



## KÉPALKOTÁSI ELJÁRÁSOK A PRECÍZIÓS GAZDÁLKODÁSBAN

ZSEBŐ SÁNDOR<sup>1</sup> – MILICS GÁBOR<sup>2</sup> – KOVÁCS ATTILA<sup>1</sup>

<sup>1</sup>Széchenyi István Egyetem, Albert Kázmér Mosonmagyaróvári Kar, Mosonmagyaróvár

<sup>2</sup>Magyar Agrár- és Élettudományi Egyetem, Gödöllő

### ÖSSZEFOGLALÁS

A növénytermesztés sikerének egyik kulcsfontosságú lépése a megfelelő gyomszabályozás. Cikkünkben a precíziós gazdálkodás adta gyomdetektálási és osztályozási módszereket vesszük sorra, kiemelten foglalkozva a gyomok által visszavert elektromágneses hullámok detektálásával. Ismertetjük a különböző kultúrnövényekben végzett szabadföldi és mesterséges környezetben végrehajtott kísérleteket, valamint bemutatjuk azok eredményeit. Megmutatjuk az alkalmazott kiértékelési módszereket, azok hiányosságait és ismertetjük a mesterséges intelligenciával kapcsolatos eredményeket, amelyek a jövőben áttörést jelenthetnek a gyomok detektálása és osztályozása tekintetében. Az összeállításban bemutatjuk a precíziós gyomszabályozás aktuális helyzetét, jövőbeli kihívásait és megoldásait.

**Kulcsszavak:** precíziós (helyspecifikus) gyomszabályozás, detektálás, osztályozás, mesterséges intelligencia

### BEVEZETÉS

Napjainkban komoly aggályok merülnek fel a talajjal és a vízellátottsággal kapcsolatban, mivel ezen erőforrásokat többé már nem tekintjük kimeríthetetlennek (*Sun et al., 2017; Zhang et al., 2020*). A precíziós gazdálkodás éppen ezen erőforrások megőrzésében nyújthat segítséget, emellett alkalmazásával növelhetjük a terméshozamokat és csökkenteni tudjuk a vetésterületek változatosságát, valamint a

kijutatott inputanyagok mennyiségét (Yost *et al.*, 2017). Röviden kifejezve a precíziós gazdálkodás nem szól másról, mint a „megfelelő helyen, a megfelelő időben, a megfelelő termék előállítását” (Pivoto *et al.*, 2018).

Jelen cikkünk célja, hogy betekintést nyerjünk a precíziós gazdálkodás, azon belül pedig a gyomszabályozás aktuális helyzetébe, bemutassuk a rendelkezésre álló eszközöket, elvégzett kísérleteket, publikált eredményeket, valamint a gyomok detektálását és osztályozását hátráltató problémákat.

## **IRODALMI ÁTTEKINTÉS**

### **Precíziós gazdálkodás**

*De Clercq et al.* (2018) szerint a precíziós gazdálkodásra tekinthetünk úgy is, mint a mezőgazdaság 4.0 korszaka, amely ígérete szerint forradalmasítja a mezőgazdasági termelést a monitoring és intervenciós technológiák által. Célja a termelés hatékonyságának növelése és a környezeti hatások csökkentése. A precíziós gazdálkodás során használt informatikai technológiák (Information Technologies - IT) alkalmazásával különböző adatok gyűjthetők össze a táblákról, amelyek segítik a gazdákat, hogy könnyebben felismerhessék a termelési erőforrások térbeli és időbeli változásait (Aubert *et al.*, 2012). Paxton *et al.* (2011) szerint az IT-k hozzájárulnak a megfelelő döntéshozáshoz műszaki, gazdasági és környezetvédelmi szempontból is. A fejlett információfeldolgozási technológiáknak köszönhetően, olyan innovatív, a precíziós gazdálkodás alapjául szolgáló rendszerszemléletek segítik a gazdálkodók termelését, mint a különböző mennyiségű kijuttatási technológiák, a légi és műholdas távérzékelés, a multispektrális és hiperspektrális földközeli eszközök, számítógépes modellezések, globális helymeghatározó rendszerek (GPS), valamint a földrajzi információs rendszerek (GIS) (Waheed *et al.*, 2006). A számítógépes látási technikák (Computer vision technologies) digitális képeket használnak a világ észlelésére és megértésére, képesek pontos, helyspecifikus információkat szolgáltatni a növényekről és azok környezetéről. Alkalmazástól függően a számítógépes látórendszer (Computer vision system) különböző érzékelési módokat használ, mint például a színes vagy RGB (red, green, blue) képalkotást, amely vizuális szemrevételezés céljából szimulálja az emberi látást, míg a közeli infravörös (NIR), multispektrális vagy hiperspektrális képalkotást a nehezebben megfogható biológiai folyamatok érzékeléséhez, a távolságmérő érzékelőket pedig a

geometriai méréseknél veszi igénybe. A hiperspektrális képeken közvetlen értékelést végezhetünk a vizsgált anyagon, valamint a kiválasztott paraméter földrajzi eloszlását is megtudhatjuk (Lodhi et al., 2019). Több kutató is hiperspektrális képek segítségével vizsgálta a növények klorofill tartalmát, gombás betegségeit vagy éppen a szárazságtűrő képességüket (Yang et al., 2015; Bauriegel et al., 2014; Gerhards et al., 2019). Napjainkban a gépi látást széles körben használják a precíziós mezőgazdasági feladatoknál, mint például a növények monitorozása, valamint fenotípus vizsgálata, a gyomirtás, a betakarítás, a járművezetés és a hozamtérképezés (Bulanon et al., 2020; Mavridou et al., 2019; Patrício et al., 2018; Wang et al., 2019; Wang et al., 2022).

