

# Tehnike hiperspektralne analize za rano otkrivanje i klasifikaciju uzročnika biljnih bolesti

---

**Zdrilić, Anđelo**

**Undergraduate thesis / Završni rad**

**2020**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Zadar / Sveučilište u Zadru**

*Permanent link / Trajna poveznica:* <https://um.nsk.hr/um:nbn:hr:162:074515>

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

*Download date / Datum preuzimanja:* **2025-03-09**



**Sveučilište u Zadru**  
Universitas Studiorum  
Jadertina | 1396 | 2002 |

*Repository / Repozitorij:*

[University of Zadar Institutional Repository](#)



Sveučilište u Zadru

Odjel za ekologiju, agronomiju i akvakulturu

Primijenjena ekologija u poljoprivredi

**Andelo Zdrilić**

**Tehnike hiperspektralne analize za rano otkrivanje i  
klasifikaciju uzročnika biljnih bolesti**

**Završni rad**

Zadar, 2020.

Sveučilište u Zadru

Odjel za ekologiju, agronomiju i akvakulturu  
Primijenjena ekologija u poljoprivredi

Tehnike hiperspektralne analize za rano otkrivanje i klasifikaciju  
uzročnika biljnih bolesti

**Završni rad**

Student/ica:

Anđelo Zdrilić

Mentor/ica:

Doc.dr.sc. Tomislav Kos

Zadar, 2020.



## Izjava o akademskoj čestitosti

Ja, **Anđelo Zdrilić**, ovime izjavljujem da je moj **završni** rad pod naslovom **Tehnike hiperspektralne analize za rano otkrivanje i klasifikaciju uzročnika biljnih bolesti** rezultat mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na izvore i radove navedene u bilješkama i popisu literature. Ni jedan dio mojega rada nije napisan na nedopušten način, odnosno nije prepisan iz necitiranih radova i ne krši bilo čija autorska prava.

Izjavljujem da ni jedan dio ovoga rada nije iskorišten u kojem drugom radu pri bilo kojoj drugoj visokoškolskoj, znanstvenoj, obrazovnoj ili inoj ustanovi.

Sadržaj mojega rada u potpunosti odgovara sadržaju obranjenoga i nakon obrane uređenoga rada.

Zadar, 13. rujna 2020.

## Tehnike hiperspektralne analize za rano otkrivanje i klasifikaciju uzročnika biljnih bolesti

Hiperspektralne analize slika omogućuju lakše određivanje stupnja razvoja biljnih bolesti, klasifikaciju biljaka na zdrave i zaražene, te otkrivanje biljnog stresa. Cilj ovih analiza je pregledati zdravlje većeg broja biljaka, predvidjeti mogućnost razvoja bolesti i stresa bilja, koristeći umjetnu inteligenciju, uz uvjet da su te tehnike brže, bolje i ekonomičnije od ljudskog rada.

Ovaj rad bavi se tematikom detekcije biljnih bolesti i stresa biljaka. Poljoprivredna proizvodnja je od velike važnosti za prehranu ljudi i životinja. Budući da su potrebe za hranom svakim danom sve veće, potrebno je moći uzgajati kvalitetnu biljnu hranu u što većim količinama, s minimalnim štetama. Sa svakim uzgojem dolazi i problematika biljnih bolesti i stresa uzrokovanog vanjskim i unutrašnjim čimbenicima. Takve probleme nije više moguće nadgledati samo ljudskim okom, pogotovo na većim parcelama, pa su se kao rješenje postavile hiperspektralne tehnike, koje automatski analiziraju usjeve preko slika i tako uvelike skraćuju vrijeme i rad inače potreban za otkrivanje prvih simptoma bolesti i stresa.

**Ključne riječi:** biljne bolesti, biljni stres, hiperspektralna analiza, neuronske mreže

Techniques in hyperspectral analysis used for early detection and classification of plant pathogens

Hyperspectral imaging and image analysis enable detection of early stages in development of plant diseases and stress, as well as classification of healthy and diseased plants. The goal of these techniques is to evaluate level of health of plants, and to predict the possibility of development of plant diseases and stress, mostly using artificial intelligence, providing these techniques are faster, better and cheaper than human labour.

This paper explores the themes of detecting plant pathogens and stress. Agricultural production is important in forms of food and feed. As the need for food increases daily, it is necessary to be able to grow quality plant food in as large quantities as possible, with minimal defects. With each cultivating process, comes the problem of plant diseases and stress caused by external and internal factors. Such problems can no longer be monitored by the human eye, especially on larger fields, so hyperspectral techniques have been set up as a solution. Their purpose is to automatically analyse the crops through imaging, and therefore shorten the time and work, otherwise required to detect the first symptoms of plant diseases and stress.

**Keywords:** hyperspectral analysis, neural networks plant diseases, plant stress

## Sadržaj

1. Uvod .....	1
2. Svrha i cilj rada.....	2
3. Razrada .....	3
3.1. Digitalno snimanje slika .....	3
3.2. Hiperspektralna analiza slike .....	5
3.2.1. Senzori korišteni u hiperspektralnoj analizi.....	7
3.2.2. Metode odabira u hiperspektralnom snimanju.....	9
3.3. Biljne bolesti i simptomi .....	10
3.3.1. Otkrivanje bolesti.....	10
3.4. Biljni stres .....	13
3.5. Tehnike korištene u hiperspektralnoj analizi slika.....	15
3.5.1. Daljinska istraživanja – <i>Remote sensing</i> .....	16
3.5.2. Umjetne neuronske mreže (ANN) .....	17
3.5.3. Konvolucijske neuronske mreže (CNN).....	21
3.6. Klasifikacija .....	24
3.6.1. Metode klasifikacije koje koriste podatke iz odabranih valnih duljina .....	25
3.6.1.1. <i>Metoda mapiranja spektralnog kuta</i> .....	25
3.6.1.2. <i>Metoda koeficijenta korelacije</i> .....	26
3.6.2. Metode klasifikacije koje koriste podatke iz cijelog spektra .....	27
3.6.2.1. <i>Analiza kvadratne diskriminante</i> .....	27
4. Zaključak .....	28
5. Literatura .....	29

## 1. Uvod

Poljoprivreda ima ključnu ulogu u svakodnevnom životu jer nam služi kao primarni izvor energije, vode i hranjivih tvari. O njoj ne ovise samo ljudi, već i životinje, a njena potražnja nije samo u obliku hrane, nego i u oblicima koji se mogu koristiti u medicinske svrhe. Tijekom uzgoja iznimno je važno pridavati pažnju biljnim bolestima i stresu, jer oni mogu znatno smanjiti urod. Godišnje propada između 30% i 40% usjeva kroz biljnu proizvodnju (Savary i sur., 2012.). Gubitci zbog bolesti imaju utjecaj na tržište jer je upravo time određen profit uzgajivača i potražnja potrošača.

Precizna poljoprivreda predstavlja nove načine uzgoja, koji postepeno mijenjaju tradicionalnu poljoprivredu. U njoj se promatraju svi čimbenici uzgoja, od okoliša, vode i tla, do vjerojatnosti pojave bolesti i napada štetnika. Koristeći velik broj uzgojnih uzoraka, utvrđuje se najbolji način uzgoja, pri čemu se obraća pozornost najviše na kvalitetu hrane uz najveći mogući urod (Xia i sur., 2011.). Primarni sektor, uključujući i poljoprivredu, se konstantno mijenja dolaskom novih tehnologija. Jedna od tih tehnologija je i hiperspektralna analiza slika bazirana na tehnikama koje provodi autonomna umjetna inteligencija, neovisna o čovjeku. Ove tehnologije pokazuju bržu obradu podataka i detaljniji pregled bilja, znatno precizniji od pregleda „golim okom“. Upravo zbog toga, precizna poljoprivreda spada u treći val agronomske revolucije. Prvi val je došao s pojavom mehanizacije, a drugi val sa zelenom revolucijom i genetskom modifikacijom biljaka (Saiz-Rubio, Rovira- Más, 2020).

