
GLASILO BILJNE ZAŠTITE

GODINA XXII

TRAVANJ - SVIBANJ

BROJ 3

Sandra SKENDŽIĆ

Sveučilište u Zagrebu, Agronomski fakultet, Zavod za poljoprivrednu
zoologiju/Zavod za melioracije
sskendzic@agr.hr

VEGETACIJSKI INDEKSI – ALATI ZA PROCJENU STANJA USJEVA PŠENICE

SAŽETAK

Učestalost i intenzitet ekstremnih vremenskih događaja vjerojatno će se povećati s klimatskim promjenama. Proizvodnja pšenice (*Triticum aestivum* L.) ključna je za globalnu sigurnost hrane. Klimatske promjene ugrožavaju održivu proizvodnju pšenice ne samo izravnim negativnim utjecajima na rast i razvoj usjeva, već i značajnim učincima na dinamiku i širenje njenih štetnika i bolesti. Smanjenje gubitaka u poljoprivredi nužno je za održivo povećanje učinkovitosti poljoprivredne proizvodnje kako bismo zadovoljili svoje sadašnje i buduće potrebe za hranom, vlaknima, stočnom hranom i gorivom. Naše sve bolje razumijevanje načina na koji biljke reagiraju na abiotički i biotički stres dovelo je do razvoja inovativnih senzorskih tehnologija za otkrivanje stresa u usjevima, razvoj brzog i pojednostavljenog sustava za donošenje odluka u različitim fenofazama te za primjene učinkovitih agrotehničkih mjera. Spektralni vegetacijski indeksi (VI) dobro su poznati i naširoko korišteni alati za procjenu stanja usjeva pšenice i predikciju prinosa zrna. U ovom članku opisani su načini dobivanja vegetacijskih indeksa s pomoću metoda daljinskih istraživanja te klasifikacija njihove široke primjene u usjevima pšenice. Vegetacijskim indeksima može se procijeniti razine stresa suše, rano detektirati napad štetnih organizama, procijeniti status dušika u usjevima te predikcija biomase, indeksa lisne površine i konačnog prinosa.


Ključne riječi: daljinska istraživanja, vegetacijski indeksi, pšenica, procjena razine stresa usjeva, predikcija prinosa

UVOD

Pšenica (*Triticum aestivum* L.) jedan je od najznačajnijih usjeva te glavni izvor kalorija i proteina u svijetu. Svjetska proizvodnja pšenice u prosjeku iznosi oko 750 milijuna tona godišnje (Grote i sur., 2021.). Brojni abiotički i biotički stresori negativno utječu na rast i razvoj usjeva pšenice. Najznačajniji su

abiotički stresori suša i nedostatak dušika, a biotički štetni organizmi – kukci i uzročnici biljnih bolesti (Šestak, 2011.; Skendžić i sur., 2021.; Sun i sur., 2019.). Trenutačno se procjenjuje da se na globalnoj razini u prosjeku 21,5 % prinosa pšenice gubi zbog napada štetnika i bolesti (Kashyap i Kumar., 2021.). Klimatske promjene imat će utjecaj na proizvodnju pšenice u obliku nižih prinosa, viših troškova i nužnog odstupanja od tradicionalnog uzgoja. Osim negativna utjecaja na rast i razvoj usjeva, klimatske promjene značajno intenziviraju pojavu i širenje štetnih organizama te brojni znanstvenici smatraju da će u budućnosti takve promjene biti još izraženije (Skendžić i sur., 2021.). Praćenje usjeva pšenice metodama daljinskih istraživanja tijekom vegetacije igra važnu ulogu pri donošenju specifičnih odluka i upravljanja agrotehničkim mjerama, ali također može poboljšati razumijevanje fizioloških procesa koji kontroliraju primanje dušika, razvoj biomase i konačan prinos. Daljinska istraživanja vegetacije nedestruktivne su metode prikladne za brzu i točnu procjenu fiziološkog stanja biljaka i za objektivnu procjenu odgovora biljaka na prirodne i antropogene čimbenike okoliša. U današnje vrijeme brojni senzori sposobni su mjeriti spektralnu refleksiju biljaka, dajući pritom vegetacijske indekse korisne za procjenu biomase i zdravstvenog stanja usjeva (Lillesand i sur., 2004.). Većina daljinskih senzora koji se koriste u poljoprivredi mjeri količinu svjetlosti koja se reflektira i/ili emitira iz objekta (vegetacije). Elektromagnetsko zračenje može varirati od niskofrekventnih radiovalova do visoko frekventnih gama-zraka. Posljedično, raspon valnih duljina klasificiran je u regije ili spektralne pojaseve, koji su organizirani u elektromagnetskom spektru prikazanom na slici 1 (Zhu i sur., 2017.). Odnos između reflektirane, apsorbirane i prenesene energije koristi se za određivanje spektralnih otisaka vegetacije koji su specifični za biljne vrste i njihovo zdravstveno stanje (Lillesand i sur., 2004.). Postoji nekoliko vrsta daljinskih senzorskih sustava koji se koriste u poljoprivredi, a najčešći je pasivni sustav koji detektira elektromagnetsku energiju reflektiranu od biljaka. Sunce je najčešći izvor energije za pasivne sustave, te se takvi senzori mogu montirati na satelite, letjelice ili izravno na poljoprivrednu opremu (Nowatzki i sur., 2017.). Daljinski senzori razlikuju se po svojoj osjetljivosti na različite valne duljine i veličini objekata koji se mogu "vidjeti". Te se razlike nazivaju spektralna i prostorna razlučivost, i one su ono što karakterizira različite sustave daljinskog istraživanja. Prostorna razlučivost definira veličinu piksela satelitskih ili zračnih snimaka koji pokrivaju površinu Zemlje i odnosi se na dimenzije najmanjeg objekta koji se može detektirati na tlu (Wójtowicz i sur., 2015). Spektralna razlučivost je osjetljivost senzora na različite valne duljine elektromagnetskog spektra, odnosno broj i širinu valnih duljina koje je senzor detektirao, a razlikujemo multispektralne, hiperspektralne i RGB senzore. Senzori pružaju bolju diskriminaciju kako se povećava broj i širina zahvaćenih valnih duljina, pa tako multispektralni koriste do 10 širokih valnih duljina, a hiperspektralni do

100 uskih valnih duljina unutar vidljivog (VIS), bliskog infracrvenog (NIR) i kratkovalnog infracrvenog (SWIR) dijela elektromagnetskog spektra (Haden i Kudenov, 2013.; Zhu i sur., 2017.). RGB kamere jeftinija su alternativa multi- i hiperspektralnim sensorima te se uspješno koriste za procjenu parametara rasta i razvoja biljaka. Standardna slika snimljena RGB kamerom sastoji se od tri valna pojasa, odnosno crvene (R), zelene (G) i plave (B) trake, koje se nalaze unutar vidljiva dijela spektra (VIS) (Travlos i sur. 2017.).




