

## NAPOVEDOVANJE POMANJKANJA VODE Z UPORABO HIPERSPEKTRALNEGA SLIKANJA IN GLOBOKEGA UČENJA

Janez LAPAJNE<sup>1</sup>, Andrej VONČINA<sup>2</sup>, Uroš ŽIBRAT<sup>3</sup>

<sup>1-3</sup> Kmetijski inštitut Slovenije, Oddelek za varstvo rastlin, Ljubljana

### IZVLEČEK

Na uspešnost pridelave krompirja lahko vplivajo stresni dejavniki, zlasti suša in vročina. Hiperspektralno slikanje in modeli globokega učenja ponujajo obetavno rešitev, saj lahko z njimi na neinvaziven način zaznamo spektralne in prostorske spremembe rastlin. Čeprav modeli globokega učenja učinkovito zaznavajo stresne dejavnike, so izzivi, kot sta "prekletstvo dimenzionalnosti" in pretirano prilagajanje modelov, še vedno prisotni, kar zahteva tehnično znanje za modeliranje. V raziskavi, ki je bila izvedena na Kmetijskem inštitutu Slovenije, smo dve sorti krompirja (KIS Krka - odporna na sušo in KIS Savinja - občutljiva na sušo), izpostavili pomanjkanju vode. Z uporabo sistema dveh hiperspektralnih senzorjev in konvolucijske nevronske mreže (CNN) z mehanizmom pozornosti smo identificirali rastline s pomanjkanjem vode. Pri obravnavanju KIS Krka se je model izkazal za učinkovitega, saj je dosegel AUC-ROC 0,74. Pri obravnavanju KIS Savinja je bila učinkovitost modela manjša, saj je model v povprečju dosegel AUC-ROC 0,64. Točnost, priklic in rezultati F1 so pokazali robustnost modela in možnost zgodnjega zaznavanja pomanjkanja vode. Poleg tega je študija pokazala, da je imelo ključno vlogo več spektralnih območij, npr. 475-580 nm, 660-730 nm, 940-970 nm, 1420-1510 nm, 1875-2040 nm in 2350-2480 nm. Uporabljena metodologija globokega učenja izpostavlja izzive pri razlikovanju obravnavanj zaradi podobnih spektralnih podpisov, pri čemer poudarja pomen spektralno-prostorskih informacij. Spektralne analize poudarjajo vloge klorofila in vsebnosti vode v vidnem in bližnjeinfrardečem ter kratkovalovnem infrardečem spektru, kar pomaga pri oceni fiziološkega stanja rastlin. Ugotovitve raziskave so uporabne pri snovanju natančnega kmetijstva, saj omogočajo optimalno dodeljevanje virov in pospešeno izbiro na sušo odpornih kultivarjev. Poleg tega omogočajo uporabo daljinskega zaznavanja za ciljno usmerjeno upravljanje vode v spreminjajočih se podnebnih razmerah.

**Ključne besede:** hiperspektralno slikanje, globoko učenje, krompir, pomanjkanje vode, sušni stres

27

<sup>1</sup> mag. inž. str., Hacquetova ulica 17, SI-1000 Ljubljana, e-pošta: janez.lapajne@kis.si