Kako bi se proces pregledavanja, klasifikacije i utvrđivanja biljnih bolesti, pogotovo u ranijim stadijima njihova razvoja, ubrzao i poboljšao, osmišljene su tehnike hiperspektralne analize slike. Ljudski spektar vidljivosti kreće se od 400 do 700 nm. Hiperspektralne metode mogu proširiti taj spektar izvan ljudskoga kako bi ranije i točnije utvrdili simptome biljnih bolesti i prema tome odrediti o kojoj se bolesti radi . Skupovi hiperspektralnih podataka sastavljeni su od 50 do 250 spektralnih snopova uske propusnosti, širine uglavnom od 5 do 20 nm, dok su tradicionalni, ranije korišteni, multispektralni podaci sastavljeni u manje, 5 do 10, ali šire snopove, od 70 do 400 nm (Crespo i sur. 2003.).



## **2. Svrha i cilj rada**

Cilj ovog rada bio je, uz dostupnu literaturu, prikupiti podatke o tehnikama hiperspektralne analize slike za otkrivanje ranih stadija biljnih bolesti i stresa bilja i metodama njihove klasifikacije. Ove metode omogućuju otkrivanje i praćenje razvoja biljnih bolesti i stresa, te predviđanje njihovog širenja.


Svrha ovog rada je, temeljem dostupne literature, objasniti tehnike kojim hiperspektralne metode utječu na poljoprivredu i kojim načinom poboljšavaju poljoprivredu sadašnjosti i budućnosti.

### 3. Razrada

#### 3.1. Digitalno snimanje slika

Za lakše razumijevanje hiperspektralnog snimanja slika, potrebno je prvo shvatiti što je standardno, odnosno digitalno snimanje slika. Boje dolaze iz raznih valnih duljina svjetla. Spektar boja vidljiv ljudskom oku 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 oko sastoji se od triju vrsta specijaliziranih stanica – čunjića, osjetljivih na te boje i njima stimulirani, odnosno, ovisno o energiji valnih duljina ovisi i intenzitet boje, 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 koja čini sliku u digitalnom snimanju. Filter ispred piksela ima ulogu očitavanja valnih duljina za plavu, zelenu ili crvenu boju. Vrijednost valne duljine se zatim zapisuje u informatičkom obliku na piksel (Lowe i sur., 2017.).



Slika 1. Prikaz valnih duljina<sup>1</sup> za hiperspektralno snimanje.

Izvor: Web stranica Middleton Spectral Vision

<sup>1</sup> 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

Hiperspektralno snimanje slike ima mnogo veći spektar očitavanja valnih duljina koji je često promjenjiv i podijeljen u više sekcija. Budući da se radi o biljkama, taj spektar se najčešće proteže od ultraljubičastog svjetla na 250 nm do kratkovalnog infracrvenog svjetla na 2500 nm. Kako bi se stvaranje slike ubrzalo i poboljšalo, hiperspektralne kamere često su fokusirane samo na pojedine dijelove tog spektra, ili se koristi više kamera kako bi se uhvatio cijeli spektar. Uz ultraljubičasto i kratkovalno infracrveno svjetlo, najčešće se promatra još kombinacija gotovo vidljivog i vidljivog infracrveno na duljinama od 400 do 1300 nm, za očitavanje refleksije krutih predmeta, dok se za emisiju plinova promatraju valne duljina srednjeg, od 3000 do 5000 nm, a ponekad i dugovalnog infracrvenog spektra, od 8000 do 12000 nm (Lowe i sur., 2017.).

Digitalno snimljena slika je primjer slike dobivene iz triju različitih i udaljenih pojaseva vidljive svjetlosti, od kojih svaka ima podatak o plavoj, zelenoj ili crvenoj boji. Hiperspektralno snimljena slika sastoji se od stotina pojaseva spektralne svjetlosti koji se nalaze neprekidno jedan do drugog, što rezultira gustim skupom podataka s dovoljno prostorne rezolucije kako bi se jedan list uspješno prikazao stotinama piksela (Lowe i sur., 2017.).

Kako bi se uočile bolesti biljke, analiziraju se valne duljine vidljivog spektra od 400 do 700 za promjene u pigmentaciji lista i valne duljine gotovo vidljivog infracrvenog spektra od 700 do 1300 nm za mezofilne stanice lista. Dehidracija biljke može poremetiti mezofilnu strukturu, pa se za razinu vode u biljnoj stanici analiziraju duljine od 1300 do 2500 nm (Peñuelas J, Filella I., 1998.).

## 3.2. Hiperspektralna analiza slike


Hiperspektralna analiza slike i precizna poljoprivreda su usko povezani upravo zbog mogućnosti prikupljanja što više informacija kako bi uzgoj bilja bio uspješan. Dosadašnja tehnologija korištena u poljoprivredi uključivala je samo digitalne slike, sastavljene od piksela koji informacije nose u obliku zelene, crvene i plave boje. Hiperspektralnom analizom taj spektar je proširen kroz cijeli ljudima vidljiv spektar, kao i valne duljine izvan tog spektra (Xia i sur., 2011.).

Osim prepoznavanja biljnih bolesti i stresa, hiperspektralna analiza ima zadatak prepoznati prave od umjetnih biljaka. Kako bi cijeli postupak prepoznavanja biljke i bolesti bio što točniji, potrebno je prikupiti što više podataka iz što većeg spektra svjetlosti. Slika nastaje tako što svjetlost različitih valnih duljina udara u objekt, apsorbira se, prenosi i raspršuje ovisno o kemijskom sastavu tog objekta. Ono što mi vidimo su zapravo odbijene valne duljine, koje ovise o indeksu loma materijala. Crvenu boju na nekom crvenom predmetu vidimo 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 hiperspektralnom analizom dobijemo još više podataka o objektu, izvan našeg vidljivog spektra, što omogućuje stvaranje još preciznije slike. Procjenjivanje stanja biljke ljudskim okom ovisno je o sposobnosti ocjenjivanja, no ljudi su skloni umoru i subjektivnosti, pa se ovakav način uočavanja biljnih bolesti pokazao nesigurnim. U svrhu poboljšanja analize slika, prvo se koristila multispektralna analiza, no uspostavilo se da je za bolje rezultate potrebno spektar svjetlosti proširiti, te je iz toga došlo do potrebe za hiperspektralnom analizom. Multispektralna analiza je i dalje pouzdana metoda u poljoprivredi. Za razliku od hiperspektralnog, multispektralno slikanje se bazira na trenutno stanje biljaka, što znači da se ne može koristiti za predviđanje razvoja bolesti. Također, multispektralnom analizom se promatra manji broj širih i valnih snopova, slike su manje rezolucije i algoritmi za obradu podataka su jednostavniji. Cilj multispektralne analize je 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.).

Hiperspektralno slikanje je proces kojim se slikama, odnosno pikselima, dodaju brojčane 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 biljne bolesti i okolišnih čimbenika (Mishra i sur., 2016.) .

Kao što je već prije navedeno, hiperspektralna analiza koristi informacije od ultraljubičastog, preko vidljivog, do infracrvenog elektromagnetskog spektra. Kako bi ljudima bilo lakše interpretirati sve te podatke, oni su podijeljeni po snopovima određenih valnih duljina i skupa sastavljeni u takozvanu hiperspektralnu informacijsku kocku, ili skraćeno hiperkocku, za procesiranje i daljnju analizu (Paoletti i sur., 2018.). Takva kocka je sastavljena od slojeva slika, a svaki piksel pojedine slike predstavlja skup informacija za određenu valnu duljinu. Svaki objekt je opisan različitim snopovima valnih duljina, pa kažemo da on ima svoj jedinstveni spektralni potpis (Shaw i sur., 2003.). Na slici 2 prikazan je primjer hiperspektralne kocke, gdje X i Y prikazuju prostorne osi, dok Z prikazuje spektralnu os u kojoj se nalazi hiperspektralni zapis slike.



Slika 2. Prikaz hiperspektralne informacijske kocke (hiperkocke).