### **Helyspecifikus gyomszabályozás**

A növényvédelem egy viszonylag új alkalmazási iránya a helyspecifikus gyomszabályozás (Site Specific Weed Management - SSWM). A gyomok veszélyforrást jelenthetnek a környezetre, az emberi egészségre, a mezőgazdasági termelékenységre, környezetvédelmi szempontból pedig megzavarják az ökológiai társulások egyensúlyát és csökkentik a fajok sokszínűségét (Adkins et al., 2014; Gharde et al., 2018). A hagyományos kijuttatáshoz képest - ami a tábla teljes területén történik - a helyspecifikus gyomszabályozásnál csak a gyomokkal borított területre juttatunk ki növényvédő szert, mellyel jelentősen csökkentjük a herbicidek által okozott környezeti terhelést (Lottes et al., 2018). Haug et al. (2014) szerint a helyspecifikus növényvédelem sikere a gyomok és kultúrnövények pontos megkülönböztetésén alapul. A gyomnövények kimutatásában nagy segítséget jelenthet a pilóta nélküli légitűrmű (UAV-Unmanned Aerial Vehicle) alkalmazása, ahol két különböző megközelítés létezik. Egyik módszer a spektrális különbözőség, mivel a gyom- és kultúrnövény által visszavert elektromágneses hullámok spektrumai között különbségek mutathatók ki, amely már hosszú múltra tekint vissza a nem UAV távérzékelés tekintetében is (López-Granados, 2011). A másik eljárást a gyomnövények tenyészedőszakának kezdetén, röviddel a csírázás után használják. Ennél a megoldásnál nagy felbontású képekre van szükség, amelyekhez az UAV-k egyedülálló lehetőséget kínálnak. Az objektum alapú képelemzési (OBIA - Object-Based Image Analysis) módszerek felülműlják a hagyományos pixel-alapú módszereket. Az OBIA módszerben az elemzések nem egyedi pixeleken, hanem hasonló spektrális tulajdonságú objektumokon, szomszédos pixelcsoportokon történik. Jó eredmények érhetők el (módosított) RGB kamerákkal, mivel ezen eszközök térbeli felbontása meghaladja a

spektrális felbontást. A jelenlegi kutatások biztató eredményeket mutatnak a gyomok soron belüli kimutatásával kapcsolatban (*De Castro*, 2018), valamint a félig automatizált módszereknél is, ahol a gépi tanulási technológiákat (Machine learning technology) használják a gyomok-kultúrnövények kiszűrésére, amelyek jelentősen csökkentik a gyomok kézi osztályozásának időigényes munkáját a tanuló adatbázis elkészítése során (*Gao et al.*, 2018; *Khan et al.*, 2022). A precíziós gyomszabályozásban a hozamnövekedés tekintetében is nagy potenciál rejlik, azonban a rendszer legfőbb akadályát egy olyan gyomdetektáló algoritmus kifejlesztésével lehetne megszüntetni, amelyet komplex növénytermesztési környezetben is lehetne alkalmazni (*Olsen et al.*, 2019).

### **Elektromágneses hullámhossztartományok és az azokat mérő érzékelők**


A leggyakrabban használt felszínközeli valós idejű szenzorok a spektrometrikus, optoelektronikus és RGB-NIR képérzékelők. A spektrometrikus érzékelők több hullámhosszon mérik a visszaverődés intenzitását, ezáltal elegendő információt szolgáltatnak a vegetáció és a talajok megkülönböztetéséhez, ellenben ez a módszer a fajok differenciálásához már kevés, különösen a korai fejlődési stádiumban, amikor a kultúrnövényeknek és a gyomoknak nagyon hasonlóak a visszaverődési tulajdonságaik (*López-Granados*, 2011; *Peteinatos et al.*, 2014).

Számos esetben a VIS-NIR (Visible-Near Infrared) spektroszkópia segítségével különítik el a gyomnövényeket a kultúrnövényektől, azonban ezek a kutatások rendszerint laboratóriumi vizsgálatokra korlátozódnak, gyakran kemometriás módszerek segítségével választják ki a megfelelő hullámhosszokat, valamint állapítják meg a kalibrációs modelleket (*Che'Ya*, 2016; *Dammer et al.*, 2013; *de Castro et al.*, 2012).

Az elektromágneses spektrum kiemelt (gyomdetektálás szempontjából fontos) tartományai (*1. ábra*):

- Látható fénytartomány (VIS-Visible; 380–720 nm) (*2. ábra*): A látható hullámhossz 380-tól 720 nm-ig terjed. A zöld növények fő fotoszintetikus pigmentje - a klorofill - ami csak a látható fényt (380–500 nm) képes megkötni. Ezt a sugárzási tartományt nevezzük fotoszintetikusan aktív radiációnak (PAR) (*Turcsányi et al.*, 2005). Elsősorban az élő növényzetnél alacsony a visszaturkórozódás, ami 5-10%-nál kevesebb is lehet, viszont a zöld csúcsonál (green peak ~550 nm) a visszaverődés akár több mint kétszerese lehet a környező

hullámhosszokhoz viszonyítva. A növények levélpigmentjei fontos tényezők a megkülönböztethetőség szempontjából (*Fernandes et al., 2013*), annak ellenére is, hogy a látható fény hullámhosszai általában kevésbé összehasonlíthatók, mint a hosszabb hullámhosszok (*Asner, 1998; Ollinger, 2011*). A pigmentek közül a klorofill A és B befolyásolja legnagyobb mértékben az abszorpciót. A legtöbb osztályozás a látható fénytartományban történik, ebből is a vizsgálatok során csak bizonyos sávokat választanak ki. A látható fénytartomány három nagy sávra osztható fel, amelyek azt szinte teljesen lefedik: a kék / kék-zöld szélé (400–499 nm), a zöld csúcspontja 550 nm körül, és a vörös minimum (650–700 nm) (*Thenkabail et al., 1999*).




1. ábra: Egyedi levél fénymegkötése a klorofill a, klorofill b és karotinoidok tekintetében (*Anda et al., 2010*)

*Figure 1: Individual leaf light fixation with respect to chlorophyll a, chlorophyll b and carotenoids (Anda et al., 2010)*

- Közeli infravörös (NIR–Near Infrared; 680–1327 nm) (2. ábra): Vannak szerzők, akik a NIR tartományt úgy definiálják, hogy az a vörös részen belüli hullámhosszakat (680–780 nm) is tartalmazza (*Jonas et al., 2010*), azonban a legtöbb szerző a vörös vállon, vagy vörös élen túli tartományt tekinti csak annak (*Cortés et al., 2019; Chen et al., 2020*). Ezek alapján a NIR a 780–1327 nm közé tehető. A nagy visszaverődés oka a levélszerkezeten belül található fotonok

szétszóródása, mivel a folyékony vízből a levegőbe kerülés során törésmutató változás történik a sejtközötti terekben (Kniplin, 1970). Az abszorpció mértéke a levélvastagságtól függően változhat (Clark, 2005). Magas szintű intraspecifikus (fajon belüli) variabilitást állapítottak meg a NIR-ben és összefüggéseket találtak a levelek életkorával, valamint a víz és a klorofill koncentrációjával kapcsolatban (Dat, 2000).