<sup>2</sup> dr., prav tam

<sup>3</sup> dr., prav tam

## ABSTRACT

### LACK OF WATER DETECTION BY UTILIZATION OF HYPERSPECTRAL IMAGING AND DEEP LEARNING

Hyperspectral imaging has emerged as a pivotal technology in agricultural research, offering a powerful means to non-invasively monitor stress factors, such as drought, in crops like potato plants. In this context, the integration of attention-based deep learning models presents a promising avenue for enhancing the efficiency of stress detection, by enabling the identification of meaningful spectral channels. The study assesses performance of deep learning models on two potato plant cultivars exposed to water-deficient condition. It explores how various sampling strategies and biases impact the classification metrics by using a dual-sensor hyperspectral imaging system (VNIR and SWIR). Moreover, it directed its focus towards pinpointing crucial wavelengths within the concatenated images indicative of water-deficient condition. The proposed deep learning model yields encouraging results. In the context of binary classification, it achieved an area under the receiver operating characteristic curve (AUC-ROC) of 0.74 (95% CI: 0.70, 0.78) and 0.64 (95% CI: 0.56, 0.69) for KIS Krka and KIS Savinja varieties, respectively. Moreover, the corresponding F1 scores were 0.67 (95% CI: 0.64, 0.71) and 0.63 (95% CI: 0.56, 0.68). The evaluation of performance on datasets with deliberately introduced biases consistently demonstrated superior results in comparison to their non-biased equivalents. Notably, the ROC-AUC values exhibited significant improvements, registering a maximum increase of 10.8% for KIS Krka and 18.9% for KIS Savinja. The wavelengths of greatest significance were observed in the ranges of 475 – 580 nm, 660 – 730 nm, 940 – 970 nm, 1420 – 1510 nm, 1875 – 2040 nm, and 2350 – 2480 nm. These findings suggest that discerning between the two treatments is attainable, despite the absence of prominently manifested symptoms of drought stress in either cultivar through visual observation. The research outcomes carry significant implications for both precision agriculture and potato breeding. In precision agriculture, precise water monitoring enhances resource allocation, irrigation, yield, and loss prevention. Hyperspectral imaging holds potential to expedite drought-tolerant cultivar selection, thereby streamlining breeding for resilient potatoes adaptable to shifting climates.

28

**Key words:** hyperspectral imaging, deep learning, potato plant, water-deficiency, drought stress.

#### 1 UVOD

Krompir je ena najpomembnejših svetovnih kulturnih rastlin, saj zaseda četrto mesto po površini pridelave s 17,6 milijona hektarov in letno pridelavo 386 milijonov ton [1]. Zaradi visoke produktivnosti je primeren za pridelavo v različnih okoljih, kar prispeva k zmanjševanju globalne lakote in podpiranju prehranske varnosti [2]. Različni stresni dejavniki, kot sta vročina in suša, vplivajo na pridelek krompirja. Suša povzroča zapletene odzive v rastlinah, kot so zapiranje rež, zmanjšana fotosinteza in rast ter sinteza stresnih spojin, kot sta prolin in abscizinska kislina.

Čeprav ti odzivi pomagajo krompirju preživeti, dolgotrajen stres lahko škoduje razvoju gomoljev in zmanjšuje pridelek.

Različne tehnologije daljinskega zaznavanja, kot so LiDAR, termično slikanje in spektralno slikanje, lahko pomagajo ublažiti te težave. Njihova uporaba prinaša več prednosti, kot so zmanjšanje človeškega dela, objektivne in kvantitativne meritve, neinvazivno spremljanje, zgodnje odkrivanje zdravja rastlin, stroškovna učinkovitost in uporaba na večjih območjih. Hiperspektralno slikanje (HSI) je ena izmed najpogosteje uporabljenih tehnik, saj daje obetavne rezultate pri zaznavanju različnih biotskih in abiotskih stresorjev na različnih poljščinah, vključno s krompirjem. Je neinvazivna tehnika, ki zajema spektralne in prostorske značilnosti objekta pri različnih valovnih dolžinah.

Čeprav so modeli globokega učenja še vedno relativno novi in zahtevni za klasifikacijo HSI in kmetijstvo na splošno, so bili v zadnjem času doseženi številni uspehi na tem področju. Na primer, Zheng et al. [3] so izvedli laboratorijski eksperiment za odkrivanje sušnega stresa na listih paprike. Podobno so Zhang et al. [4] izvedli študijo za klasifikacijo semen različnih vrst koruze, Garillos-Manliguez et al. [5] pa za oceno zrelosti papaje. Meng et al. [6] so zasnovali terensko raziskavo za razlikovanje med vrstami riža z uporabo HSI naprave na UAV platformi. V teh študijah so bili podatki pridobljeni v eni seji slikanja, brez časovne kvalifikacije vzorcev.

V tej študiji predlagamo novo metodo na osnovi HSI z uporabo globokega učenja za zaznavanje pomanjkanja vode pri krompirju. Slikanje dveh sort krompirja je bilo izvedeno v časovni seriji, da bi ocenili zmogljivost klasifikacije skozi več tednov in preizkusili sposobnost zgodnjega odkrivanja.

