spring Discharge. *Lect. Notes. Artif. Int.*, Vol. 2011: 1-11.

RÖMER, C., WAHABZADA, M., BALLVORA, A., PINTO, F., ROSSINI, M., PANIGADA, C., BEHMANN, J., L ON, J., THURAU, C., BAUCKHAGE, C., KERSTING, K., RASCHER, U., PL MER, L. (2012). Early drought stress detection in cereals: Simplex Volume Maximization for hyperspectral image analysis. *Funct. Plant. Biol.*, Vol. 39, 11: 878-890.

RUMPF, T., MAHLEIN, A. K. (2010). Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. *Plant. Dis.*, Vol. 100, 2: 241-251.

SAIZ-RUBIO, V., ROVIRA-MÁS, F. (2020). From Smart Farming towards Agriculture 5.0: A Review on Crop Data Management. *Agronomy* Vol. 10, 2: 207.

SAN (Smart Agriculture Network). (2019). Projekt IRI (istraživanje, razvoj i inovacije) „Povećanje razvoja novih proizvoda i usluga koji proizlaze iz aktivnosti istraživanja i razvoja. (KK.01.2.1.01.0100)“.

SANKARAN, S., EHSANI, R. (2012). Evaluation of Visible-Near Infrared Reflectance Spectra of Avocado Leaves as a Non-destructive Sensing Tool for Detection of Laurel Wilt. *Plant. Dis.*, Vol. 96, 11: 1683-1689.

SAVARY, S., FICKE, A., AUBERTOT, J. N., HOLLIER, C. (2012). Crop losses due to diseases and their implications for global food production losses and food security. *Food. Secur.*, Vol. 4: 519-537.

SHAW, G. A., BURKE, H. K. (2003). *Spectral Imaging for Remote Sensing*. Lincoln Laboratory Journal., Vol. 14, 1: 3-27.

SINGH, V., MISRA, A. K. (2017). Detection of Plant Leaf Diseases Using Image Segmentation and Soft Computing Techniques. *Inf. Process. Agric.*, Vol. 4, 1: 41-49.

SINGHA, C. B., JAYASA, D. S., PALIWALA, J., WHITE, N. D. G. (2009). Detection of insect-damaged wheat kernels using near-infrared hyperspectral imaging. *J. Stored Prod. Res.* Vol. 45, 3: 151-158.

SINGHA, C. B., JAYASA, D. S., PALIWALA, J., WHITE, N. D. G. (2010). Identification of insect-damaged wheat kernels using short-wave near-infrared hyperspectral and digital colour imaging. *Comput. Electron. Agric.*, Vol. 73, 2: 118-125.

SMART AGRICULTURE MARKET Smart Agriculture Market by Agriculture Type, Hardware | COVID-19 Impact Analysis|MarketsandMarkets™ (pristupljeno: 08. 02. 2021.)

SUNDIN G., CASTIBLANCO L., YUAN X. (2016). Bacterial disease management: challenges, experience, innovation and future prospects. *Mol. Plant Pathol.* Vol. 17(9): 1506–1518.

ŠIMIČEV, D. (2015). Računalno učitavanje višesegmentnih displeja. Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Diplomaska radionica FER, Zagreb, 9. srpnja 2015. https://www.fer.unizg.hr/_download/repository/18-Simicev-poster.pdf (pristupljeno 16.01.2021.)

UJEVIĆ ANDRIJIĆ, Ž. (2019). Umjetne neuronske mreže. *Kem. Ind.*, Vol. 68, 5-6: 219–220.

VETRIDEPIKA, K., JOHNSON, A., LAFRULHUDHA, M., RAMYA, M. (2016). Enhancement of Precision Agriculture Using Hyperspectral Imaging. National Conference on Emerging Trends in Electronics, Instrumentation, Automation & Control (ETEIAC) organized by Karpagam College of Engineering, 11th Mar, IJTRD, pp. 19-21.

WANG, J., NAKANO, K., OHASHI, S., KUBOT,Y., TAKIZAWA, K., SASAKI, Y. (2011) Detection of external insect infestations in jujube fruit using hyperspectral reflectance imaging. *Biosyst. Eng.*, Vol. 108, 4: 345-351.

WANG, J., QIAN, Y., YE, Q., WANG, B. (2017): Image retrieval method based on metric learning for convolutional neural network. *IOP Conf. Ser.: Mater. Sci. Eng.*, Vol. 231, 1: 1-7.

XIA, J., TANG, Z., LI, H. (2011): An environment monitoring system for precise agriculture based on wireless sensor networks. 7th Conference on Mobile Ad-Hoc and Sensor Networks, IEEE, pp. 28-35.

XIE, C., SHAO, Y., LI, X., HE, Y. (2015). Detection of early blight and late blight diseases on tomato leaves using hyperspectral imaging. *Sci. Rep.*, Vol. 5, 1: 1-11.

ZURMOTAI, N. (2016). GIS, Remote Sensing and GPS: their activity, Integration and Fieldwork. The collection of materials of the International scientific-practical conference on 28-29 April 2016 Almaty. At: Kazakh Leading Academy of Architecture and Civil Engineering, Almaty, Kazakhstan.