2. ábra: Különböző anyagok visszaverődési spektrumai az elektromágneses hullámok függvényében (Ashraf et al., 2011)

Figure 2: Reflectance spectrum of different materials (Ashraf et al., 2011)

Ezen tulajdonságok figyelembevételével alkották meg az optoelektronikus szenzorokat is, bár ezek kevés spektrális sávban mérik a visszaverődés erősségét, rendszerint egyben vagy kettőben a vörös/közeli infravörös (R/NIR) régióban. Az eszközök nagyon gyorsan, eredményesen és költséghatékonyan különböztetik meg a vegetációt a háttértől (talajtól). A WeedSeeker®, GreenSeeker® (Trimble Agriculture, Sunnyvale, CA, USA) és WEED-it (Romotron, CJ Steenderen, Hollandia) nagyon népszerű növényérzékelő eszközök a piacon (Peteinatos et al., 2014; Tremblay et al., 2009).

**ANYAG ÉS MÓDSZER**

A kutatók számos érzékelési módszert vizsgáltak, mint a gépi látás (machine vision) (García-Santillán et al., 2018, Li et al., 2022), látható és közeli infravörös (VIS-NIR) spektroszkópia (Shapira et al., 2013; Zwiggelaar, 1998), multi-/hiper-spektrális képek (Huang et al., 2016), fluoreszcencia (Longchamps et al., 2009) és távolság érzékelő technikák (fény-, távolság-LiDAR [Light Detection and Ranging] és ultrahang érzékelés) (Andújar et al., 2013; Reiser et al., 2017). Ezeket a módszereket kétféle módon kategorizálhatjuk: légi távérzékelés és földi(közeli) technikák (Lin, 2009).

A légi távérzékelés eszközei közé tartoznak a különböző műholdak, léggömbök, repülőgépek és a pilóta nélküli légi járművek (UAV). Ezen eszközök felhasználási területe rendkívül széles, de ha csak az utóbbi éveket vesszük figyelembe, akkor a pilóta nélküli légi járművek vagy másnéven drónok térhódítása és azok alkalmazása robbanásszerű növekedést ért el (Padró et al., 2019; Li et al., 2020; Kumar et al., 2022). Megjelenésükkel új fejezetet nyitottak a távérzékelésben, mivel példátlan mértékű térbeli, spektrális és időbeli felbontású adatokat szolgáltatnak (Colomina et al., 2014). További előnyük, hogy nagyon rugalmasak, könnyen kezelhetőek és igény szerint történhet az adatgyűjtés. Emiatt az UAV-re tekinthetünk úgy is, mint egy új technikai eszköz, amellyel gyorsan és taposásmentesen nyerhetjük ki a szántóföldi növények fenotípus információit (Liu et al., 2016). A drónok használatával lehetőségünk nyílik területi térképek felfrissítésére vagy készítésére, 3D-s modellek előállítására. Létrehozhatjuk a talaj, a növények és az öntözés monitoring rendszerét, vegetációs indexeket számolhatunk ki, előrejelezhetjük a várható terméshozamot, kimutathatjuk az eróziós, száraz vagy extrudált részeket, valamint nyomon követhetjük a termékek minőségét a betakarítás során. Térképkészítésnél az összes objektum pontos koordinátájának segítségével lehetőségünk nyílik vizuális elemzések elkészítésére legfeljebb néhány pixel pontosságig (Mogili et al., 2018). Azonban érdemes megjegyezni, hogy ezek az eszközök csak „hordozók”, az adatok minősége és mennyisége a rajtuk lévő szenzoroktól vagy kameráktól függ.

A földi(közeli) technikai eszközök is csak egy „hordozók”. A mérések általában földhöz közeli vagy fixen telepített állomásokra felszerelt érzékelők segítségével valósulnak meg. Andújar et al. (2013) egy quadra szerelt LIDAR szenzorral végeztek földközeli érzékelést, míg Ranjan et al., (2019) bab földön növényi stresszt vizsgáltak, valamint

hozambecslést végeztek ugyanezzel a technológiával. A távérzékelési technikák kiválóan alkalmazhatók térképkészítés vagy nagy területek vizsgálatánál, hátrányuk viszont, hogy nem használhatók valós idejű folyamatoknál, valamint a képek térbeli felbontása is alacsonyabb, mint a földközeli technikáké (López-Granados, 2011).


### **RGB érzékelők**

A gyomdetektálás során számtalan módszert és eszközt alkalmaznak a kutatók. A legelterjedtebb mind közül az RGB kamera, amely a többi készülékhez képest olcsóbb és bárhol könnyen elérhető (Gao *et al.*, 2018). További előnye, hogy nagy a képek felbontása és gyors a detektálás sebessége, amelyek mind elengedhetetlenek a precíziós gazdálkodás eszközeinek használata során. Ezen felül az elkészített képeket könnyen be lehet tölteni a gépi tanulási algoritmusokba és fel lehet használni az olyan számítógépes látási megoldásoknál, mint az osztályozás vagy a tárgyfelismerés. Hátránya viszont, hogy igen érzékeny a terepi fényviszonyváltozásokra, amelyek a képek szegmentálásánál és az objektumok felismerésénél lenne fontos. A probléma megoldására egy mesterséges világítással ellátott zárt képalkotó teret kell kialakítani (Giselsson *et al.*, 2017).

Meng *et al.* (2015) HSI (Hue Saturation Intensity) színmodellt alkalmazott a változó fényviszonyok színes képekre gyakorolt hatásának csökkentésére és szürkeárnyalatos képet állított elő H komponensekkel. A kísérlet során szétválasztotta a színes és a monokromatikus (egyszínű) komponenseket, ezáltal lehetősége nyílt a fekete-fehér képekre alkalmazott algoritmusok használatára.