## 2 MATERIALI IN METODE

Eksperiment je bil izveden v rastlinjaku na Kmetijskem inštitutu Slovenije (Ljubljana, Slovenija), med aprilom in avgustom 2022. Eksperimentalni pogoji so bili skrbno nadzorovani: dnevna temperatura 21 °C, nočna temperatura 15 °C, relativna vlaga 60% in svetlobni cikel 14 ur. Gomolji krompirja (*Solanum tuberosum* L.) so bili posajeni v lonce s prostornino 5 litrov. Skupaj je bilo posajenih 28 rastlin sorte KIS Krka in 18 rastlin sorte KIS Savinja (Slika 1). Po približno 5 tednih rasti je bila polovica rastlin vsake sorte (14 oziroma 9 rastlin) naključno razdeljena v skupine suše (D) ali kontrolne skupine (C). Rastline so nato gojili še dodatnih 5 tednov. V skupini D so bile rastline izpostavljene režimu namakanja z omejeno vodo. Za spremljanje vlažnosti v substratu (zemlji) so bili uporabljeni tenziometri (Jett Fill tenziometri, Eijkelkamp, Giesbeek, Nizozemska). Med trajanjem eksperimenta je bilo matični potencial tal skrbno vzdrževan v območju od -0,01 MPa do -0,025 MPa za dobro zalite rastline in od -0,05 MPa do -0,07 MPa za rastline s pomanjkanjem vode. Točne vrednosti so bile preverjene enkrat na dan, da so ostale znotraj predpisanih mej.

Predobdelava slik je vključevala šest korakov: (1) kalibracija slik na radiometrične enote svetlosti ( $W\ sr^{-1}m^{-2}$ ) s pomočjo opreme proizvajalca Hypspec; (2) pretvorba slik v reflektanco z uporabo referenčnega panela; (3) ko-registracija VNIR in SWIR slik za ustvarjanje enotne reflektančne slike; (4) segmentacija slik - izolacija pikslov listne površine, ozadje nastavljeno na nič; (5) izrezovanje slik v manjše slike velikosti 64x64

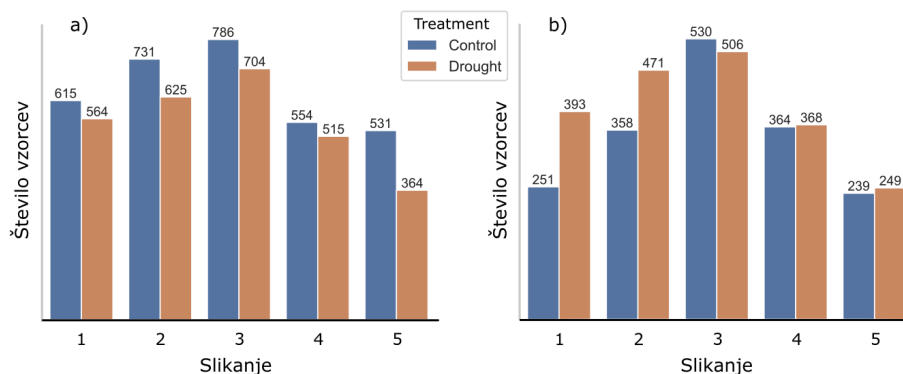
pikslov (v nadaljevanju vzorci), podobno kot v [6] in [7]; (6) Odstranitev prvih in zadnjih petih spektralnih kanalov tako VNIR kot SWIR (ostane 428 pasov).



Slika 1: Rastline obeh sort na koncu eksperimenta. KIS Krka a) kontrola, b) izpostavljene strsu; KIS Savinja c) kontrola, d) izpostavljene stresu.

V tej študiji so enakomerno razporejeni rezi originalnih hiperspektralnih slik uporabljeni za generiranje vzorcev. Skupno je bilo ustvarjenih 9718 vzorcev (Slika 2). Med njimi je bilo 5989 vzorcev iz sorte KIS Krka: 3217 iz dobro zalitih in 2772 s pomanjkanjem vode. Preostalih 3729 vzorcev je bilo iz sorte KIS Savinja: 1742 iz dobro zalitih in 1987 s pomanjkanjem vode. Slika 3 prikazuje porazdelitev vzorcev na posamezno slikanje.

30



Slika 2: Število vzorcev glede na tretma (kontrola, pomanjkanje vode) za a) KIS Krka and b) KIS Savinja.