Izvor: Timothy R. Gothwal


### 3.2.1. Senzori korišteni u hiperspektralnoj analizi

Hiperspektralna kamera je uređaj koji se koristi za hiperspektralno snimanje. Sastoji se od objektiva, spektrografa i digitalne kamere, koja obrađuje podatke. Kamere se razlikuju ovisno o načinu na koji želimo pregledati parcelu, o proizvođaču i količini podataka koju želimo snimiti. Spektrograf je najvažniji dio kamere jer o njegovoj građi ovisi koje će se valne duljine snimati i na koji način. Svjetlo prolazi kroz konveksnu rešetku ili prizmu na leći, te se dijeli na uske valne duljine i njihova vrijednost se zapisuje na svjetlosni čip u digitalnom dijelu kamere (Polder i sur., 2003.). Hiperspektralni senzori međusobno se razlikuju po broju snopova i rasponu valnih duljina koje obuhvaćaju, propusnosti, prostornoj rezoluciji i površini koju obuhvaćaju, te načinom 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 (Licciardi, G.A. 2010.).

**Whiskbroom senzori** ili elektromehanički senzori karakterizirani su manjim, jednolinijskim detektorom, a koji koriste optiku na osi ili teleskope sa zrcalima koji se kreću cijelom dužinom parcele. Ovakvi senzori slikaju točku po točku te ih na završetku spajaju u jednu sliku (Ortenberg, 2011.). Upravo su po toj kretnji i dobili ime jer podsjećaju na manju metlu koja čisti.

**Pushbroom senzori** su nastali kao nadogradnja na whiskbroom senzore. Analogno prije navedenoj metafori, pushbroom senzori su dobili ime po metli koja zauzima cijelu širinu nekog prostora i tako „čisti“, odnosno skenira, sve ispred sebe. Ovi senzori koriste niz detektora za dvodimenzionalno snimanje u jednom nizu. Letjelice na kojima se nalaze ovi senzori kreću se duž smjera parcele koji skeniraju kako bi u jednom prolazu obuhvatili cijelu sliku. Pushbroom senzori sadrže spektrometre za dobivanje slika u visokoj rezoluciji, te su zbog toga jedni od najčešće korištenih senzora u hiperspektralnom slikanju (Kurz T., Buckley S., 2016.).

**Staring senzori**, ili niz žarišnih točaka (focal-plane array, FPA), djeluju na principu sličnom kao pushbroom senzori, samo što ne skeniraju samo uz dužinu, već i širinu parcele, što obuhvaća dosad najveću površinu koja se može skenirati u određenom vremenu. Dok pushbroom slikanje možemo zamisliti uzimanje više slika i dodavanje jedne na drugu, FPA slikanje više izgleda kao panorama koja skenira i spaja sve u jednu sliku (Licciardi, G.A. 2010.).



Slika 3. Prikaz Whiskbroom, Pushbroom i Staring (FPA) senzora i površine koju obuhvaćaju tijekom skeniranja.  
Izvor: Liccardi (2010.)

### 3.2.2. Metode odabira u hiperspektralnom snimanju

Hiperspektralni spektrometri također se razlikuju po spektralnim načinima odabira. Disperzijski elementi stvaraju sliku pomoću rešetke ili prizme. Nadolazeća elektromagnetska radijacija podijeljena je pod različitim kutovima. Spektar pojedinog osnovnog piksela bit će raspršen i fokusiran na različitim mjestima jedne dimenzije detektorskog niza (Fong, 2008.). Ovi elementi koriste se u pushbroom i whiskbroom skeniranju.

Sustavi bazirani na filterima djeluju tako da se uski pojas spektra može odabrati pomoću optičkog propusnog filtera. Najčešće se koristi linearni varijabilni filter (LVF), ponekad u kombinaciji s konveksnom rešetkom, koja svjetlost rastavlja na snopove. Prvotno su se koristili posebni filteri uskog pojasa za odvajanje valnih duljina. Takav postupak trajao predugo i često je dolazilo do izostajanja i miješanja ponekih valnih duljina zbog ograničenog broja filtera. Na ideji unaprjeđenja takvih filtera su nastali LVF, često zvani i klinastim filterima (wedge filters), čija debljina varira u obliku klina što omogućuje precizno odvajanje poželjnih valnih duljina, bez interferencije susjednih (Ksendzov i sur., 1998.).

Spektrometar Fourierovom transformacijom (FTS) je adaptacija Michaelsonovog interferometra<sup>2</sup> gdje je zraka iz izvora svjetlosti razdvojena u dva snopa pomoću razdjelnika koja 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. Signal koji se na kraju dobije ovisi o valnoj duljini svjetla i udaljenosti mjesta gdje se svjetlo razdvaja i zrcala. Kad je optička udaljenost između ta dva snopa jednak nuli, odnosno višekratnik vrijednosti valne duljine, tada se pojavi svijetli signal. U suprotnom, krajnji signal će biti mračan. Za skeniranje, dovoljno je pratiti stvaranje tamnih i svijetlih signala na jednom zrcalu. Pomoću matematičkog postupka obrnute Fourierove transformacije, moguće je očitati vrijednosti valnih duljina. Cilj ovakvog skeniranja je utvrditi koje su valne duljine emitirane i u kojoj količini. Asfairan i sur. (2013.) koristili su ovu metodu za detekciju bolesti truljenja lista riže (*Pyricularia grisea*), crne truleži (*Xanthomonas campestris*) i tungrovirusa (*Tungro Bacilliform Virus*).

---

<sup>2</sup> Interferometar koji dijeli izvor svjetlosti pomoću razdjelnika na dvije zrake koje se reflektiraju natrag na razdjelnik, gdje se proučava njihova interferencija.



### **3.3. Biljne bolesti i simptomi**

Kvaliteta lista na nekoj biljci odlikuje se njegovim stanjem bez oštećenja, deficita i bez značajnih varijacija u izgledu. Ovisi o mnogim čimbenicima, poput sjemena, presađivanja, branja i tako dalje (Dhingra i sur., 2017.). Bolesti lista mogu se kategorizirati ovisno o kakvom se uzročniku radi, odnosno je li on zarazan ili nezarazan.


Zarazne bolesti lista uzrokuju patogeni organizmi, kao što su bakterije, virusi, viroidi, fizoplazme i gljive. Infektivni inokulum ima svojstvo razmnožavanja unutar ili na domaćinu i širi se s jednog domaćina na drugog.. Za uspješnu zarazu, potrebno je imati povoljne ekološke čimbenike, poput temperature okoliša i relativne vlažnosti zraka, zarazni patogen i domaćina, koji je osjetljiv na taj patogen. Nezarazne ili neinfektivne bolesti lista su one bolesti nastale uslijed nepovoljnih uvjeta rasta, nepogodnog omjera kisika i vlage u zraku, previsoke ili preniske temperature, otrovnih agensa u tlu ili atmosferi i uslijed nedostatka biogenih elemenata. Kao što i samo ime kaže, nezarazne bolesti ne prenose se na druge biljke i ne razmnožavaju se unutar domaćina (Naikawadi, Amoda, 2013.).

Simptomi bolesti se znatno razlikuju ovisno o patogenu. Primjerice, simptomi virusnih bolesti, ili viroza, uključuju lezije, kloroze i uvijanje lista, ponekad s izraslinama na naličju, takozvanim enacijama (Garcia-Ruiz, 2019.). S druge strane, bakterioze karakteriziraju venuće listova, lokaliziranu klorozu i rakove (Sundin i sur., 2016.) . Gljivične bolesti rade štete u obliku pepelnice, hrđe ili plamenjače na listu, uzrokuju propadanje korijena i sl. (Jain i sur., 2019.).