Guerrero *et al.* (2017) három különböző fejlődésű stádiumban lévő kukoricában végeztek állomány- és gyomdetektálást (3. ábra). A kutatásaikat két fő részre lehet osztani. Először a vetési sorok felismerését végezték a kiváló minőségű képek szegmentálása alapján, ahol a növények fehér képpontként jelentek meg, a fennmaradó rész pedig feketeként. Ezt követően a vetési sorok alapján számították ki a gyomsűrűséget és végezték a traktor irányítását.





3. ábra: (a) Eredeti RGB kép, (b) COM index az (a)-ból, (c) Bináris kép Otsu módszere után (Guerrero et al., 2017)

Figure 3: (a) Original image; (b) COM index from (a); (c) Binary image after Otsu thresholding (Guerrero et al., 2017)

### Multispektrális érzékelők


Az RGB kamerákkal összevetve a multispektrális képkészítő eszközök nem korlátozódnak csak a látható fénytartományra, hanem az ultraibolya, a közeli infravörös és az infravörös spektrumokban is használhatók, attól függően, hogy milyen tartományt tudnak mérni a szenzorok (Bi et al., 2019). A hiperspektrális érzékelőkkel ellentétben, a képalkotó szenzorok által készített képek (RGB képek, multispektrális képek - MSI) nagy térbeli felbontással rendelkeznek, ellenben kisszámú spektrális sávot tartalmaznak (Goshtasby et al., 2007).

Matese et al. (2013) egy szőlőültetvényt térképeztek fel és multispektrális kamera képeiből számolták az NDVI indexet. Shendryk et al. (2020) Ausztrália nedves trópusi régiójában két cukornád ültetvényen végeztek kísérletet, ahol multispektrális képek és LiDAR segítségével próbálták meghatározni a biomassza és a levelek nitrogéntartalmának mennyiségét.

### Hiperspektrális érzékelők

A hiperspektrális képalkotás egy olyan technika, ahol a fény széles spektrumát képpontonként (pixelenként) mérjük és ezáltal kapjuk az elemzésekhez szükséges információkat (Moshou et al., 2005). A hiperspektrális képérzékelők több tucat vagy akár több száz spektrális sávot is képesek összegyűjteni a spektrumok széles tartományából. Az anyagoknak különböző hullámhosszokon eltérő reflektanciájuk van, ezért a hiperspektrális képeknél (HSI) képesek vagyunk pontosan meghatározni az anyagokhoz

tartozó széles spektrumtartományú egyedi spektrumokat. Ily módon a hiperspektrális képalkotás széleskörűen alkalmazható a távérzékelési feladatok során (*Bioucas-Dias et al., 2013*). Azonban meg van ennek a hátránya is, mivel a hiperspektrális képek általában sok sávval rendelkeznek, ellenben alacsony a térbeli felbontásuk. A hiperspektrális képek térbeli felbontásának javítására egy hatékony és gazdaság megoldás a képfúzió (4. ábra). Egyre több érzékelő képes egyszerre begyűjteni a HSI-t és a nagy felbontású MSI-t ugyanarról a helyről, ezáltal a nagy spektrális és a nagy térbeli felbontás is elérhető, amelyet HSI-MSI fúzióknak (Fused HSI) neveznek (*Goshtasby et al., 2007*). A hibák elkerülése végett, azonban mindig érdemes vizuális ellenőrzést tartani, mivel a képek egyesítése során előfordulhat, hogy a szimulált adatfúzió és a valós fúzió nem pontosan egyezik egymással (*Dian et al., 2020*).



4. ábra: HSI (Hiperspektrális képek) és MSI (multispektrális képek) fúziójának illusztrációja (*Dian et al., 2020*)

Figure 4: The illustration of the HSI (Hyperspectral image) and MSI (Multispectral image) fusion (*Dian et al., 2020*)

*Waheed et al. (2006)* szerint a hiperspektrális távérzékelési adatok sokrétűbb információkat szolgáltatnak a mezőgazdasági termelésnél. A hiperspektrális képfeldolgozás felhasználható mindenfajta új és hatékony mezőgazdasági célra (*Teke et al., 2013*), mint például a levélben történő nitrogénfelhalmozódás (*Wei et al., 2008*), nitrogénhiány, valamint az invazív gyomfajok megállapítására (*Goel et al., 2003*), levélterület index (LAI) számításra (*Liu et al., 2016*), és növényi betegségek kimutatására (*Zhang et al., 2003*). *Moshou et al. (2005)* vizsgálataik során megállapították, hogy a

hiperspektrális és multispektrális képekből az előtt lehet azonosítani egy betegséget, hogy annak látható tünetei lennének, és ez alapján 94,5%-os pontossággal meg lehet különböztetni őket az egészséges növényektől.

### **Hőérzékelők**

A hőképképzés egy non-destruktív technika a hőmérséklet vizsgálatára az objektum által kibocsátott infravörös sugárzás alapján. A hőtérképek értékelésével adatokat tudhatunk meg a dimenzióról, a hőeloszlásról, valamint a struktúráról. A hőkamerák jellemzően alacsony felbontású kamerák (maximális felbontása 640×512 pixel vagy 0,33 MP), és csak egy sávot képesek mérni a mikrobolométer szenzorokkal a hosszú hullámú infravörös régióban. Ezekkel az eszközökkel a levélzet hőmérsékletét is lehet mérni (*Ali et al., 2020*). *Mangus et al. (2016)* szerint számos kutatás bizonyította, hogy a termikus infravörös hullámhossz sokkal érzékenyebb a vízstresszre, mint más hullámhossz régiók (látható és infravörös tartomány). Érdekes módon külön-külön a hiperspektrális, valamint a hőadatok kiegészítő információkat szolgáltatnak a fertőzések állapotáról és stádiumáról, ezek kombinálásával viszont sokkal összetettebb képet kaphatunk a növényi kórokozók állapotának és stádiumának vizsgálatánál (*Mahlein, 2016*). *López-López et al. (2016)* megállapították, hogy a betegségek korai stádiumban történő felderítésére során a termikus indexek ugyanolyan erősnek bizonyultak, mint a hiperspektrális indexek. Egy táblázatban összefoglalva (*1. táblázat*) tekinthetjük meg a különböző szenzorok felhasználási területeit.