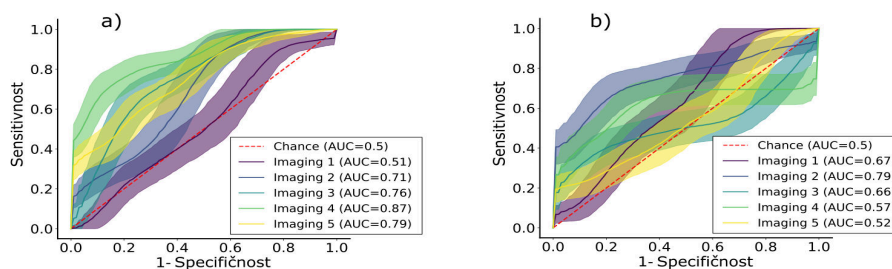
Razvili smo konvolucijsko nevronske mrežo z mehanizmom pozornosti za identifikacijo rastlin s pomanjkanjem vode. Model sestavlja pet delov: (1) mreža sprejme vzorec; (2) vzorec je obdelan skozi plasti pozornosti na pasove, kjer so izluščene pomembnostne vrednosti vsakega spektralnega pasu; (3) s pomnožitvijo originalnega vhodnega

vzorca s temi pomembnostnimi vrednostmi se proizvede prilagojen vzorec; (4) ta se poda v ostanek mreže, ki ga pretvori skozi več blokov v kompleksne latentne značilke, na podlagi katerih je napovedana vrednost; (5) uporablja se sigmoidna aktivacijska funkcija za omejitve izračunane napovedane vrednosti na območje [0,1]. Tako je izhod modela kontinuirana ocena, to je verjetnost, da je rastlina izpostavljena pomanjkanju vode.

### 3 REZULTATI IN RAZPRAVA

Opredelili smo uspešnost predlagane globoke nevronske mreže. Klasifikacijske metrike so prikazane ločeno za vsako sorto v Preglednicah 1 in 2. Vizualna predstavitev ROC krivulj je prikazana na Sliki 3. Najboljše rezultate smo dosegli za KIS Krka, z AUC-ROC vrednostjo 0,74, medtem ko je KIS Savinja dosegla AUC-ROC 0,64. Za KIS Krka je bil model manj uspešen v prvem slikanju. V preostalih slikanjih je dosegel AUC-ROC vrednosti med 0,71 (slikanje 2) in 0,87 (slikanje 4). F1 ocene so bile na splošno nižje, z razponom med 0,54 (slikanje 1) in 0,78 (slikanje 4), medtem ko sta natančnost in priklic približno sledila F1 ocenam. Dodatno razlik med natančnostjo in priklicem ni bilo, kar kaže, da model ni bil preveč prilagojen podatkom. Skupni rezultati so bili slabši za KIS Savinja, z najvišjo AUC-ROC oceno 0,79 (slikanje 2). Najslabšo klasifikacijsko uspešnost smo dosegli za slikanje 5. Model je bil sposoben razvrščati vzorce prvega slikanja s AUC-ROC vrednostjo 0,67.

31



Slika 3: ROC krivulje za a) KIS Krka and b) KIS Savinja.


Preglednica 1: Rezultati klasifikacije za KIS Krka.

Slikanje	AUC-ROC	F1	Natančnost	Priklic
1	0.51 (0.40, 0.62)	0.54 (0.45, 0.63)	0.54 (0.45, 0.63)	0.54 (0.44, 0.63)
2	0.71 (0.59, 0.79)	0.68 (0.59, 0.76)	0.71 (0.62, 0.78)	0.69 (0.59, 0.76)
3	0.76 (0.66, 0.84)	0.65 (0.56, 0.74)	0.69 (0.59, 0.76)	0.66 (0.58, 0.74)
4	0.87 (0.80, 0.92)	0.78 (0.69, 0.84)	0.78 (0.69, 0.84)	0.78 (0.68, 0.84)
5	0.79 (0.70, 0.86)	0.70 (0.60, 0.77)	0.70 (0.60, 0.77)	0.70 (0.59, 0.77)
Združeno	0.74 (0.70, 0.78)	0.67 (0.64, 0.71)	0.68 (0.64, 0.71)	0.67 (0.64, 0.71)

Preglednica 2: Klasifikacijski podatki za KIS Savinja.