#### **3.3.1. Otkrivanje bolesti**

Za prepoznavanje spektralnih značajki koje su jedinstvene po kemijskim i fizičkim svojstvima za objekt koji se promatra, hiperspektralni spektrometri dobivaju podatke u području visokospektralne rezolucije. To je od velike koristi za agronomiju, pogotovo u područjima praćenja rasta usjeva, otkrivanja bolesti i procjenjivanja kvalitete vode. U posljednjih nekoliko godina, hiperspektralna tehnologija koristi se u mnogim poljoprivrednim praksama poput otkrivanja pjega na plodovima jabuke i određivanje gorčine koštica u njima (Nicolai i sur., 2006.) i otkrivanja ozljeda i unutarnjih oštećenja u krastavcima. Abhu-Kalaf i Salman (2014.) u svom radu koriste spektroskopiju vidljivog i gotovo vidljivog infracrvenog


spektra za predviđanje razvoja bolesti paunovog oka (*Spiloaceae oleaginea*) na maslini. Koristeći više metoda klasifikacije, u 91% slučajeva su uspješno predvidjeli bolest. Na slikama 4 i 5 vidimo promjene u refleksiji na crvenom rubu u slučaju zdrave masline i masline zaražene paunovim okom, *S. oleagina* (Smart Agriculture Network, 2019.).



Slike 4. i 5. Prikaz razlike u refleksiji na crvenom rubu između zdrave masline (A) i masline zaražene paunovim okom (B).


Izvor: Smart Agriculture Network (2019.)

Biljni listove 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 6). Pomoću refleksije, na tom rubu se može odrediti količina klorofila u listu (Slika 7) i koncentracija dušika, pa se stoga može odrediti i razina dušičnog stresa (Ahmet i sur., 2016.).



Slika 6. Prikaz crvenog ruba i razlike u refleksiji zdrave i bolesne biljke.

Izvor: Ahmet i sur. (2016.).



Slika 7. Graf prikazuje omjer refleksije lista i količine klorofila u njemu.

Izvor: Ahmet i sur. (2016.).

U pšenici, najvažnije je pratiti vodeni stres, količinu dušika i gljivične bolesti. Haboudaine i sur. (2002.) utvrdili su da prisutnost klorofila u tkivu lista znatno utječe na elektromagnetski spektar u vidljivom dijelu, pogotovo na području plavih (450 nm) i crvenih (670) valnih duljina. Također, uspostavljena je veza između koncentracije dušika u listu i količine klorofila, to jest, listovi koji imaju jače apsorbiraju plave i crvene valne duljine imaju veću koncentraciju klorofila pa tako i veću koncentraciju dušika u sebi.

Neke od najvećih šteta pri proizvodnji raži, pšenice, ječma i zobi prouzrokovane su gljivicama iz roda *Fusarium*. Ove gljivice smanjuju urod, a mogu imati i toksično djelovanje na žito. Bauriegel i sur. (2011) u svom radu navode kako je korištenje hiperspektralnog snimanja pomoglo pri uočavanju ranih stadija razvoja gljivica iz roda *Fusarium* na žitaricama, pogotovo u stadiju mliječne zriobe. U radu, Bauriegel i sur. proučavali su valne duljine na 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%. 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 u zdrave i zaražene.

Ahmet 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 (1400 do 1600 nm i 1900 do 2100 nm) vide se znakovi suhoće i stresa biljke.

### **3.4. Biljni stres**


Prinos usjeva ovisi o okolišu i promjenjivim uzgojnim čimbenicima. Poneka odstupanja od normalnih uvjeta, poput bolesti ili suše, mogu izazvati stres biljaka. Biljke u stresu imaju manji prinos za do 22% u usporedbi sa zdravim biljkama (Behmann i sur., 2014.). Budući da je hiperspektralno snimanje još uvijek relativno nova tehnologija, većina istraživanja se baziraju na istraživanjima biljnih bolesti, a manji dio na biljni stres. Utjecaj napada štetočina na zdravlje biljke zasad ostaje za buduća istraživanja, jer još nije razvijena dovoljno dobra tehnologija koja može pratiti tako komplicirane uzorke.

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 simptom stesa izazvanog sušom je 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 promjene moguće je ranije uočiti hiperspektralnom analizom nego ljudskim okom. Stres također može biti izazvan nedostatkom nutrijenata, uslijed bolesti ili napada štetočina.

Novija metoda koja se koristi za analizu stresa je maksimalizacija volumena simpleksa ili SiVM (*Simplex Volume Maximization*) koja spada u skupinu nenadgledanih metoda koje koriste podatke iz cijelog spektra (Römer i sur., 2012). Metoda analizira cijeli spektar i postepeno ga skraćuje, dok ne ostanu valne duljine između 400 i 900 nm, u kojima se mogu pronaći podaci o stresu. Uspoređivanjem sličnosti spektra slika s poduke i novih slika, utvrđuje se postotak vjerojatnosti da biljke koje se analiziraju pate od stresa.

Van Deepika i sur. (2016.) su u svom radu opisali prepoznavanje stresa u tropskih biljaka pomoću hiperspektralne analize. Na slici 8 vidimo razliku između zdravog lista (A) i lista u stresu (B) u hiperspektralnom dijelu. Zdravi list je svježe otkinut, dok je drugi list izložen sušenju na 12 sati na sobnoj temperaturi. Promatrali su biljke na punom spektru od 380 do 1023 nm, s time da su za istraživanje korištene valne duljine od 400 do 1000 nm posložene u 477 snopa. Ostale duljine nisu pouzdane za pregled, jer u laboratorijskim uvjetima često dolazi do greške pri krajnjim duljinama zbog umjetnog osvjetljenja. Refleksija zdravih biljaka bila je mnogo veća u spektru od 750 do 1000 nm zbog veće količine vode u njima.



Slika 8. Prikaz zdravog lista i lista u stresu. Red 1 prikazuje zdravi list (1A) i list u stresu (1B). Red 2 prikazuje isto lišće, samo u hiperspektralnom obliku.

Izvor: VetriDeepika i sur. (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 hiperspektralne analize slika stabala pokazali

su da je došlo do povećanja refleksije zelene i crvene boje na duljinama između 750 i 1000 nm kod 60% i 40% poljskog kapaciteta, dok ostala stabla nisu pokazala znakove stresa i označena su zdravima.

### **3.5. Tehnike korištene u hiperspektralnoj analizi slika**

Kroz povijest, ljudi su razvili mnoge načine uzgoja kako bi smanjili propadanje uroda zbog bolesti. U zadnjih par desetljeća, kemijske metode zaštite, najviše pesticidima, su u opadanju radi novih tehnologija koje potiču održivi razvoj, dok su integrirane metode zaštite su u porastu (Savary i sur., 2012.). Bez obzira na metodu, najvažniji postupak u zaštiti bilja je što ranije prepoznati simptome bolesti. Kao što je ranije navedeno, ljudi nemaju sposobnost pregledati velike površine u kratkom vremenu niti konstantnu preciznost pri prepoznavanju simptoma, a tako i biljnih bolesti. Upravo zbog toga rješenje tog problema leži u računalima, koji mogu i prepoznati i klasificirati bolesti i stres biljaka pri visokoj preciznosti u kratkom vremenu. Precizna poljoprivreda se razvija pod konceptom *Agronomija 5.0*. Svrha ovog koncepta je implementirati brze sustave koji koriste umjetnu inteligenciju, čija je produktivnost veća i brža od ljudskog rada. Potreba za *Agronomijom 5.0* javlja se najviše iz potrebe za radnom snagom na farmama i plantažama. Današnje društvo se odmaklo od agrarnog stila života, što rezultira znatno manjim brojem ljudi zaposlenih u primarnom sektoru (Saiz-Rubio, Rovira-Más, 2020). Prema istraživanjima *Smart Agriculture Market*, procjenjuje se da će vrijednost tržišta precizne poljoprivrede u 2022. godini, iznositi 11,23 mlrd USD, uz godišnju stopu rasta od 13,27%.

Najvažnije tehnike korištene u hiperspektralnoj analizi, a koji su pod nadzorom umjetne inteligencije su daljinsko istraživanje, umjetne neuronske mreže i konvolucijske neuronske mreže.