*I. táblázat: Különböző szenzorok és azok alkalmazási területeik (Maes et al., 2019)*


*Table 1: Overview of Applications and Suitability of Different Sensors (Maes et al., 2019)*

Alkalmazás		Szenzorok/kamera típusai			
		RGB	Multispektrális	Hiperspektrális	Hő
Szárasság stressz	Detektálás korai stádiumban	-	-	A <sup>a</sup>	NA
	Hosszútávú következmények	-	NA	NA	A
Kórokozók kimutatása	Detektálás korai stádiumban	-	-	NA	NA
	Fertőzés súlyossága	NA	NA	NA	A
Gyom detektálás	Spektrális különbség	-	A	NA	-
	Objektum alapú	NA	NA	-	-
Tápanyag		A	NA	NA	A
Növekedési erély	Növekedési stádium	NA	-	-	-
	Levélmennyiség és biomassza	NA	NA	-	-
	Megdőlés	NA	-	-	A
Hozam		A	NA	-	-

NA – nagyon alkalmas; A – alkalmas; a, – A hiperspektrális adatokból ki kell számítani a nap okozta fluoreszcenciát

## Mesterséges intelligencia

Leegyszerűsített megközelítés szerint a mesterséges intelligencia nem más, mint létrehozunk egy számítógépet, egy robotot vagy bármilyen eszközt, amely az emberi gondolkodás mintájára megoldja a problémákat (Sukhadia et al., 2020; Kundalia et al., 2020). A mesterséges intelligencia fő alkalmazási területe a gépi tanulás (Machine learning), ahol a fejlődés gyors és jelentős (Kakkad et al., 2019; Sakthipriya et al., 2022). A gépi tanulás a döntéshozás során algoritmusokat alakít ki, így oldja meg az emberek számára túl komplex problémákat (Panchiwala et al., 2020; Talaviya et al., 2020). A gépi tanulás egyik iránya az úgynevezett mély tanulás (Deep learning), amely rengeteg időt és energiát spórol meg a programozóknak azáltal, hogy a feladatokat nem kell specifikálni vagy optimalizálni (Jha et al., 2019; Ahir et al., 2020). A mély tanulás ezzel forradalmasította a mesterséges intelligencia világát (5. ábra). A mesterséges neurális hálózatok (ANN - Artificial Neural Networks) nagyon rugalmasak a három réteggel - bemeneti réteg, többi réteg és a kimeneti réteg -, amelyek a mély tanuló neurális hálózatokat (deep learning neural network) is alkotják. A mesterséges neurális hálózatokat az agyi idegrendszer mintájára építették fel és az információfeldolgozás is ehhez hasonlóan történik (Sladojevic et al., 2016; Pandya et al., 2020).



5. ábra: Folyamatábra a neurális hálózatokról. Az egyszerű neurális hálózatoknál nem épül ki összeköttetés a többi réteg között, míg a mély tanuló neurális hálózatoknál kapcsolatban állnak egymással (Yanga et al., 2019)


Figure 5: Flow diagram of neural networks. In simple neural networks, no connection is established between the other layers, while in deep learning neural networks they are connected to each other (Yanga et al., 2019)

### Mesterséges intelligencia a mezőgazdaságban

A mesterséges intelligencia mezőgazdaságban történő alkalmazása megoldásokat szolgáltat az olyan fontos kérdésekre - csak néhányat említve -, mint a kártevők és betegségek megjelenése, a vegyszerek nem megfelelő alkalmazása, a helytelen vízelvezetés és öntözés, gyomirtás, valamint a hozambecslés (Bannerjee et al., 2018).

A gépi (mesterséges) látástechnikával történő képalkotás nagyon ígéretes eszköznek tűnik a precíziós gazdálkodás során, sok vizsgálat folyik ezzel kapcsolatban (Taghadomi-Saberi, 2015; Wang et al., 2022; McCarthy et al., 2022). A mesterséges intelligenciát a gépi látásnál is használják és közös cél minden számítógépes látás alapú (computer vision-based) precíziós mezőgazdasági feladatban, hogy azonosítani tudjuk a kívánt objektumot (pl. mag vagy gyom), valamint meg tudjuk különböztetni a környezetétől. A mesterséges intelligencia bevezetése segíthet felgyorsítani ezen folyamatokat, mivel különböző modellek bevezetésére és tanítására (6. ábra) kerül sor (Lobet, 2017). A Konvolúciós Neurális Hálózatok (CNN - Convolutional Neural Network) automatikusan kinyerik a szükséges tulajdonságokat, mielőtt elkezdenék osztályozási és detektálási feladatukat (Asad et al., 2019). Olsen et al. (2019) a mély tanulós struktúrát

alkalmazták, mely során 16 különböző gyomnövény képeit osztályozták sikeresen. *Asad et al.* (2019) repcében végezték kutatásukat ugyanezzel az eljárással. A mély tanulási technikák megjelenésével a gyomtulajdonságok kinyerésének lépése, valamint az osztályozási lépés egybeolvad.



6. ábra: Folyamatábra a javasolt gyomdetektálási módszertanhoz (*Asad et al.*, 2019)

Figure 6: Flow diagram for proposed weed detection methodology (*Asad et al.*, 2019)

## EREDMÉNYEK

### Adatbázisok

A precíziós gazdálkodás legkisebb és legfontosabb építőelemei az adatok. Az adatok begyűjtéséből építhetjük fel a szükséges adatbázisokat, amelyekre tekinthetünk úgy is, mint a gazdálkodók döntéstámogatói rendszere. Azonban nem elég, hogy begyűjtjük a szükséges adatbázisokat, azokat használni is kell. Ha még gyorsabb fejlődést szeretnénk elérni, akkor kölcsönös adatmegosztást kellene kialakítani egymás között, de a gazdálkodók jelenleg erre még nem gondolnak. Pedig számos előnnyel járna. Az adatkészletek nyilvánosan hozzáférhetővé tételével jelentős erőforrásokat spórolhatunk meg az adatok előkészítésénél, és ezzel lehetővé tesszük a képi elemzések, valamint a gépi tanulási algoritmusok fejlesztését a különböző kutatócsoportok számára (*Lobet*, 2017). A számítógépes látással foglalkozók már használnak olyan képi adatbázisokat,