Slikanje	AUC-ROC	F1	Natančnost	Priklic
1	0.67 (0.51, 0.78)	0.62 (0.47, 0.72)	0.62 (0.48, 0.72)	0.62 (0.47, 0.72)
2	0.79 (0.65, 0.89)	0.76 (0.63, 0.86)	0.80 (0.67, 0.87)	0.77 (0.63, 0.85)
3	0.66 (0.51, 0.80)	0.65 (0.53, 0.77)	0.65 (0.51, 0.76)	0.65 (0.52, 0.75)
4	0.57 (0.40, 0.72)	0.60 (0.44, 0.72)	0.71 (0.54, 0.80)	0.63 (0.50, 0.73)
5	0.52 (0.36, 0.66)	0.49 (0.35, 0.62)	0.50 (0.33, 0.62)	0.50 (0.35, 0.60)
Združeno	0.64 (0.56, 0.69)	0.63 (0.56, 0.68)	0.64 (0.58, 0.69)	0.63 (0.57, 0.68)

Spectralne kanale smo razporedili glede na njihovo pomembnost (Slika 4), da bi ugotovili, kateri deli spektra valovnih dolžin zagotavljajo največ informacije pri napovedovanju. Nekateri deli spektra bolj izraziti kot drugi. Na primer, najbolj izrazite valovne dolžine v VNIR delu so bile med 475 in 580 nm, 660 in 730 nm ter 940 in 970 nm; v SWIR pa med 1420 in 1510 nm, 1875 in 2040 nm ter 2350 in 2480 nm. Relavantni spektralni pasovi primerljivi za obe sorti, zlasti v VNIR delu spektra. Vendar pa so bile nekatere manjše razlike v celotnem SWIR delu spektra, zlasti v območjih med 1100 in 1500 nm, 1900 in 2050 nm ter 2350 in 2430 nm.



Slika 4: Relavantne valovne dolžine za a) KIS Krka in b) KIS Savinja.

32

Klasifikacija je bila bolj zanesljiva za sorto KIS Krka (AUC-ROC 0,74; F1 0,67) v primerjavi s sorto KIS Savinja (AUC-ROC 0,64; F1 0,63), kar bi lahko bilo posledica nezadostnega pogoja za pomanjkanje vode pri tej sorti ali pa manjšega razpoložljivega podatkovnega nabora. Najslabši rezultati klasifikacije za KIS Krka so bili doseženi pri slikanju 1, kar bi lahko bilo posledica nizkega vpliva stresa na rastlino krompirja ali pa pomanjkanja časa za vpliv stresa na spektralni odziv. Zanimivo je, da je bilo nasprotno res za KIS Savinja, kjer je bil najslabši rezultat dosežen pri slikanju 5. Eno možno pojasnilo za to je majhna velikost podatkovnega nabora, zaradi česar model ni imel dovolj podatkovne variabilnosti za ustrezno učenje. KIS Savinja je sorta občutljiva na sušo, zato je odziv lahko teoretično drugačen v primerjavi s KIS Krka [8].

Uporaba obeh hiperspektralnih kamer, ki zajemata VNIR in SWIR del spektra, je zagotovila dodatne informacije za zaznavanje pomanjkanja vode pri rastlinah krompirja. Rastline v suši preusmerjajo vire v liste z večjo fotosintetsko aktivnostjo, kar vpliva na proizvodnjo snovi in prevoz v tkivih rastline [9,10]. Suša povzroča

presnovne spremembe, ki vključujejo kopičenje prostih sladkorjev, esencialnih aminokislin za osmotsko ravnovesje, pa tudi povečano proizvodnjo obrambnih spojin, kot so proteazni inhibitorji in oksidativni encimi [11]. Spremembe so opredeljene s pomočjo ustreznih spektralnih območij, ki smo jih identificirali v naši študiji, saj so ta povezana s specifičnimi fiziološkimi spremenljivkami, značilnimi za stres suše pri številnih rastlinskih vrstah [12,13]. Še posebej so se kot koristna izkazala pasova, povezana z vsebnostjo vode v listih pri 970 nm in 1480 nm, kar je bilo že prej dokazano v raziskavi Eitel et al. [14]. Dodatno sta bila v VNIR delu spektra močno izpostavljena dva območja - zelena in rdeča -, kar kaže na spremembe v vsebnosti klorofila in pigmentov (482–773 nm) ter povezane spremembe z biomaso (759–770 nm) [3]. Pomembni spektralni pasovi v SWIR delu spektra so povezani z ligninom ali celulozo (2000 nm), proteini (2162–2173 nm) [15,16] ter povezani s celulozo, škrobom, amilozo in proteini (2325–2417 nm) [17,18].