Slika 1. Elektromagnetski spektrar
(Izvor: <https://api.izzi.digital>)


U literaturi se koriste različite metode za praćenje promjena vegetacije. Jedna je od njih metoda daljinskih istraživanja koja je praktičan, brz i ekonomičan način proučavanja stanja poljoprivrednih usjeva, osobito na velikim površinama (Xie i sur., 2008.). Radi se o metodi prikupljanja informacija o udaljenim objektima (vegetaciji) bez fizičkog dodira s proučavanim objektom (vegetacijom), a uključuje proces snimanja, obrade, analize i tumačenja podataka prikupljenih tim istraživanjem (Frančula i sur., 1994.). Daljinski senzor je instrument koji prikuplja podatke o objektu iz daljine, a nositelj informacija u daljinskom istraživanju je elektromagnetsko zračenje. Ono se može opisati kao harmonično kretanje u obliku valova koji se javljaju u jednakim vremenskim intervalima. Oni su razvrstani prema valnim duljinama (npr. 475 nm) ili dijelovima spektra (npr. vidljivi dio spektra 400 – 700 nm) (Oluić, 2001.). Svaki materijal u prirodi (vegetacija, tlo, neživi objekti itd.) ima svoju jedinstvenu raspodjelu reflektiranog, emitiranog i apsorbiranog elektromagnetskog zračenja. Ta se spektralna svojstva mogu koristiti za razlikovanje različitih materijala ili za dobivanje informacija o obliku, veličini i drugim fizikalnim i kemijskim svojstvima. Spektralna svojstva vegetacije variraju s valnom duljinom. Na primjer, pigment klorofil u listu snažno apsorbira zračenje crvene i plave valne duljine, ali reflektira zelene valne duljine, dok je mjerenje i praćenje bliske infracrvene refleksije (NIR) jedan od načina na koji se može odrediti zdravstveno stanje vegetacije (Aggarwal, 2004.). Najkorisnije valne duljine u istraživanju promjena vegetacije uključuju vidljivi dio spektra (VIS; 400 – 700

nm), blisko infracrveni dio spektra (NIR; 700 – 1300 nm) i kratkovalni infracrveni spektar (SWIR; 1300 – 2500 nm) (Wójtowicz i sur., 2015.). Refleksija je jedno od najvažnijih svojstava u području daljinskih istraživanja. Mjeri se kao funkcija valne duljine i naziva se spektralna refleksija. Graf spektralne refleksije objekta kao funkcije valne duljine naziva se krivulja spektralne refleksije (Maid i Deshmukh, 2018.). Slika 2 prikazuje krivulju spektralnog otiska zdrave vegetacije te položaj najznačajnijih dijelova spektra. Budući da proučavani objekti imaju jedinstvene spektralne karakteristike ili spektralne otiske, mogu se identificirati i klasificirati prema snimkama dobivenima daljinskim istraživanjima (Xie i sur., 2008.). Ovim metodama istraživanja omogućeno je praćenje dinamičnih promjena biljaka i tla tijekom vegetacijske sezone. Daljinska istraživanja mogu se podijeliti u tri kategorije: istraživanje s pomoću senzora u svemiru (*satellite-based*), zraku (*air-borne*) ili na tlu (*ground-based*) (slika 3). Pri odabiru platforme za daljinsko istraživanje mora se uzeti u obzir prostorna i spektralna razlučivost. Prednost je zračnih snimaka, u usporedbi sa satelitskima, u mogućnosti pružanja snimaka vrlo visoke prostorne rezolucije (20 cm ili manje). Budući da se zračna snimanja često provode kao jednokratne operacije, prednost je korištenja satelita za promatranje površine Zemlje u mogućnosti kontinuiranog praćenja (Ozesmi i Bauer, 2014.). Danas se daljinska istraživanja iz zraka uglavnom provode bespilotnim letjelicama (eng. *Unmanned Aerial Vehicles*). To su zrakoplovi kojima se daljinski upravlja sa zemaljske stanice, popraćeni sensorima – RGB, multispektralnim, hiperspektralnim i termalnim kamerama (Daponte i sur., 2019.). Njihova je osnovna primjena u praćenju fenologije biljaka, procjeni visine biljaka te procjeni statusa dušika u biljkama (Liu i sur., 2020.). U daljinskim istraživanjima s tla koriste se ručni instrumenti koji su iznimno korisni za operativno praćenje biotičkih i abiotičkih stresora usjeva na manjim površinama. Ta tehnologija ima bolju spektralnu i prostornu razlučivost od zračnih i satelitskih senzora, a ograničavajući je čimbenik učinkovitost i dugo vrijeme potrebno za analizu velikih površina u usporedbi sa zračnim i satelitskim sensorima koji mogu dati informacije za znatno veće površine odjednom (Wójtowicz i sur., 2015.). Spektroradiometri su instrumenti korisni za predviđanje prinosa usjeva, detekciju stresa suše, stresa od infestacije štetnih organizama i stresa od nedostatka biljnih hraniva te se mogu koristiti u poljskim i laboratorijskim istraživanjima. U spektralnim istraživanjima usjeva pšenice, mjerenja spektroradiometrom najčešće se obavljaju na razini lista (*leaf level*) ili na razini sklopa (*canopy level*). Spektralna analiza na razini lista manje je složena od one na razini sklopa te se takvi pokusi mogu izvoditi u zatvorenom prostoru. Također, na njih manje utječu okolišni čimbenici kao što su intenzitet svjetlosti, refleksija tla i struktura sklopa (orientacija listova, sjena i indeks lisne površine) (Jacquemoud i sur., 2009.; Yang i sur., 2021.). U posljednjih nekoliko desetljeća broj istraživanja spektralnih otisaka biljaka znatno se povećao jer su multi-