mint a COCO vagy a PASCAL VOC, amely figyelemreméltó sikereket ér el az objektumok detektálási, szegmentálási feladatainál, valamint a modellek kiépítésében. Azonban ezeknek az adathalmazoknak a képei az internetről származnak, illetve természeti képeket vagy tárgyakat ábrázolnak, amelyeket nem lehet integrálni a precíziós gazdálkodásba. Ellenben vannak olyan növényeket tartalmazó képi adatbázisok, mint a Leafsnap (*Redmon et al., 2018*), vagy a PlantVillage (*Mohanty et al., 2016*) ahol a gyűjtés elsősorban botanikai taxonómiaira vagy növényi fenológiára irányul és ezeket a képeket laboratóriumi körülmények között gyűjtik össze. A számítógépes látású precíziós gazdálkodás sokkal speciálisabb adatbázist kíván meg az olyan feladatoknál, mint a robotirányítás vagy a növényvizsgálat, különös tekintettel a terepi körülmények között történő adatgyűjtés során, mint például a növények fejlődési stádiuma, a talajfelszín jellemzői és a változó fényviszonyok (*Sun et al., 2017*). A kutatók már sikeresen kialakították az ehhez kapcsolódó különböző adatbázisokat, mint például a CWFI-t vagy a gyomtérkép adatbázist.

#### *CWFI (crop/weed field image) adatbázis*

*Haug et al., (2015)* az elsők között publikálták a gyomszabályozásra szánt terepi adatbázisukat. Egy Bonirob (*Ruchelshausen et al., 2009*) autonóm terepi robotra szerelt multispektrális kamerával gyűjtöttek képeket egy répafieldön. A kamerát beárnyékolták és mesterséges megvilágítást alkalmaztak, hogy kiküszöböljék a változó fényviszonyokat, valamint csak a fényképezőgép vörös (R) és a NIR csatornáit használták fel a képalkotáshoz (de az adatbázisban lévő képek 3 csatornás R-NIR-R formátumban mentődtek). Az adatbázist összesen 60 nyers kép alkotta, amelyeken vegetációs átfedések is láthatók és pixel szinten meghatározható a gyom, a növény és háttérben a talaj. Annak ellenére, hogy ez az adatkészlet viszonylag kicsinek mondható, mégis felhasználható a gyomokon végzett gépi tanulás modellek értékeléséhez (*McCool et al., 2017; Fawakherji et al., 2019*).

#### *Gyomtérkép adatbázis*

A Gyomtérkép adatbázis (Weed Map Dataset) (*Sa et al., 2018*) és a weedNet adatbázis (*Sa et al., 2017*) létrehozása is egy kutatócsoport nevéhez köthető. Feltehetőleg ez a legnagyobb nyilvánosan elérhető multispektrális légi adatbázis a cukorrépa gyomjainak szegmentálása és térképezése tekintetében. Két drónt, egy négy (550 nm, 660 nm, 735

nm, 790 nm) és egy ötcsatornás (475 nm, 560 nm, 668 nm, 717 nm, 840 nm) multispektrális kamerával szereltek fel, a repülés pedig 10 méteren történt a cukorrépatábla felett. A repülés magába foglal nyolc nagy felbontású ortomozaikos képet, pixel szintű gyom-, növény- és háttér-azonosítást. Ez az adatbázis egy új mércét jelenthet a nagy felbontású ortomozaikos gyomtérképek gépi tanulás algoritmusának kialakításához, mivel rengeteg kép áll rendelkezésre a detektálási és tanulási folyamathoz.

### **Képek feldolgozása**

A képfeldolgozás sikerességét döntően befolyásolja a gyomok sűrűsége és a rájuk jellemző tulajdonságok, a változó fényviszonyok az adott területen, a kultúrnövények és gyomnövények leveleinek átfedése, a növények különböző növekedési szakaszai stb. (Lin, 2009; López-Granados, 2011; Romeo *et al.*, 2013). A megfelelő képfeldolgozási módszerekkel azonban kiszűrhetőek a kedvezőtlen környezeti tényezők. A talajokat és egyéb nem zöld színű jellemzőket csökkenteni tudjuk kameraszűrőkkel és különböző típusú kamerákkal (Astrand *et al.*, 2005).

A hiperspektrális képosztályozási problémák megoldására számos osztályozási módszerrel próbálkoznak a kutatók, mint a tartóvektor gép (support vector machine - SVM) (Melgani *et al.*, 2004), K-legközelebbi szomszéd (K-nearest neighbour method) (Blanzieri *et al.*, 2008), döntési fa (decision tree) (Delalieux *et al.*, 2012), extrém tanuló gép (extreme learning machine - ELM) (Su *et al.*, 2017) és még sok más (Vijayalakshmi *et al.*, 2020). Golhani *et al.* (2018) kutatásukban neurális hálózati technikákat használtak a hiperspektrális adatok feldolgozásához, különleges hangsúlyt fektetve a növénybetegségek kimutatására.

### **Indexek**

A képek feldolgozása, osztályozása a legtöbb esetben valamilyen indexszám alapján történik, hogy könnyebben lehessen dolgozni a rendelkezésre álló adatokkal. Az indexszámok elemzésénél kiemelkedő jelentősége van az összehasonlíthatóságnak. Az azonos jellegű, azonos mértékegységű adatoknál ez egyszerű módon megoldható, például viszonyszámokkal. Gyakran azonban szükség van a közvetlenül nem összesíthető adatokra vonatkozó átlagos változás meghatározására (Havasy *et al.*, 1996). Ezeket a módszereket a precíziós gazdálkodásnál is alkalmazzák.