### 3.5.1. Daljinska istraživanja – *Remote sensing*

Daljinska istraživanja omogućuju efektivan pregled površina većih razmjera, koje su zahvatile bolesti. Uočavanje i prepoznavanje u razvojnim stadijima bolesti omogućuju bržu zaštitu bilja, što u konačnici povećava sveukupnu proizvodnju hrane. Za detekciju postoje dva glavna pristupa: spektrometrima i optičkim, odnosno vizualnim, instrumentima. Spektrometrijske metode omogućuju jako rano otkrivanje razvoja bolesti. Primjerice, razvoj fitoftore (*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 et al., 2016.). Optičke metode se mogu provoditi zasebno ili u kombinaciji sa spektrometrima, što daje najbolje rezultate. Sastavni dijelovi uspješnog prepoznavanja su metode i algoritmi za predprocesiranje i selekciju značajki objekata u uzgojnom prostoru i modeli umjetne neuronske mreže (*Artificial neural network – ANN*) za grupiranje podataka i klasifikaciju bolesti (Naikawadi, Amoda, 2013.).

Daljinska istraživanja nastala su na principu globalnog položajnog sustava (GPS), uz dodatak posebnih senzora, zračnih slika i satelitskog snimanja, i posebnih software-a temeljenih na geografsko-informacijskom sustavu (GIS), napravljenih specifično za obradive površine. Daljinski detektori koriste se i za izračun gustoće sjetve, količinu potrebnog gnojiva za određene površine, zaštitu bilja i predviđanje uroda, pri tome uzimajući u obzir kulture koje se uzgajaju, te klimatska i pedološka svojstva prostora na kojem se uzgaja (Zurmotai, 2016.). Efekti izazvani atmosferskim čimbenicima između objekta koji se snima i senzora, odnosno spektrometra, su zajednički svim oblicima daljinskog snimanja, pa tako i hiperspektralnom. Utjecaj tih atmosferskih čimbenika se može podijeliti u dvije kategorije: oni koji su konstantni u vremenu i prostoru i oni koji nisu. Prvu kategoriju čine apsorbiranje i raspršenje čestica CO<sub>2</sub>, N<sub>2</sub>, CH<sub>4</sub> i O<sub>2</sub>. U drugu kategoriju pripadaju čimbenici koji ovise o okolnostima, poput vodene pare, ozona i aerosolnih otopina (Audert i sur., 2018.). Tehnologija koja može u potpunosti zanemariti ove čimbenike trenutno još nije dostupna, pa je zadatak svih novih metoda pronaći način kako uspješno snimati objekte bez obzira na utjecaj atmosfere.

Prednost hiperspektralnog 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 je


znatno porasla. S druge strane, dolazak nove tehnologije je značio i stvaranje novih metoda procesiranja podataka.

### 3.5.2. Umjetne neuronske mreže (ANN)

Umjetne neuronske mreže napravljive su od mreže umjetnih neurona koji su nastali po uzoru na biološke procese ljudskog mozga i svrstavamo ih u nadgledane mreže. Neuronsku mrežu je dovoljno jednom naučiti što treba napraviti kako bi uspješno odrađivala svoj posao. Sve informacije koje mreža nauči, ona koristi u prepoznavanju budućih zadataka, što omogućuje pronalaženje odgovora čak i kad su ulazni podaci nepotpuni ili djelomično 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, Rode, 2014.). Mreža se sastoji od ulazne i izlazne komponente, između kojih se nalaze višeslojne mreže ili skriveni slojevi. Prvi sloj sastoji se od ulaznih neurona, koji podatke šalju pomoću sinapsi, to jest spojeva između neurona, prema sloju izlaznih neurona. Sinapse pohranjuju parametre koji se označavaju kao težina ili jakost impulsa (*weights*). Budući da su slične mozgu, mreže djeluju na sustavu pamćenja točnih i netočnih odgovora, pa tako one točne šalju naprijed prema izlaznom sloju neurona, dok netočne vraćaju natrag i koriste ih za primjer negativnog procesiranja podataka. Neuronske mreže mogu naći vezu između ulazne i izlazne komponente bilo kojeg procesa, čak i ako podaci nisu u izravnoj linearnoj vezi. Obzirom na ulazne podatke i vrstu problema, mreža može naći jedan ili više odgovora (Raju i sur., 2011.).

Na slici 9 vidimo primjer konfiguracije umjetne neuronske mreže s tri sloja: 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 su posebno prikladne za situacije kada imaju više vremena za pronalaženje odgovora, primjerice za predviđanje napada štetočina.






Slika 9. Prikaz konfiguracije neuronske mreže s ulaznim, skrivenim i izlaznim slojevima, skupa sa sinapsama koje ih povezuju.

Izvor: Raju i sur. (2014.)

Kulkarni i sur. (2012.) predstavili su metodologiju za rano i precizno otkrivanje biljnih bolesti koristeći umjetne neuronske mreže. U eksperimentu su koristili lišće zaraženo s koncentričnom pjegavosti (*Alternaria spp.*), bakterijskom pjegavosti izazvanu gljivicom *Xanthoamoans campestris* i crnom pjegavosti koju izaziva gljivica *Colletotrichum lindemuthanium*. Za klasifikaciju su koristili klasifikator temeljen na umjetnoj mreži, a za izdvajanje značajki koristili su filter.

Na grafu 1 prikazani su koraci u analizi slike. Analiza započinje slikanjem uzorka hiperspektralnom kamerom. Nakon toga, slike idu na predprocesiranje, što uključuje filtriranje i segmentaciju, te na izdvajanje značajki poput boje i teksture. Posljednji dio metode uključuje klasifikaciju pomoću umjetne neuronske mreže.



Graf 1. Prikaz analize hiperspektralnih slika koristeći umjetnu neuronsku mrežu.

*Ulazne slike* su samo one slike 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 neuronske mreže 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 faktori na slici, poput distorzije ili zamućenosti, uklanjaju, a poželjni faktori se 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, 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. Budući da se slike izmjenjuju i spremaju više puta na relaciji baza podataka – predprocesiranje, njihova se kvaliteta može smanjiti.

3. Poboljšanje slike je jedan od najvažnijih postupaka u analizi slike. Glavna svrha je istaknuti detalje koji se slabije vide na slici ili izmijeniti kontrast slike dok se ne dobije željeni rezultat koji se može dalje obrađivati. Isticanje detalja se radi tako da se intenzitet piksela na kojima se nalaze važniji podaci povećava, a onim manje potrebnim pikselima se smanjuje.

U hiperspektralnoj slici svaki piksel predstavlja određenu valnu duljinu, što omogućuje popravljavanje deformiranih piksela tako se takvom pikselu pridodaje srednja vrijednost valnih duljina susjednih piksela. Nakon što 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 pojednostavljuje ili mijenja prikaz slike u oblik koji ima više smisla i lakši je za analizirati za neuronsku mrežu. Također, procesom segmentacije izdvajaju se 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 10 vidimo primjer ulazne i segmentirane slike lista graha zaraženog bolesti *Alternaria spp.*, to jest koncentričnom pjegavosti (Singh, Misra, 2017.).

Nakon segmentacije slijedi *izdvajanje značajki* slike. Ovisno o segmentiranim informacijama, potrebno je izolirati važne podatke. Važnost ovog postupka je u tome što omogućuje odabir važnijih od manje važnih značajki i smanjivanje ukupne količine podataka tako što se dijele u nekoliko setova, i tako ubrzavaju proces analize i klasifikacije u neuronskoj mreži. Jedan od mogućih načina izdvajanja značajki je korištenjem filtera, koji računa energiju valnih duljina pojedinačnih piksela i rezultate uspoređuje s rezultatima s prijašnjih testiranja (Gawande, 2014).

Posljednji korak u analizi slike je *klasifikacija* njenih značajki. Klasifikacija korištenjem umjetnih neuronskih mreža je opisana ranije u ovom radu. Koristeći se znanjem iz prijašnjih testova, umjetne neuronske mreže traže sličnosti između starih i novih podataka i određuju koji dijelovi slike opisuju zaraženi, a koji zdravi dio biljke na slici. Na slici 11 vidimo konačni rezultat analize slike za bolest koncentrične pjegavosti (*Alternaria spp.*) na listu graha (Singh, Misra, 2017.).