hiperspektralne kamere i terenski spektrometri sve više sposobni precizno izmjeriti cijeli elektromagnetski spektar (350 - 2500 nm) iz kojega se mogu dobiti informacije za niz biljnih svojstava (npr. Singh i sur., 2015.; Yang i sur., 2016., Silva-Perez i sur., 2018.). Spektrometri i multispektralni senzori mjere spektralnu refleksiju biljaka te pritom omogućuju izračun vegetacijskih indeksa. Vegetacijski indeksi mogu opisati zdravstveno stanje poljoprivrednih kultura, a svaki pojedini indeks koristi omjere i razlike između različitih dijelova elektromagnetskog spektra. S obzirom na sve navedeno, može se zaključiti da vegetacijski indeksi imaju mnogobrojne koristi u poljoprivrednoj praksi (Jelinek i sur., 2020.).



Slika 2. Krivulja spektralnog otiska zdrave vegetacije gdje VIS predstavlja vidljivi, NIR bliski infracrveni, a SWIR kratkovalni infracrveni dio spektra (uređeno prema Roman i Ursu, 2016.)



Slika 3. Kategorije daljinskih istraživanja; A) snimanje zračnim sensorom na bespilotnoj letjelici, B) snimanje vegetacije satelitskim sensorom, C) snimanje usjeva pšenice spektrometrijom. Izvori: <https://deeptechexpress.com/6-ways-drones-can-cut-crop-monitoring-costs/>, <https://www.tehrantimes.com/news/432895/>

ŠTO JE VEGETACIJSKI INDEKS (VI)?

Spektralni otisci vegetacije temelje se na činjenici da stanice lista različito reflektiraju ili apsorbiraju energiju u različitim dijelovima elektromagnetskog spektra. Upravo te razlike u refleksiji u vidljivu dijelu spektra te bliskom infracrvenom dijelu spektra dovele su do nastanka vegetacijskih indeksa (VI). Poznato je da zelene biljke ili one koje fotosintetiziraju koriste plavi i crveni dio spektra (VIS) kao izvor energije te unutar tih valnih duljina slabo reflektiraju energiju, iz toga se dijela spektra obično procjenjuje sadržaj klorofila i ostalih biljnih pigmenata, dok bliski infracrveni dio spektra (NIR) bilježi strukturalna svojstva lista. Zelena biljna masa obično apsorbira energiju u crvenom i plavom dijelu spektra, reflektira je u zelenom dijelu spektra te snažno reflektira energiju u bliskom infracrvenom dijelu spektra (Lillesand, 2004.). Spektralno područje između crvenog dijela unutar vidljiva spektra i visoke refleksije u bliskom infracrvenom dijelu spektra nazvano je crveni rub. On mijenja oblik i položaj kada biljka prolazi kroz stres, kao što je nedostatak dušika (Barnes i sur., 2000.). Također, biljno tkivo pokazuje snažna obilježja apsorpcije unutar kratkovalnog infracrvenog dijela spektra (SWIR), što je uvjetovano sadržajem vode u tkivu (Lillesand, 2004.) (slika 2). Različiti okolišni stresori uzrokuju

varijacije spektralne krivulje biljnog materijala u cijelom elektromagnetskom spektru. Biljni stres značajno mijenja spektralna obilježja vegetacije jer pigment klorofila brzo propada i gubi svoja svojstva apsorpcije, povećavajući refleksiju od plavog do crvenog dijela unutar vidljivog elektromagnetskog spektra (oko 400 nm – 670 nm) (Roy, 1989.). Štoviše, stres često rezultira klorozom listova, pri čemu biljke žute zbog gubitka klorofila i prevladavanja karotenoida (Roman i Ursu, 2016.). Mjerenje ovih varijacija i proučavanje njihova međusobna odnosa može pružiti značajne informacije o zdravstvenom stanju biljaka, sadržaju vode i drugim važnim biljnim svojstvima (Gitelson i sur., 2002.; Roman i Ursu, 2016.). Proučavanje spektralnih obilježja refleksije biljnog materijala pridonijelo je definiranju vegetacijskih indeksa, koji povezujući vrijednosti različitih kombinacija valnih duljina elektromagnetskog spektra s biljnim svojstvima, mogu modelima predikcije kvantificirati brojne agronomske varijable te odrediti njihove vremenske i prostorne varijacije (Šestak, 2011.). Vegetacijski indeks predstavlja bezdimenzionalnu radiometrijsku mjeru koja se dobiva kombinacijom vrijednosti iz više spektralnih područja u jednu vrijednost. Brojni vegetacijski indeksi temeljeni na valnim duljinama u vidljivu i bliskom infracrvenom dijelu elektromagnetskog spektra korišteni su u daljinskim istraživanjima za predikciju biomase, biokemijskih komponenti lista i nekih fizioloških biljnih svojstava. Na primjer, vegetacijski indeks normalizirane razlike (Normalized difference vegetation index, NDVI) koristi se za praćenje vegetacije korištenjem crvenog i bliskog infracrvenog dijela spektra za mjerenje relativnog udjela zelene mase, razvoja lišća, biomase i sadržaja klorofila (Silva-Perez i sur., 2018.). Freeman i sur. (2003.) istraživali su mogućnost predikcije prinosa ozime pšenice s pomoću NDVI-a te zaključili kako je NDVI izmjeren u razvojnim fazama kasnog vlatanja, klasanja i cvjetanja korelirao s prinosom zrna. Neki vegetacijski indeksi kao što su MRSI (*Modified ratio spectral index*) i CCI (*Chlorophyll content index*) koriste se pri kvantifikaciji indeksa lisne površine (*LAI*) i udjela klorofila (Yang i sur., 2021.). U tablici 1 prikazani su najčešće korišteni vegetacijski indeksi u daljinskim istraživanjima pšenice, njihove formule te mogućnosti primjene.