1969-ben az első vegetációs index megalkotását követően napjainkban már jóval több, mint 100 található belőlük (*Jinru et al.*, 2017). A vegetációs indexeket a képek szegmentálásánál használják, amikor detektálni szeretnék a mezőgazdasági táblákon található gyomokat (*Montalvo et al.*, 2012). A nyers RGB csatornákat és a kinyert vegetációs indexeket elsősorban a növényzet háttértől való kiszűrésére használják (*Kazmi et al.*, 2015). A vegetációs indexek segítségével az élő növények könnyen elkülöníthetőek az elhalt, élettelen dolgoktól, így azokat már nem veszik figyelembe a képfeldolgozás során, ezáltal szűrni tudják a vizsgálandó adatmennyiséget (*Jinru et al.*, 2017). Az összes vegetációs index közül az NDVI-t használják a legszélesebb körben. Az NDVI vegetációs index egy dimenziómentes mérőszám, amely egy adott terület vegetációs aktivitását fejezi ki. Értékét a növényzet által a közeli infravörös (NIR) és a látható vörös (RED) sugárzási tartományban visszavert intenzitások különbségének és összegének hányadosa szolgáltatja, az NDVI korrelál a területet takaró növényzet fajlagos klorofill tartalmával (*Mika et al.*, 2011).

A zöld indexek vagy *Otsu* (1979) módszerének a használata egy klasszikus megoldás a gyomnyomás és a környezeti fényváltozások által okozott hatások csökkentésére.

Bár számos növényt és feltételt tanulmányoztak a légi felvételezések során, a legtöbb kutatásnál az alábbi négy változót vizsgálták a leggyakrabban:

- Vegetációs indexek (NDVI, GNDVI stb.) *Espinoza et al.*, (2017); *Soubry et al.*, (2017) kutatásaikban bizonyos vegetációs tulajdonság változatosságát elemezték.
- Fotokémiai reflektációs index (Photochemical reflectance index - PRI) *Delalieux et al.*, (2014); *Stagakis et al.*, (2012) a levelekben található karotinoid pigmentek visszatükröződési változásait kutatták.
- A levélzet és a levegő hőmérséklete közötti különbséget vizsgálta *Gonzalez-Dugo et al.* (2013), néhány tanulmány pedig közvetlenül a levélzet hőmérsékletét vizsgálta, mint például *Espinoza et al.* (2017).
- A növény vízstressz indexel (crop water stress index – CWSI) kapcsolatban sok kutatást végeztek, mint *Park et al.* (2017); *Poblete et al.* (2018), amely a levél hőmérséklete és a levegő hőmérséklete közti különbségen alapszik, amit a párapomás hiánya (vapor pressure deficit - VPD) szabályoz (*Zarco-Tejada et al.*, 2013).

Azért ezt a négy változót vizsgálták a leggyakrabban a kutatók, mert a vegetációs indexek segítségével sikerült kiszűrni az élő-élettelen dolgokat, ráadásul bizonyos

esetekben már a zöld szín reflektancia alapján elkülöníthetőek voltak a gyomok a kultúrnövénytől. Ha ezzel a detektálási móddal nem lehetett valid eredményeket kapni, akkor további indexek vizsgálatával próbáltak különbségeket találni a növények között. Erre megfelelő megoldást jelenthetett a fotokémiai reflektációs index, a vízstressz index vagy éppen a levélzet-levegő közti különbség vizsgálata (*Gonzalez-Dugo et al.* 2013; *Delalieux et al.*, 2014; *Espinoza et al.*, 2017; *Poblete et al.* 2018).

### **Egyéb gyomfelismerési módszerek**

A gyomok kimutatására és osztályozására újabb technika a fluoreszcens markerek használata, melyet magára a magra vagy az aktuális kultúrnövényre juttatnak ki. *Raja et al.* (2019) négy különböző technikával foglalkoztak, melyek a következők: szisztematikus markerek, fluoreszcens fehérjék, növényjelölések és topical markerek.

A LiDAR (Light Detection and Ranging) egy távérzékelési technika, ahol a távolságok mérésére kerül sor az érzékelő és a detektálandó objektum között. *Andújar et al.* (2013) a LiDAR alapú detektálási eljárással a kukorica sorközökben található négy főgyomot (*Sorghum halepense*, *Cyperus rotundus*, *Datura ferox* és *Xanthium strumarium*) vizsgálták.

### **KÖVETKEZTETÉSEK ÉS ÖSSZEGFOGLALÁS**

A gyomok pontos feltérképezése alapvető fontosságú a gyomsűrűség becsléséhez, valamint a precíziós gyomszabályozás megvalósításához. A mély tanuláshoz szemantikus szegmentálás ígéretes technikának tűnik, azonban szűk keresztmetszete, hogy a mezőgazdasági képeket pixelszintre nem lehet lebontani. Ebből is látszik, hogy a precíziós gyomfelismerés legkritikusabb szakasza az adatok feldolgozása, mivel a begyűjtött képekből tudjuk a gyomok elhelyezkedését meghatározni, valamint az eltérő visszaverődési értékek alapján végezhetjük a szegmentálási folyamatot (*Asad et al.*, 2019).

Ideális körülmények között és a gyomok fejlődésének egy bizonyos időpontját figyelembe véve a jelenlegi képfeldolgozási technikák nagyon reménytelen osztályozási eredményeket mutatnak. Azonban sok kihívással is szembe kell nézni ezzel kapcsolatban. A növények levelei és a gyomok a késői fejlődési szakaszban gyakran átfedik egymást, emiatt megkülönböztethetetlenekké válnak. *Lottes et al.* (2016), *Dyrmann et al.* (2017),

*Ahmad et al.* (2018), kutatásaiknál kisebb-nagyobb sikerrel az átfedéseket okozta problémák megoldására különböző osztályozási eljárásokat alkalmaztak.

Néha bizonyos anyagok vagy károsítók változtathatják meg a levelek morfológiai, texturális vagy spektrális tulajdonságait, a különböző növekedési szakaszokban is ez történik (*Shaner et al.*, 2014). Ez a feladat továbbra is megoldásra vár, mivel a mai napig kevés kutatás foglalkozott ezzel a kérdéssel. Egy általánosan elfogadott megközelítés az osztályozási modell képzése különböző növekedési fázisokban (*Hassanein et al.*, 2018; *Rumpf et al.*, 2012).

További fejlődést okoz a természetes fényviszonyok változása. A különböző megvilágítási viszonyok eltérő színekhez, árnyékokhoz, tükröződésekhez stb. vezetnek, ami nagyban megnehezíti a szegmentálási, osztályozási algoritmusok kialakítását. *Tang et al.* (2016), *Zheng et al.* (2009), *Hamuda et al.* (2018) az algoritmusok hatékonyságának növelése érdekében különböző szintérmodelleket használtak.