Ulazna slika



Segmentirana slika

Slika 10. Ulazna slika lista graha zaraženog gljivičnom bolesti koncentrična pjegavost (*Alternaria spp.*) (lijevo) i segmentirana slika istog lista (desno).

Izvor: Singh, Misra (2014.)



Slika 11. Prikaz konačne analize slike lista graha zaraženog koncentričnom pjegavosti (*Alternaria spp.*). Desno vidimo izlaznu sliku na kojoj su označeni samo zaraženi dijelovi lista.

Izvor: Singh, Misra (2014.)

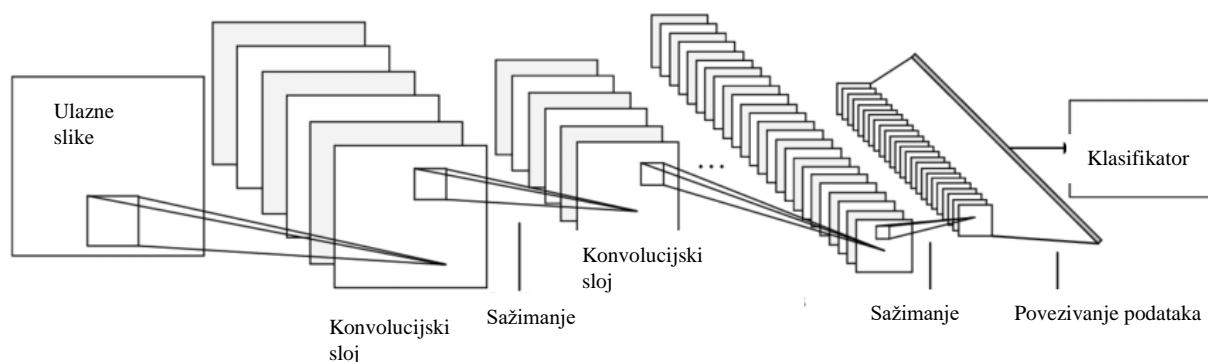
### 3.5.3. Konvolucijske neuronske mreže (CNN)

Konvolucijske neuronske mreže (*Convolutional neural network - CNN*) imaju širok spektar primjene, od prepoznavanja teksta i objekata do čitanja dokumenata i često se koriste u društvenim mrežama (Nagasubramanian i sur., 2018.). Kroz posljednjih par godina, trodimenzionalne konvolucijske mreže koriste se za klasifikaciju hiperspektralnih slika. Ove mreže nastale su kao nadogradnja nad višeslojnim, umjetnim neuronskim mrežama.

Konvolucijske mreže mogu naučiti probleme osobito brzo i može koristiti mnogo kompleksnije algoritme za razliku od ANN. Rješenje problema se traži po slojevima, a ne istodobno na svim neuronima, što uvelike smanjuje vrijeme obrade podataka. Za poljoprivredu

to znači da je moguće ranije i točnije pronaći rane simptome razvoja bolesti na biljkama i uspješnije predvidjeti njihov razvoj (Kamilaris, 2018.).

Kao i umjetna neuronska mreža, konvolucijska mreža također se 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 konvolucijske mreže je “LeNet-5“, prikazana na slici 12.



Slika 12. Prikaz LeNet-9 arhitekture konvolucijske mreže.

Izvor: Wang i sur. (2017).


Konvolucijski slojevi sadrže filtere i različiti broj skrivenih slojeva, ovisno o vrsti analize slike, koji sadrže neurone. Svi neuroni su 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 umjetnih neuronskih mreža. Izlazna komponenta skrivenog sloja je aktivacijska mapa koja sadrži podatke filtera, odnosno podijeljene vrijednosti neurona (Hu i sur., 2015.). Pojedinačni konvolucijski sloj može imati više filtera koji u istovremeno mogu prenositi vrijednosti na neurone, čime omogućuju pretraživanje više značajki. Kao i svaka neuronska mreža, i konvolucijska treba proći niz vježbi i testova, kako bi naučila razlikovati poželjne od nepoželjnih značajki.

Između konvolucijskih slojeva nalaze se slojevi sažimanja koji dijele vrijednosti aktivacijskih značajki po određenoj funkciji, najčešće po maksimalnoj vrijednosti. Ovaj

postupak pojednostavljuje aktivacijske mape i smanjuje njihovu rezoluciju. Dio podataka se grupira u zajedničku vrijednost najčešće metodom sažimanja maksimalnih vrijednosti. Mreža završava ujedinjenjem podataka u potpuno povezani sloj (Hu i sur., 2015.) .

Glavna prednost konvolucijske mreže je ta što joj treba manje parametara za učenje uzoraka od uobičajene neuronske mreže, brže su i imaju veći postotak uspješnosti. Konvolucijski sloj služi istovremeno za pregled podataka, spremanje u bazu podataka, i izdvajanje značajki slike. Budući da se hiperspektralna kocka sastoji od slojevitih podataka, konvolucijska mreža izgleda kao najbolje rješenje za njihovu obradu. Najveći nedostatak ovih mreža je njihova kompleksnost, koja se očituje procesima obrade i klasifikacije podataka.

U svom radu, Nagasubramanian i sur. (2018.). koristili su konvolucijske neuronske mreže za otkrivanje ugljenaste truleži (*Macrophomina phaseolina*) na stabljici soje. Uzorci su prikupljeni nakon 3, 6, 9, 12 i 15 dana nakon početka zaraze, te su njihove hiperspektralne slike, isto kao i slike zdravih biljaka, sastavljene u hiperspektralnu informacijsku kocku. Sve biljke slikane za ovaj eksperiment imale su razvijene crveno-smeđe lezije na vrhu stabljike, zbog činjenice da se bolest više širi kroz unutrašnjem dijelu stabljike više nego na vanjskom. Stupanj razvijenosti bolesti ovisi o duljini izloženosti biljke patogenu. Slika 13 prikazana je u RGB obliku kako bi se jasnije vidio razvoj bolesti na i u stabljici soje.



Slika 13. Prikaz razvijenosti bolesti truleži soje.

Izvor: Nagasubramanian i sur. (2017.).

Prikupljeno je 111 hiperspektralnih slika rezolucije 500x1600x240. 64 slike sadrže zdrave stabljike, a 47 zaražene. Za vježbanje konvolucijske mreže, korišteno je 1090 slika, gdje 940 prikazuje zdrave, a 150 zaražene stabljike. Nakon vježbe, korištene su slike zaraženih stabljika soje. Konvolucijska mreža je nakon izdvajanja značajki smanjila rezolucije slika na 64x64x240. Mreža je uspjela prepoznati, odvojiti i klasificirati zaražene biljke s prosječnom uspješnošću od 95.73% za sve stadije razvoja bolesti.

Svoj rezultat su prikazali u obliku mapa značajnosti na kojima se vidi da su pikseli koji predstavljaju zaražene dijelove stabljika naglašeniji od ostalih piksela u sloju. To znači da je konvolucijska mreža uspješno označila zaražene dijelove stabljike od nezaraženih.

### **3.6. Klasifikacija**

Klasifikacija snimaka je proces grupiranja određenih dijelova slike u kategorije. Za hiperspektralno 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 podijele parcele na biljke koje se na njoj nalaze i na dio koji nije bitan za analizu, poput nežive prirode. Kao što je ranije navedeno, svaki piksel u hiperspektralnoj slici nosi vrijednosti određenog spektralnog pojasa. Zadatak klasifikatora je uspoređivati te vrijednosti piksela i na račun vrijednosti podijeliti ih u određene kategorije. Postoji više vrsta podjela klasifikacija. U ovom radu predstavljena je podjela klasifikacijskih metoda na metode koje koriste podskupine odabranih valnih duljina i metode koje koriste podatke iz cijelog spektra valnih duljina (Lowe i sur., 2017.).