Tablica 1. Značajni vegetacijski indeksi u daljinskim istraživanjima usjeva pšenice

Indeks	Naziv	Formula	Primjena	Izvori
NDVI	<i>Normalized difference vegetation index</i>	$NDVI = \frac{RNIR - RR}{RNIR + RR}$	Predikcija prinosa Procjena biomase Procjena statusa dušika (N) Monitoring stresa suše	Šestak, 2011. Freeman i sur., 2003. Cabrera-Bosquet i sur., 2011.

CCI	<i>Chlorophyll content index</i>	CCI = RNIR (931 nm)/RRed (653 nm)	Procjena statusa dušika (N) Procjena biljnih bolesti	Denis i sur., 2020. Mishra i sur., 2015.
NPCI	<i>Normalized pigment chlorophyll index</i>	(R680 – R430)/(R680 + R430)	Procjena udjela klorofila u listu	Huang i sur., 2021.
PRI	<i>Photochemical Reflectance Index</i>	PRI = (R530 - R570) / (R530 + R570)	Akumulacija biomase	Magney i sur., 2016.
GNDVI	<i>Green normalized difference vegetation index</i>	GNDVI = (RNIR - RGREEN)/(RNIR + RGR EEN)	Predikcija prinosa Procjena statusa dušika Procjena razine šteta od štetnika	Mirik i sur., 2012. Hunt i sur., 2008. Li i sur., 2019.
SAVI	<i>Soil adjusted vegetation index</i>	SAVI = ((RNIR - RRED) / (RNIR + RRED + L)) x (1 + L)	Predikcija prinosa Procjena LAI Procjena statusa dušika (N)	Nagy i sur., 2021. Gupta i sur., 2006. Wang i sur., 2015.
OSAVI	<i>Optimized soil-adjusted vegetation index</i>	OSAVI = (RNIR-RR) / (RNIR+RR+L) L=0.16	Procjena statusa dušika (N) Monitoring biljnih bolesti	Yao i sur., 2014. Su i sur., 2018.
AI	<i>Aphid index</i>	AI = (R740- R887)/(R691-R698)	Procjena i rana detekcija napada lisnih uši	Mirik i sur., 2012.
WI	<i>Water index</i>	WI = R900/R970	Procjena stresa suše	Sun i sur., 2019.
NDWI	<i>Normalized difference water index</i>	NDWI = (R860- R1240)/(R860+R1240)	Procjena stresa suše	Wang i sur., 2015.

PRIMJENA VEGETACIJSKIH INDEKSA

Pravodobno detektiran stres usjeva omogućuje brzo usklađivanje i prilagodbu planiranih agrotehničkih zahvata te sprječavanje negativnih učinaka na prinos što predstavlja jedan od postulata precizne poljoprivrede. Precizna poljoprivreda – koncept upravljanja koji se temelji na promatranju, mjerenju i reagiranju na varijabilnost usjeva unutar polja – uključuje prikupljanje podataka za karakterizaciju prostorne varijabilnosti polja, mapiranje te donošenje i provedbu odluka u praksi (Mulla, 2013.). Razvoj daljinskih istraživanja utjecao je na veći broj primjena u preciznoj poljoprivredi te omogućio razvoj vegetacijskih indeksa kao indikatora biljnog stresa i predikcije prinosa (Polivova i Brook, 2021.). Danas se vegetacijski indeksi u usjevima pšenice primjenjuju

.....

kod procjene abiotskog stresa – nedostatka vlage (suša) i nedostatka biljnih hraniva te biotskog stresa – napada štetnika i uzročnika biljnih bolesti. Osim procjene stresa, vegetacijski indeksi imaju nezamjenjivu ulogu u predikciji biomase i konačnog prinosa zrna (Šestak i sur., 2018.).

Detekcija stresa suše

U daljinskim istraživanjima usjeva pšenice posebna se pozornost posvećuje sušnom stresu zbog njegova iznimnog negativnog utjecaja na rast, razvoj te konačan prinos zrna (Kramer, 1983.; Tilling i sur., 2007.). S obzirom na utjecaj suše u usjevima ozime pšenice, biljke su osjetljive u određenim kritičnim fazama rasta, tj. klijanju i nicanju, busanju i vlatanju, a posebno u fenofazama razvoja reproduktivnih organa, kao što je cvatnja i nalijevanje zrna (Kovačević i Rastija, 2014.; Sarto i sur., 2017.). Brza procjena sadržaja vode u biljkama pšenice, osim za potrebe upravljanja navodnjavanjem, omogućila bi učinkovit pregled i raspoznavanje otpornih sorata unutar oplemenjivačkih programa (Elsayed i sur., 2011.). Mjerenje spektralnih obilježja usjeva pšenice predstavlja laku, brzu, praktičnu i ekonomičnu tehniku za procjenu nekoliko kriterija fenotipizacije povezanih s otpornosti na sušu. Nekoliko spektralnih raspona smatra se korisnim za procjenu sušnog stresa. Na temelju vegetacijskih indeksa izračunanih u omjerima i razlikama između refleksije biljnog materijala na vidljivom (VIS), bliskom infracrvenom (NIR) i kratkovalnom infracrvenom (SWIR) dijelu elektromagnetskog spektra mogu se predvidjeti različita agronomska biljna svojstva povezana sa sušom (El-Hendawy i sur., 2017.). Rezultati El-Hendawy i sur. (2017.) pokazuju da se u oplemenjivačkim programima kombinacija bliskih infracrvenih (NIR) i kratkovalnih infracrvenih (SWIR) valnih duljina može koristiti kao brz i jeftin način za odabir genotipova pšenice s većim potencijalnim prinosom uz različite vodne režime. Brojni indeksi dizajnirani su kao indikatori sušnog stresa u usjevima pšenice. Za tu su svrhu u literaturi najčešće korišteni indeksi NDVI (*Normalized difference vegetation indeks*), SR (*Simple ratio*), PRI (*Photochemical reflectance index*), WI (*Water index*), NDWI (*Normalized difference water index*), WBI (*Water band index*) i BPI (*Brown pigment index*) (Sun i sur., 2019.; Wang i sur., 2015.; Klem i sur., 2018.).