#### 4 SKLEPI

Ugotovitve naše študije imajo pomembne implikacije za precizno kmetijstvo in programe za vzgojo krompirja. V kontekstu preciznega kmetijstva sposobnost natančnega spremljanja razpoložljivosti vode omogoča optimizacijo razporeditve virov in upravljanje namakanja z uporabo v raznovrstnih aplikacijah. To zagotavlja, da se voda dovaja točno tam in takrat, ko je potrebna, s čimer se maksimizira pridelovalni potencial. Poleg tega naši rezultati ponujajo neinvaziven način ocenjevanja vodnega stanja pridelkov, kar omogoča zmanjšanje potencialnih izgub. Za programe vzgoje krompirja naše ugotovitve predstavljajo potencialno orodje za pospeševanje izbire sort, odpornih na sušo. S pomočjo hiperspektralnega slikanja lahko vzgojitelji hitro pregledajo in identificirajo obetavne sorte, ki kažejo robustne odzive na različne vodne pogoje. To pospešuje proces vzgoje in omogoča razvoj sort krompirja, odpornih na sušo, ki so primerne za spreminjajoče se podnebne razmere. Sposobnost bolj celovitega in učinkovitega fenotipiziranja pridelkov izboljšuje natančnost in uspeh vzgojnih prizadevanj ter prispeva k ustvarjanju boljših sort, ki zagotavljajo prehransko varnost in trajnostne kmetijske prakse. Pridobljeni podatki bi lahko služili za nadaljnji razvoj aplikacij daljinskega zaznavanja, ki omogočajo ciljno upravljanje z vodo in oceno zdravja rastlin. To bi lahko preprečilo razvoj in širjenje talnih škodljivcev, ki se pojavljajo zaradi podnebnih sprememb in višjih povprečnih temperatur.

#### 5 LITERATURA

- Birch, P.R.J.; Bryan, G.; Fenton, B.; Gilroy, E.M.; Hein, I.; Jones, J.T.; Prashar, A.; Taylor, M.A.; Torrance, L.; Toth, I.K. Crops That Feed the World 8: Potato: Are the Trends of Increased Global Production Sustainable? *Food Sec.* **2012**, *4*, 477–508, doi:10.1007/s12571-012-0220-1.
- Devaux, A.; Goffart, J.-P.; Kromann, P.; Andrade-Piedra, J.; Polar, V.; Hareau, G. The Potato of the Future: Opportunities and Challenges in Sustainable Agri-Food Systems. *Potato Res.* **2021**, *64*, 681–720, doi:10.1007/s11540-021-09501-4.