### 3.6.1. Metode klasifikacije koje koriste podatke iz odabranih valnih duljina

Ove metode uzimaju uzorke s poznatim podacima za klasifikaciju piksela s nepoznatim podacima. Najčešće se koriste, ranije 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.). Analitičar koji provodi analizu slike sam odabire određene valne duljine u spektru, koje će ići na daljnju klasifikaciju. 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, cijeli proces analize, identifikacije i klasifikacije bolesti je mnogo jednostavniji i brži kad analitičar zna koju bolest traži i na kojem rasponu valnih duljina se može očitati njena prisutnost. Primjerice, za otkrivanje bolesti bijele truleži (*Sclerotinia sclerotiorum*) u celeru, dovoljno je pregledati samo valne duljine između 1481 i 1524 nm, i između 2022 i 2395 nm (Huang i Apan, 2006.).


Dvije najčešće korištene metode koje klasificiraju određene valne duljine su klasifikacija metodom mapiranja spektralnog kuta i klasifikacija metodom koeficijenta korelacije.

#### 3.6.1.1. Metoda mapiranja spektralnog kuta

Metoda mapiranja spektralnog kuta ili SAM metoda (Spectral Angle Mapper) koristi algoritam koji uspoređuje spektar nove snimke s prije poznatim spektrom odabranim od strane analitičara. Ovom metodom, slike, odnosno spektar valnih duljina u hiperkocki, korištene za poduku i nove slike prikazane su u obliku vektora u prostoru. Nakon segmentacije, neuronske mreže računaju spektralni kut između slojeva i pridodaju tu vrijednost pikselima. Vrijednost se dobije matematičkom funkcijom kosinusa i računa se za svaku klasu koja se analizira. Manji spektralni kut znači veću sličnost između piksela koji se uspoređuju. Kao rezultat izlazi takozvani „raster“, koji sadrži matricu piksela s vrijednostima spektralnog kuta (Ghaiwat i sur. 2014.).



Koristeći se ovom metodom, Rumpf i sur. (2010.), su u svom istraživanju uspjeli raspoznati bolesne listove šećerne repe od zdravog lišća s prosjekom 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 14 vidimo 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, budući da se u njenom slučaju refleksija ne mijenja mnogo u ranom stadiju razvoja bolesti.



Slika 14. Prikaz razlike u refleksiji zdrave biljke i biljaka zaraženih bolestima *C. beticola*, *U. betae* i *E. betae*.

Izvor: Rumpf i sur. (2010.)

### 3.6.1.2. Metoda koeficijenta korelacije

Ova metoda bazira 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, gdje 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.

### **3.6.2. Metode klasifikacije koje koriste podatke iz cijelog spektra**

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

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

#### *3.6.2.1. Analiza kvadratne diskriminante*

Ova metoda klasificira piksele novih slika, uspoređujući njihov sadržaj sa slikama s poduke koristeći metodu kvadratne analize diskriminante. Ova metoda je slična metodi koeficijenta korelacije jer se bazira na međuovisnosti klasa. Kvadrirana euklidska udaljenost vektora između svake klase se učitava, računalno se obradi pomoću algoritma i kao izlaznu vrijednost daje ovisnost od 0 do 1. Manja euklidska udaljenost znači da je ovisnost dvaju klasa veća, što znači da su i podaci u njima sličniji (Šimićev, 2015.).

Sankaran i Ehsani (2012.) koristili su ovu metodu u svom istraživanju o otkrivanju sušenja kore (*Raffaelea lauricola*) avokada. Metoda se pokazala uspješnom u otkrivanju i predviđanju bolesti u 94% slučajeva.

## 4. Zaključak

Hiperspektralna analiza slike obuhvaća metode kojima se otkrivaju rani stadiji razvoja biljnog stresa i biljnih bolesti. Metode se zasnivaju na strojnom učenju i daljinskim istraživanjima, a u istraživanjima pomaže i umjetna inteligencija u obliku neuronskih mreža. Konstantnim razvijanjem umjetne inteligencije, poboljšavaju se i rezultati istraživanja bolesti, kao i predviđanje njihovog daljnjeg razvoja unutar individualne biljke ili na cijeloj parceli.

Hiperspektralno snimanje znači da se slika prikazuje u obliku piksela, gdje svaki piksel predstavlja snop svjetlosti, koji se može kretati od ultraljubičastog do dugovalnog infracrvenog spektra, proširujući spektar pregleda daleko izvan samo ljudskog. Analiza započinje obradom slike u hiperspektralnom obliku. Potom slijedi izdvajanje poželjnih značajki, poput odvajanja zaraženih od zdravih dijelova biljke. Naposljetku dolazi do klasifikacije slike, gdje se utvrđuje o kojoj se bolesti radi i do koje je razine ona razvijena u biljci. Metode analize se razlikuju ovisno o vrsti istraživanja i osobi koja ga provodi, a najčešće uključuju umjetne neuronske mreže i konvolucijske neuronske mreže.

Hiperspektralna analiza slike je još uvijek novi način obrade podataka u agronomiji. Usprkos tomu, pokazala se kao zasad najboljim i najbržim rješenjem na problem otkrivanja biljnih bolesti i stresa u preciznoj poljoprivredi. Dakako, potrebna su konstantna istraživanja ovim metodama kako bismo ih bolje razumjeli i kako bi se povećala njihova točnost. Sa sigurnošću se može reći kako je hiperspektralna analiza slike tehnologija budućnosti i da će biti neophodna u daljnjim poljoprivrednim postignućima.

## 5. Literatura

1. 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, *Palestine Technical University Research Journal*, 2, stranice 1-8
2. Asfarian A., Herdiyeni Y. (2013.): Paddy diseases identification with texture analysis using fractal descriptors based on fourier spectrum, [https://www.researchgate.net/publication/260435013\\_Paddy\\_Diseases\\_Identification\\_with\\_Texture\\_Analysis\\_using\\_Fractal\\_Descriptors\\_Based\\_on\\_Fourier\\_Spectrum](https://www.researchgate.net/publication/260435013_Paddy_Diseases_Identification_with_Texture_Analysis_using_Fractal_Descriptors_Based_on_Fourier_Spectrum) (pristupljeno 10.9.2020.)
3. Audebert N., Le Saux B, Lefevre S. (2018.): Deep Learning for Classification of Hyperspectral Data, *IEEE Geoscience and Remote Sensing Magazine*, stranice 1-13
4. Badnakhe M., Deshmukh P. (2011.): An Application of K-Means Clustering and Artificial Intelligence in Pattern Recognition for Crop Diseases, *IPCSIT*, 20, stranice 134-138
5. Bauriegel E., Giebel A. (2011.): Early detection of Fusarium infection in wheat using hyper-spectral imaging, *Computers and Electronics in Agriculture*, 75, 2, stranice 304-312
6. Behmann J., Streinrücken J., Plümer L. (2014.): Detection of early plant stress responses in hyperspectral images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, stranice 98-111
7. Crespo J. L., Duro R. J., López Peña F.,(2003): Gaussian Synapse ANNs in Multi and Hyperspectral Image Data Analysis, *IEEE Transactions of Instrumentation and Measurements* 52, stranice 724-732
8. Dahikar S., Rode S. (2014.): Agricultural Crop Yield Prediction Using Artificial Neural Network Approach, *International Journal of Innovative Research in Electrical, Electronics, Instrumentation and Control Engineering*, 2, stranice 683 - 686
9. Dhingra G., Kumar V., Joshi H. D. (2017.): Study of digital image processing techniques for leaf disease detection and classification, *Multimedia Tools and Application*, 77
10. Fong A. (2008.): Advanced photonic tools for hyperspectral imaging in the life sciences, *Biotechnics International Feature*, stranice 1-5