Detekcija napada štetnika i uzročnika biljnih bolesti

Maceljski (2000.) navodi da precizna zaštita bilja mora omogućiti adekvatne mjere zaštite, i to tako da one budu optimalne svakoj biljci, a ne samo prosjeku svih biljaka u polju. Precizna zaštita bilja pritom mora težiti i izbjegavanju primjene nekoga sredstva za zaštitu bilja gdje nije potrebno, sniženju troškova te smanjenju onečišćenja okoliša. Pesticidi se mogu primijeniti na specifične dijelove polja ako je poznata prostorno-vremenska pojava stresa na biljkama. Za postizanje tako prostorno precizne primjene, potrebna je detekcija i

mapiranje simptoma stresa u usjevima utemeljena na podacima dobivenima sensorima. Metode daljinskih istraživanja mogle bi biti prikladan alat za praćenje heterogenosti usjeva, a mogle bi i omogućiti smanjenje uporabe pesticida pravodobnim lokaliziranim tretiranjima i smanjenim dozama aplikacije pesticida (Franke i Menz, 2007.). Patogeni pšenice uzrokuju smanjenje sadržaja klorofila u listovima zbog nekrotičnih ili klorotičnih lezija koje utječu na krivulju refleksije u vidljivu dijelu (VIS) i dijelu crvenog ruba spektra (550 nm; 650 – 720 nm). Starenjem zaraženih lezija dolazi do posmeđenja i sušenja lista te takvi simptomi utječu na vidljivi i bliski infracrveni dio spektra (680 – 800 nm). Što se tiče strukture biljnog sklopa, infekcija patogenom mijenja gustoću sklopa i lisnu površinu, što se može uočiti u bliskom infracrvenom dijelu spektra (West i sur., 2003., Franke i Menz., 2007.). Zbog ovih karakteristika postoji velik potencijal za detekciju zaraženih biljaka na temelju snimanja sensorima. Najčešće korišteni vegetacijski indeksi uporabljeni za ranu detekciju napada biljnih bolesti su NBNDVI (*Narrow-band normalized difference vegetation indeks*), NDVI (*Normalized difference vegetation index*), PRI (*Photochemical reflectance index*), i GI (*Greenness index*) (Ashourloo i sur., 2014.). Simptomi hranjenja kukaca na biljkama dovode do promjene koncentracije kemijskih pigmenta, lisne površine i stanične strukture zahvaćena tkiva ili biljke (Mirik i sur., 2012.). U najznačajnije štetnike pšenice ubrajaju se lisne uši. U istraživanju Mirik i sur., (2012.) pšenica zaražena ruskom lisnom ušom (*Diuraphis noxia*, Mordvilko) imala je veću vidljivu refleksiju od 460 nm do oko 730 – 750 nm od nezaražene pšenice. Iznad 730 – 750 nm, bliska infracrvena (NIR) refleksija nezaražene pšenice bila je veća u usporedbi sa zaraženom pšenicom. U istom su istraživanju četiri indeksa pokazala dobru korelaciju s razinom napada štetnika, to su indeksi NDVI (*Normalized difference vegetation index*), GNDVI (*Green normalized difference vegetation index*), MNDVI (*Modified normalized difference vegetation index*) i SR (*Simple ratio*). U istraživanju Mirik i sur., (2007.) za procjenu razine napada *D. noxia* na pšenici uspješno je implementiran i korišten indeks AI (*Aphid index*).

Procjena sadržaja dušika (N) u usjevu

Dušik je kritičan element potreban za stvaranje biomase poljoprivrednih kultura, pri čemu se njegova koncentracija u biljkama smanjuje kako se udio suhe biomase povećava (Raj i sur., 2021.) Udio klorofila u listu i njemu razmjerni sadržaj dušika u listu indikator su potreba usjeva pšenice za dušikom (Šestak, 2011.). Kako je koncentracija dušika u listu povezana s količinom klorofila, mnoga su se daljinska istraživanja usredotočila na procjenu koncentracije klorofila u listovima, kako bi se na neizravan način procjenio status dušika, što je jednostavnija metoda od klasičnih laboratorijskih analiza procjene sadržaja dušika u biljci (Haboudane i sur., 2008.). Mnogi su autori ustanovili značajne valne duljine unutar elektromagnetskog spektra (515, 520,

525, 550, 575, 743, 1116, 2173 i 2359 nm) koje koreliraju sa sadržajem dušika u biljkama (Thenkabail i sur., 2016.). Neka su istraživanja pokazala korelaciju između indeksa koji se temelje na spektralnom području crvenog ruba i sadržaja dušika u usjevu. DCNI (*Double peak canopy nitrogen index*) primjer je indeksa koji se temelji na crvenom rubu gdje su korištene valne duljine od 720, 700 i 670 nm (Raj i sur., 2021.). Osim indeksa DCNI, u literaturi se za ovu svrhu najčešće primjenjuju indeksi: NDVI (*Normalized difference vegetation index*), CCI (*Chlorophyl content index*), GNDVI (*Green normalized difference vegetation index*), SAVI (*Soil adjusted vegetation index*), OSAVI (*Optimized soil adjusted vegetation index*) i RVI (*Ratio vegetation index*) (Šestak, 2011.; Yao i sur., 2014.; Denis i sur., 2020.; Frels i sur., 2018.)