- Zheng, Z.; Liu, Y.; He, M.; Chen, D.; Sun, L.; Zhu, F. Effective Band Selection of Hyperspectral Image by an Attention Mechanism-Based Convolutional Network. *RSC Adv.* **2022**, *12*, 8750–8759, doi:10.1039/D1RA07662K.
- Zhang, W.; Li, Z.; Sun, H.-H.; Zhang, Q.; Zhuang, P.; Li, C. SSTNet: Spatial, Spectral, and Texture Aware Attention Network Using Hyperspectral Image for Corn Variety Identification. *IEEE Geosci. Remote Sensing Lett.* **2022**, *19*, 1–5, doi:10.1109/LGRS.2022.3225215.
- Garillos-Manliguez, C.A.; Chiang, J.Y. Multimodal Deep Learning and Visible-Light and Hyperspectral Imaging for Fruit Maturity Estimation. *Sensors* **2021**, *21*, 1288, doi:10.3390/s21041288.
- Meng, Y.; Ma, Z.; Ji, Z.; Gao, R.; Su, Z. Fine Hyperspectral Classification of Rice Varieties Based on Attention Module 3D-2DCNN. *Computers and Electronics in Agriculture* **2022**, *203*, 107474, doi:10.1016/j.compag.2022.107474.
- Nagasubramanian, K.; Jones, S.; Singh, A.K.; Sarkar, S.; Singh, A.; Ganapathysubramanian, B. Plant Disease Identification Using Explainable 3D Deep Learning on Hyperspectral Images. *Plant Methods* **2019**, *15*, 98, doi:10.1186/s13007-019-0479-8.
- Fawcett, T. An Introduction to ROC Analysis. *Pattern Recognition Letters* **2006**, *27*, 861–874, doi:10.1016/j.patrec.2005.10.010.
- Monneveux, P.; Ramírez, D.A.; Pino, M.-T. Drought Tolerance in Potato (*S. Tuberosum* L.). *Plant Science* **2013**, *205–206*, 76–86, doi:10.1016/j.plantsci.2013.01.011.
- Deblonde, P.M.K.; Ledent, J.F. Effects of Moderate Drought Conditions on Green Leaf Number, Stem Height, Leaf Length and Tuber Yield of Potato Cultivars. *European Journal of Agronomy* **2001**, *14*, 31–41, doi:10.1016/S1161-0301(00)00081-2.
- Praprotnik, E.; Vončina, A.; Žigon, P.; Knapič, M.; Susič, N.; Širca, S.; Vodnik, D.; Lenarčič, D.; Lapajne, J.; Žibrat, U.; et al. Early Detection of Wireworm (Coleoptera: Elateridae) Infestation and Drought Stress in Maize Using Hyperspectral Imaging. *Agronomy* **2023**, *13*, 178, doi:10.3390/agronomy13010178.
- Zarco-Tejada, P.J.; González-Dugo, V.; Williams, L.E.; Suárez, L.; Berni, J.A.J.; Goldammer, D.; Fereres, E. A PRI-Based Water Stress Index Combining Structural and Chlorophyll Effects: Assessment Using Diurnal Narrow-Band Airborne Imagery and the CWSI Thermal Index. *Remote Sensing of Environment* **2013**, *138*, 38–50, doi:10.1016/j.rse.2013.07.024.
- Workman Jr., J.; Weyer, L. *Practical Guide and Spectral Atlas for Interpretive Near-Infrared Spectroscopy*; 0 ed.; CRC Press, 2012; ISBN 978-0-429-11051-1.
- Eitel, J.U.H.; Gessler, P.E.; Smith, A.M.S.; Robberecht, R. Suitability of Existing and Novel Spectral Indices to Remotely Detect Water Stress in *Populus* Spp. *Forest Ecology and Management* **2006**, *229*, 170–182, doi:10.1016/j.foreco.2006.03.027.
- Kokaly, R.F. Investigating a Physical Basis for Spectroscopic Estimates of Leaf Nitrogen Concentration. *Remote Sensing of Environment* **2001**, *75*, 153–161, doi:10.1016/S0034-4257(00)00163-2.
- Susič, N.; Žibrat, U.; Sinkovič, L.; Vončina, A.; Razinger, J.; Knapič, M.; Sedlar, A.; Širca, S.; Gerič Stare, B. From Genome to Field—Observation of the Multimodal Nematicidal and Plant Growth-Promoting Effects of *Bacillus Firmus* I-1582 on Tomatoes Using Hyperspectral Remote Sensing. *Plants* **2020**, *9*, 592, doi:10.3390/plants9050592.
- Thenkabail, P.S.; Mariotto, I.; Gumma, M.K.; Middleton, E.M.; Landis, D.R.; Huemmrich, K.F. Selection of Hyperspectral Narrowbands (HNBs) and Composition of Hyperspectral Twoband Vegetation Indices (HVIs) for Biophysical Characterization and Discrimination of Crop Types Using Field Reflectance and Hyperion/EO-1 Data. *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing* **2013**, *6*, 427–439, doi:10.1109/JSTARS.2013.2252601.
- Kokaly, R.F.; Skidmore, A.K. Plant Phenolics and Absorption Features in Vegetation Reflectance Spectra near 1.66 Mm. *International Journal of Applied Earth Observation and Geoinformation* **2015**, *43*, 55–83, doi:10.1016/j.jag.2015.01.010.