11. Ganchenko V., Doudkin A., Pawlowski T., Petrovsky A., Sadykhov R. (2016.): Based on Perceptron Object Classification Algorithms for Processing of Agricultural Field Images, *Modeling and Simulation*, stranice 86-92
12. Garcia-Ruiz H. (2019.) – When viruses infect plants, <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6417105/> (pristupljeno 10.9.2020.)
13. Gawande U. (2014.): An Overview of the Research on Plant Leaves Disease detection using Image Processing Techniques, *IOSR Journal of Computer Engineering*, 16,1, stranice 10-16
14. Ghaiwat S. i sur. (2014.): Detection and Classification of Plant Leaf Diseases Using Image processing Techniques, *ISSN* 2,3
15. Haboudaine D., Miller J. (2002.): Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture, *Remote Sensing in of Environment*, 81, stranice 416-426
16. Hu W., Huang Y., Wei L. (2015.): Deep Convolutional Neural Networks for Hyperspectral Image Classification, *Journal of Sensors, Hindawi Publishing Corporation*, stranice 1-12
17. Huang J-F., Apan A. (2016.): Detection of Sclerotinia rot disease on celery using hyperspectral data and partial least squares regression, *Journal of Spatial Science*, 51,2, stranice 129-142
18. Jain A., Sarsaiya S, Wu Q. (2019.): A review of plant leaf fungal diseases and its environment speciation, <https://www.tandfonline.com/doi/full/10.1080/21655979.2019.1649520>, (pristupljeno 10.9.2020.)
19. Janeš, F. (2019.): Klasifikacija hiperspektralnih snimaka metodom mapiranja spektralnog kuta i koeficijenta korelacije, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva
20. Kamilaris A., Prenafeta-Boldú F. (2018.): A review of the use of convolutional neural networks in agriculture, *The Journal of Agricultural Science*, stranice 1-11
21. Kim Y., Glenn D. (2011.): Hyperspectral image analysis for water stress detection of apple trees, *Computers and Electronics in Agriculture*, 77, stranice 155-160
22. Kopljar D., (2016.): Konvolucijske neuronske mreže, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva
23. 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*,

[https://www.researchgate.net/publication/255581861\\_Wedge\\_Filters\\_for\\_Spectral\\_Imaging\\_in\\_the\\_Near\\_IR\\_Using\\_Metal\\_Grids](https://www.researchgate.net/publication/255581861_Wedge_Filters_for_Spectral_Imaging_in_the_Near_IR_Using_Metal_Grids) (pristupljeno 22.08.2020.)

24. Kulkarni A., Patil R. (2012.): Applying image processing technique to detect plant diseases, *IJMER*, 2, 5, stranice 3661-3664
25. Kurz T., Buckley S., (2016.): A review of hyperspectral imaging in close range applications, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, stranice 865-870
26. Licciardi G. (2010.) - Neural network architectures for information extraction from hyper-spectral images, University of Rome, stranice 29-36
27. Linker R. (2010.): Application of FTIR Spectroscopy to Agricultural Soils Analysis, <https://www.intechopen.com/books/fourier-transforms-new-analytical-approaches-and-ftir-strategies/application-of-ftir-spectroscopy-to-agricultural-soils-analysis> (pristupljeno 18.8.2020.)
28. 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*, 13:80
29. Middleton Spectral Vision, <https://www.middletonspectral.com/resources/what-is-hyperspectral-imaging/> (pristupljeno 10.8.2020.)
30. Mishra S., Mishra D., Santra G. (2016.): Applications of Machine Learning Techniques in Agricultural Crop Production: A Review Paper, *Indian Journal of Science and Technology*, 9, 38
31. Moshou D., Bravo C., West J., Ramon H. (2004.): Early Disease Detection in Wheat Fields using Spectral Reflectance, *Biosystems Engineering*, 84,2, stranice 137-145
32. Nagasubramanian K. i sur. (2018.): Explaining hyperspectral imaging based plant disease identification: 3D CNN and saliency maps, *31st Conference on Neural Information Processing Systems*, stranice 1-8
33. Naikawadi S., Amoda N. (2013.): Advances in Image Processing for Detection of Plant Diseases, *IJAIEEM*, 2, 11, stranice 168-172
34. Nicolai B., Lotze E., Scheerlink N. (2006.): Non-destructive measurement of bitter pit in apple fruit using NIR hyperspectral imaging, *Postharvest Biology and Technology*, 40, stranice 1-6
35. Ortenberg F. (2011.): Hyperspectral Remote Sensing of Vegetation, stranice 39-68

36. Paoletti M.E., Haut J. M., Plaza J., Plaza A. (2018.): A new deep convolutional neural network for fast hyperspectral image classification, *ISPRS Journal of Photogrammetry and Remote Sensing*, stranice 120–147
37. Peñuelas J, Filella I. (1998.): Visible and near-infrared reflectance techniques for diagnosing plant physiological status, *Trends in Plant Science*, 3, stranice 151-156
38. Polder G., Young I., Heijden G. (2003.): Calibration and characterisation of imaging spectrographs, *Journal of Near Infrared Spectroscopy*, 11, stranice 193-210
39. Qin J., Chao C., Kim M., Lu R., Burks T. (2013.): Hyperspectral and multispectral imaging for evaluating food safety and quality, *Journal of Food Engineering*, 18, 2, stranice 157-171
40. Raju M., Srivastava R., Bisht D., Kumar A. (2011.): Development of Artificial Neural-Network-Based Models for the Simulation of Spring Discharge, *Advances in Artificial Intelligence*, 2, stranice 1-11
41. Raju M., Yasmin J., Mo C. (2016.): Outdoor Applications of Hyperspectral Imaging Technology for Monitoring Agricultural Crops, *Journal of Biosystems Engineering*, 41, stranice 395-407
42. Römer C. (2012.): Early drought stress detection in cereals: Simplex Volume Maximization for hyperspectral image analysis, *Functional Plant Biology*, 39, stranice 878-890
43. Rumpf T., Mahlein A.-K. (2010.): Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance, *Plant Disease*, 100,2, stranice 241-251
44. Saiz-Rubio V., Rovira-Más F. (2020.): From Smart Farming towards Agriculture 5.0: A Review on Crop Data Management, *Agronomy* 10, 207, stranice 1-4
45. 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 Diseases*, 96, stranice 1683-1689
46. Savary S., Ficke A., Aubertot J.-N., Hollier C (2012.): Crop losses due to diseases and their implications for global food production losses and food security, *Food security*, 4
47. Shaw G. A., Burke, H. K. (2003.): Spectral Imaging for Remote Sensing, *Lincoln Laboratory Journal*, 14, 1, stranice 3-27
48. Singh V., Misra A.K. (2016): Detection of Plant Leaf Diseases Using Image Segmentation and Soft Computing Techniques, *Information Processing in Agriculture*, 4, stranice 41-49

49. Sundin G., Castiblanco L., Yuan X. (2016.): Bacterial disease management: challenges, experience, innovation and future prospects, <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6638406/> (pristupljeno 10.9.2020.)
50. Šimićev, D. (2015.): Računalno učitavanje višesegmentnih displeja, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva
51. VetriDeepika K., Johnson A., LafrulHudha M., Ramya M. (2016.): Enhancement of Precision Agriculture Using Hyperspectral Imaging, *IJTRD*, stranice 19-21
52. Wang, Jieyuan, Qian, Ying, Ye, Qingqing, Wang, Biao. (2017): Image retrieval method based on metric learning for convolutional neural network, IOP Conference Series: Materials Science and Engineering, *Computational Intelligence and Neuroscience*, 17, stranice 1-8
53. 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*, stranice 28-35
54. Xie C., Shao Y., Li X., He Y. (2015.): Detection of early blight and late blight diseases on tomato leaves using hyperspectral imaging, *Scientific Reports* 5:16564
55. Zurmotai N., (2016.): GIS, Remote Sensing and GPS: their activity, Integration and Fieldwork, [https://www.researchgate.net/publication/311206263\\_GIS\\_Remote\\_Sensing\\_and\\_GPS\\_their\\_activity\\_Integration\\_and\\_Fieldwork](https://www.researchgate.net/publication/311206263_GIS_Remote_Sensing_and_GPS_their_activity_Integration_and_Fieldwork) (pristupljeno 28.8.2020.)