Predikcija prinosa

Na prinos usjeva mogu utjecati mnogi čimbenici kao što su oborine i temperatura tijekom vegetacije, svojstva tla, štetni organizmi i antropogeni čimbenici poput navodnjavanja ili gnojidbe (Prasad i sur., 2006.) Napredak u predviđanju vremenskih uvjeta i modeliranju usjeva omogućio je razvoj tehnologije za predviđanje potencijalnih prinosa zrna (Raun i sur., 2001.). Točno predviđanje prinosa i kvalitete pšenice prije žetve vrlo je poželjno, kako bi se upravljalo lancima opskrbe, kao i za sigurnost hrane i procjenu njezine kvalitete (Lee i sur., 2013). Također, značajno je i za donošenje odluka i primjene odgovarajućih agrotehničkih mjera, kao što je gnojidba (Bonfil i sur., 2004.). Korelacija indeksa NDVI s prinosom dokazana je za nekoliko fizioloških svojstava usjeva koja utječu na prinos u različitim agroekološkom uvjetima. Veća vrijednost indeksa NDVI povezana je s bržom stopom rasta te s većom akumulacijom biomase tijekom vegetativnih faza kao i s produženjem razdoblja nalijevanja zrna koje nastaje kao rezultat odgađanja starenja listova tijekom faze zriobe, čime se konačno povećava prinos (Hassan i sur., 2018.). Kako bi se uspostavio najbolji model predikcije prinosa pšenice, najčešće se, uz indeks NDVI (*Normalized difference vegetation index*), koriste vegetacijski indeksi, kao što je NDNI (*Normalized difference nitrogen index*), NDWI (*Normalized difference water index*), GNDVI (*Green difference vegetation index*), SAVI (*Soil adjusted vegetation index*) (Chandel i sur., 2019.; Li i sur., 2019.).

ZAKLJUČCI

Vegetacijski indeksi koji kombiniraju vidljive (VIS), blisko infracrvene (NIR) i kratkovalne infracrvene (SWIR) dijelove spektra značajno su poboljšali i ubrzali proces detekcije zdravstvenog stanja usjeva pšenice te omogućili procjenu prinosa u ranijim fenofazama. Različiti okolišni uvjeti uzgoja usjeva imaju svoje varijabilne i složene karakteristike, koje je potrebno uzeti u obzir pri korištenju različitih vegetacijskih indeksa. Stoga svaki indeks ima svoju specifičnu formulu,

svoju prikladnost za specifične primjene i neke ograničavajuće čimbenike. Stoga, za praktične primjene, odabir specifičnog indeksa treba biti napravljen oprezno, uz sveobuhvatno razmatranje i analizu prednosti i ograničenja, a zatim ga kombinirati za primjenu u određenim okolišnim uvjetima uzgoja. S razvojem tehnologije hiperspektralnih i multispektralnih senzora za daljinska istraživanja mogu se razviti novi vegetacijski indeksi, koji bi mogli proširiti područja istraživanja.

Ovaj pregledni rad nastao je kroz projekt Napredna i prediktivna poljoprivreda za otpornost na klimatske promjene (AgroSPARC) (KK.05.1.1.02.0031) koji financira Europski fond za regionalni razvoj i Fond za zaštitu okoliša i energetska učinkovitost Republike Hrvatske.

VEGETATION INDICES - TOOLS FOR ASSESSING THE CONDITION OF WHEAT

SUMMARY

The frequency and intensity of extreme weather events are likely to increase with climate change. Wheat (*Triticum aestivum* L.) production is critical to global food security. Climate change threatens sustainable wheat production not only through direct negative impacts on crop growth, but also through profound effects on the dynamics and severity of pests and diseases. Reducing yield losses is necessary to sustainably increase the efficiency of agricultural production and meet our current and future needs for food, fiber, animal feed, and biofuel. Our growing understanding of how crops respond to abiotic and biotic stress has led to the development of innovative sensing technologies to detect stress in crops and develop a rapid and simplified decision support system (DSS) for decision making in different phenophases and for effective interventions. Spectral vegetation indices (VI) are well-known and widely used tools for assessing wheat crop condition and predicting grain yields. This article describes methods for determining vegetation indices using remote sensing methods and their broad application. Vegetation indices can be used to estimate drought severity, detect pests early, assess crop nitrogen status, and predict biomass, leaf area index, and final yield.

Key words: remote sensing, vegetation indices, wheat, estimation of crop stress, yield prediction

LITERATURA

Aggarwal, S. (2004.). Principles of remote sensing. Satellite remote sensing and GIS applications in agricultural meteorology, 23(2), 23-28.

Ashourloo, D., Mobasheri, M. R., & Huete, A. (2014.). Evaluating the effect of different wheat rust disease symptoms on vegetation indices using hyperspectral measurements. Remote Sensing, 6(6), 5107-5123.

.....

Barnes, E. M., Clarke, T. R., Richards, S. E., Colaizzi, P. D., Haberland, J., Kostrzewski, M., ... & Moran, M. S. (2000, July). Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In Proceedings of the Fifth International Conference on Precision Agriculture, Bloomington, MN, USA (Vol. 1619).

Bonfil, D. J., Karnieli, A., Raz, M., Mufradi, I., Asido, S., Egozi, H., ... & Schmilovitch, Z. (2004.). Decision support system for improving wheat grain quality in the Mediterranean area of Israel. *Field Crops Research*, 89(1), 153-163.

Cabrera-Bosquet, L., Molero, G., Stellacci, A., Bort, J., Nogués, S., & Araus, J. (2011.). NDVI as a potential tool for predicting biomass, plant nitrogen content and growth in wheat genotypes subjected to different water and nitrogen conditions. *Cereal Research Communications*, 39(1), 147-159.

Chandel, N. S., Tiwari, P. S., Singh, K. P., Jat, D., Gaikwad, B. B., Tripathi, H., & Golhani, K. (2019.). Yield prediction in wheat (*Triticum aestivum* L.) using spectral reflectance indices. *Curr. Sci*, 116(2), 272.

Daponte, P., de Vito, L., Glielmo, L., Iannelli, L., Liuzza, D., Picariello, F., Silano, G. (2019.). A review on the use of drones for precision agriculture. *Metrology for Agriculture and Forestry*, 275, 1-10.

Denis, A., Desclee, B., Migdall, S., Hansen, H., Bach, H., Ott, P., ... & Tychon, B. (2020.). Multispectral remote sensing as a tool to support organic crop certification: assessment of the discrimination level between organic and conventional maize. *Remote Sensing*, 13(1), 117.

Elsayed, S., Mistele, B., & Schmidhalter, U. (2011.). Can changes in leaf water potential be assessed spectrally?. *Functional Plant Biology*, 38(6), 523-533.

El-Hendawy, S. E., Hassan, W. M., Al-Suhaibani, N. A., & Schmidhalter, U. (2017.). Spectral assessment of drought tolerance indices and grain yield in advanced spring wheat lines grown under full and limited water irrigation. *Agricultural Water Management*, 182, 1-12.

Frančula, N., Lapaine, M., & Vučetić, N. (1994.). Primjena daljinskih istraživanja u kartografiji. *Geodetski list*, 3, 265-276.

Franke, J., & Menz, G. (2007.). Multi-temporal wheat disease detection by multi-spectral remote sensing. *Precision Agriculture*, 8(3), 161-172.

Freeman, K. W., Raun, W. R., Johnson, G. V., Mullen, R. W., Stone, M. L., & Solie, J. B. (2003.). Late-season prediction of wheat grain yield and grain protein. *Communications in Soil Science and Plant Analysis*, 34(13-14), 1837-1852.

Frels, K., Guttieri, M., Joyce, B., Leavitt, B., & Baenziger, P. S. (2018.). Evaluating canopy spectral reflectance vegetation indices to estimate nitrogen use traits in hard winter wheat. *Field Crops Research*, 217, 82-92.

Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002.). Novel algorithms for remote estimation of vegetation fraction. *Remote sensing of Environment*, 80(1), 76-87.

Grote, U., Fasse, A., Nguyen, T. T., & Erenstein, O. (2021.). Food security and the dynamics of wheat and maize value chains in Africa and Asia. *Frontiers in Sustainable Food Systems*, 4, 617009.

Gupta, R. K., Vijayan, D., & Prasad, T. S. (2006.). The relationship of hyper-spectral vegetation indices with leaf area index (LAI) over the growth cycle of wheat and chickpea at 3 nm spectral resolution. *Advances in Space Research*, 38(10), 2212-2217.

Hagen, N. A., & Kudenov, M. W. (2013.). Review of snapshot spectral imaging technologies. *Optical Engineering*, 52(9), 090901.

Hassan, M. A., Yang, M., Rasheed, A., Yang, G., Reynolds, M., Xia, X., ... & He, Z. (2019.). A rapid monitoring of NDVI across the wheat growth cycle for grain yield prediction using a multi-spectral UAV platform. *Plant science*, 282, 95-103.

Huang, L., Wu, K., Huang, W., Dong, Y., Ma, H., Liu, Y., & Liu, L. (2021.). Detection of Fusarium Head Blight in Wheat Ears Using Continuous Wavelet Analysis and PSO-SVM. *Agriculture*, 11(10), 998.

Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P. J., Asner, G. P., ... & Ustin, S. L. (2009.). PROSPECT+ SAIL models: A review of use for vegetation characterization. *Remote sensing of environment*, 113, S56-S66.

Jelínek, Z., Stary, K., Kumhálová, J., Lukáš, J., & Mašek, J. (2020.). Winter wheat, winter rape and poppy crop growth evaluation with the help of remote and proximal sensing measurements.

Kashyap, B., & Kumar, R. (2021.). Sensing methodologies in agriculture for monitoring biotic stress in plants due to pathogens and pests. *Inventions*, 6(2), 29.

Klem, K., Záhora, J., Zemek, F., Trunda, P., Tůma, I., Novotná, K., ... & Holub, P. (2018.). Interactive effects of water deficit and nitrogen nutrition on winter wheat. Remote sensing methods for their detection. *Agricultural Water Management*, 210, 171-184.

Kramer, P. J. (1983.). Problems in water relations of plants and cells. In *International review of cytology* (Vol. 85, pp. 253-286). Academic Press.

Kovačević, V., & Rastija, M. (2014.). Žitarice, sveučilišni udžbenik, Poljoprivredni fakultet u Osijeku.

Lee, B. H., Kenkel, P., & Brorsen, B. W. (2013.). Pre-harvest forecasting of county wheat yield and wheat quality using weather information. *Agricultural and forest meteorology*, 168, 26-35.

Li, H., Zhang, Y., Lei, Y., Antoniuk, V., & Hu, C. (2019.). Evaluating different non-destructive estimation methods for winter wheat (*Triticum aestivum* L.) nitrogen status based on canopy spectrum. *Remote Sensing*, 12(1), 95.

Lillesand, T.M., Kiefer, R.W., Chipman, J.W. (2004.). *Remote sensing and image interpretation*. 5th ed. John Wiley & Sons, New York.

Maceljški, M. (2000.). Precizna zaštita bilja kao dio precizne poljoprivrede. In XLIV. seminar iz zaštite bilja, Opatija, str (Vol. 3, No. 4).

Maid, M. K., & Deshmukh, R. R. (2018, May). Statistical Analysis of WLR (Wheat Leaf Rust) Disease using ASD FieldSpec4 Spectroradiometer. In 2018 3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT) (pp. 1398-1402). IEEE.

Mirik, M., Michels Jr, G. J., Kassymzhanova-Mirik, S., & Elliott, N. C. (2007.). Reflectance characteristics of Russian wheat aphid (Hemiptera: Aphididae) stress and abundance in winter wheat. *Computers and Electronics in Agriculture*, 57(2), 123-134.

Mirik, M., Ansley, R. J., Michels, G. J., & Elliott, N. C. (2012.). Spectral vegetation indices selected for quantifying Russian wheat aphid (*Diuraphis noxia*) feeding damage in wheat (*Triticum aestivum* L.). *Precision Agriculture*, 13(4), 501-516.

Mulla, D. J. (2013.). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems engineering*, 114(4), 358-371.

Nagy, A., Szabó, A., Adeniyi, O. D., & Tamás, J. (2021.). Wheat Yield Forecasting for the Tisza River Catchment Using Landsat 8 NDVI and SAVI Time Series and Reported Crop Statistics. *Agronomy*, 11(4), 652.

Oluić, M. (2001.). Snimanje i istraživanje Zemlje iz Svemira. Hrvatska akademija znanosti i umjetnosti, Zagreb.

Ozesmi, S. L., & Bauer, M. E. (2002.). Satellite remote sensing of wetlands. *Wetlands ecology and management*, 10(5), 381-402.

Polivova, M., & Brook, A. (2021.). Detailed Investigation of Spectral Vegetation Indices for Fine Field-Scale Phenotyping.

Prasad, A. K., Chai, L., Singh, R. P., & Kafatos, M. (2006.). Crop yield estimation model for Iowa using remote sensing and surface parameters. *International Journal of Applied earth observation and geoinformation*, 8(1), 26-33.

Raj, R., Walker, J. P., Vinod, V., Pingale, R., Naik, B., & Jagarlapudi, A. (2021.). Leaf water content estimation using top-of-canopy airborne hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102393.

Raun, W. R., Solie, J. B., Johnson, G. V., Stone, M. L., Lukina, E. V., Thomason, W. E., & Schepers, J. S. (2001.). In-season prediction of potential grain yield in winter wheat using canopy reflectance. *Agronomy Journal*, 93(1), 131-138.

Roman, A., & Ursu, T. (2016.). Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks. *Landscape archaeology on the northern frontier of the roman empire at porolissum: an interdisciplinary research project*. Cluj-Napoca: Mega Publishing House, 141-152.

Roy, P. S. (1989.). Spectral reflectance characteristics of vegetation and their use in estimating productive potential. In *Proceedings/Indian Academy of Sciences (Vol. 99, No. 1, pp. 59-81)*. Springer India.

Sarto, M. V. M., Sarto, J. R. W., Rampim, L., Rosset, J. S., Bassegio, D., da Costa, P. F., & Inagaki, A. M. (2017.). Wheat phenology and yield under drought: a review. *Australian Journal of Crop Science*, 11(8), 941-946.

Silva-Perez, V., Molero, G., Serbin, S. P., Condon, A. G., Reynolds, M. P., Furbank, R. T., & Evans, J. R. (2018.). Hyperspectral reflectance as a tool to measure biochemical and physiological traits in wheat. *Journal of Experimental Botany*, 69(3), 483-496.

Singh, A., Serbin, S. P., McNeil, B. E., Kingdon, C. C., & Townsend, P. A. (2015.). Imaging spectroscopy algorithms for mapping canopy foliar chemical and morphological traits and their uncertainties. *Ecological Applications*, 25(8), 2180-2197.

Skendžić, S., Zovko, M., Živković, I. P., Lešić, V., & Lemić, D. (2021.). The impact of climate change on agricultural insect pests. *Insects*, 12(5), 440.

Su, J., Liu, C., Coombes, M., Hu, X., Wang, C., Xu, X., ... & Chen, W. H. (2018.). Wheat yellow rust monitoring by learning from multispectral UAV aerial imagery. *Computers and electronics in agriculture*, 155, 157-166.

Sun, H., Feng, M., Xiao, L., Yang, W., Wang, C., Jia, X., ... & Li, D. (2019.). Assessment of plant water status in winter wheat (*Triticum aestivum* L.) based on canopy spectral indices. *PLoS One*, 14(6), e0216890.

Šestak, I. (2011). Use of Field Spectroscopy for Assessment of Nitrogen Use Efficiency in Winter Wheat (Doctoral dissertation, Doctoral thesis, University of Vol. 22 / Br. 3

Zagreb).

Šestak, I., Mesić, M., Zgorelec, Ž., & Perčin, A. (2018.). Diffuse reflectance spectroscopy for field scale assessment of winter wheat yield. *Environmental Earth Sciences*, 77(13), 1-11.

Thenkabail, P. S., & Lyon, J. G. (Eds.). (2016.). *Hyperspectral remote sensing of vegetation*. CRC press.

Tilling, A. K., O'Leary, G. J., Ferwerda, J. G., Jones, S. D., Fitzgerald, G. J., Rodriguez, D., & Belford, R. (2007.). Remote sensing of nitrogen and water stress in wheat. *Field Crops Research*, 104(1-3), 77-85.

Travlos, I., Mikroulis, A., Anastasiou, E., Fountas, S., Bilalis, D., Tsiropoulos, Z., & Balafoutis, A. (2017). The use of RGB cameras in defining crop development in legumes. *Advances in Animal Biosciences*, 8(2), 224-228.

Wang, X., Zhao, C., Guo, N., Li, Y., Jian, S., & Yu, K. (2015.). Determining the canopy water stress for spring wheat using canopy hyperspectral reflectance data in loess plateau semiarid regions. *Spectroscopy Letters*, 48(7), 492-498.

West, J. S., Bravo, C., Oberti, R., Lemaire, D., Moshou, D., & McCartney, H. A. (2003.). The potential of optical canopy measurement for targeted control of field crop diseases. *Annual review of Phytopathology*, 41(1), 593-614.

Wójtowicz, M., Wójtowicz, A., & Piekarczyk, J. (2016.). Application of remote sensing methods in agriculture. *Communications in Biometry and Crop Science*, 11(1), 31-50.

Xie, Y., Sha, Z., & Yu, M. (2008.). Remote sensing imagery in vegetation mapping: a review. *Journal of plant ecology*, 1(1), 9-23.

Yang, X., Tang, J., Mustard, J. F., Wu, J., Zhao, K., Serbin, S., & Lee, J. E. (2016.). Seasonal variability of multiple leaf traits captured by leaf spectroscopy at two temperate deciduous forests. *Remote Sensing of Environment*, 179, 1-12.

Yang, T., Lu, J., Liao, F., Qi, H., Yao, X., Cheng, T., ... & Tian, Y. (2021.). Retrieving potassium levels in wheat blades using normalised spectra. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102412.

Yao, X., Yao, X., Jia, W., Tian, Y., Ni, J., Cao, W., & Zhu, Y. (2013.). Comparison and intercalibration of vegetation indices from different sensors for monitoring above-ground plant nitrogen uptake in winter wheat. *Sensors*, 13(3), 3109-3130.

Yao, X., Ren, H., Cao, Z., Tian, Y., Cao, W., Zhu, Y., & Cheng, T. (2014.). Detecting leaf nitrogen content in wheat with canopy hyperspectrum under different soil backgrounds. *International Journal of Applied Earth Observation and Geoinformation*, 32, 114-124.

Zhu, L., Suomalainen, J., Liu, J., Hyypä, J., Kaartinen, H., & Haggren, H. (2018.). A review: Remote sensing sensors. Multi-purposeful application of geospatial data, 19-42.

Pregledni rad