Azonban minden lehetséges opciót figyelembe véve új dimenziót jelenthet a mesterséges intelligencia mezőgazdaságban történő megjelenése. Előnye, hogy kiválthatja az élő munkaerőt, az emberek számára komplex, bonyolult feladatokat is pillanatok alatt képes elvégezni, folyamatos tanulásra képes és nagy segítséget jelenthet a gyomfelismerési feladatoknál (*Patrício et al.*, 2018; *Pathan et al.*, 2020; *Tripathi et al.*, 2022).

Bár még mindig számos megválaszolatlan kérdés vetődik fel, ígéretes jövőnek nézünk elébe a gyomdetektálás és osztályozás terén, mivel számtalan kutató és kutatócsoport összpontosítja erre a tématerületre az erejét.

## IMAGE ANALYSIS METHODS IN PRECISION FARMING

SÁNDOR ZSEBŐ<sup>1</sup> – GÁBOR MILICS<sup>2</sup> – ATILA KOVÁCS<sup>1</sup>

<sup>1</sup>Széchenyi István University, Albert Kázmér Agricultural Faculty, Mosonmagyaróvár

<sup>2</sup>Hungarian University of Agriculture and Life Sciences, Gödöllő

### SUMMARY

One of the keys to success in crop production is adequate weed management. In this article, we have a look at the weed detection and classification methods provided by

precision farming, with special attention to the spectral reflectance by weeds. We review and discuss experiments in different cultivated plants in the field and in an artificial environment. The used evaluation methods along with their advantages and disadvantages are presented. Results obtained by the use of artificial intelligence are also examined, representing a potential breakthrough technology in the future for weed detection and classification. The goal of this review is to explore the current state, future challenges, and solutions of precision weed control.

**Keywords:** precision (site-specific) weed management, weed detection, classification, artificial intelligence

### **KÖSZÖNETNYILVÁNÍTÁS**

A cikk elkészítését az EFOP-3.6.3-VEKOP-16-2017-00008 számú projekt támogatta. A projekt az Európai Unió támogatásával, az Európai Szociális Alap társfinanszírozásával valósult meg.

Ezen felül a szerzők köszönetüket fejezik ki a Tématerületi Kiválósági Program 2020 (2020-4.1.1-TKP2020) – Nemzeti Kihívások alprogram – Autonóm Közlekedési Rendszerek Kiválósági Központ létrehozása a Széchenyi István Egyetemen (TKP2020-NKA-14) támogatásának is.

### **IRODALOMJEGYZÉK**

- Adkins, S. – Shabbir, A. (2014):* Biology, ecology and management of the invasive parthenium weed (*Parthenium hysterophorus* L.). *Pest Manag. Sci.* 70 (7), 1023–1029.
- Ahir, K. – Govani, K. – Gajera, R. – Shah, M. (2020):* Application on virtual reality for enhanced education learning, military training and sports. *Augmented Human Research* 5, 7.
- Ahmad, J. – Muhammad, K. – Ahmad, I. – Ahmad, W. – Smith, M.L. – Smith, L.N. – Jain, D.K. – Wang, H. – Mehmood, I. (2018):* Visual features based boosted classification of weeds for real-time selective herbicide sprayer systems. *Comput. Ind.* 98, 23–33.
- Ali, M.M. – Hashim, N. – Aziz, S.A. – Lasekan, O. (2020):* Emerging non-destructive thermal imaging technique coupled with chemometrics on quality and safety inspection in food and agriculture. *Trends in Food Science & Technology.* 105. 176-185.

- Anda, A. – Kocsis, T. – Kovács, A. – Tőkei, L. – Varga, Z. (2010):* Agrometeorológiai és klimatológiai alapismeretek. Mezőgazda kiadó. 70-76.
- Andújar, D. – Escolà, A. – Rosell-Polo, J. R. – Fernández-Quintanilla, C. – Dorado, J. (2013):* Potential of a terrestrial LiDAR-based system to characterise weed vegetation in maize crops. *Com. and El. in Agriculture* 92.11-15.
- Aubert, B.A. – Schroeder, A. – Grimaudo, J. (2012):* IT as enabler of sustainable farming: Anempirical analysis of farmers' adoption decision of precision agriculture technology. *Decision Support Systems* 54 (1), 510–520.
- Asad, M.H. – Bais, A. (2019):* Weed detection in canola fields using maximum likelihood classification and deep convolutional neural network. *Information Processing in Agriculture*.
- Ashraf, M. A. – Maah, M. J. – Yusoff, I. (2011):* Introduction to Remote Sensing of Biomass. *Biomass and Remote Sensing of Biomass. Rijeka Croatia InTech*.129-171.
- Asner, G.P. (1998):* Biophysical and biochemical sources of variability in canopy reflectance. *Remote Sens. Environ*, 64, 234–253.
- Astrand, B. – Baerveldt, A.J. (2005):* A vision based row-following system for agricultural field machinery. *Mechatronics* 15, 251–269.
- Bai, X. – Cao, Z. – Wang, Y. – Yu, Z. – Hu, Z. – Zhang, X. – Li, C. (2014):* Vegetation segmentation robust to illumination variations based on clustering and morphology modelling. *Biosyst. Eng.* 125, 80–97.
- Bannerjee, G. – Sarkar, U. – Das, S. – Ghosh, I. (2018):* Artificial intelligence in agriculture: a literature survey. *International Journal of Scientific Research in Computer Science Applications and Management Studies* 7 (3), 1–6.
- Bauriegel, E. – Herppich, W.B. (2014):* Hyperspectral and chlorophyll fluorescence imaging for early detection of plant diseases, with special reference to fusarium spec. *Infect. Wheat.* 32–57.
- Bi, F.K. – Hou, J.Y. – Wang, Y.T. – Chen, Y. – Wang, Y.P. (2019):* Land cover classification of multispectral remote sensing images based on time-spectrum association features and multikernel boosting incremental learning, *J. Appl. Sens.* 13 (4) 044510,
- Bioucas-Dias, J. – Plaza, A. – Camps-Valls, G. – Scheunders, P. – Nasrabadi, N. – Chanussot, J. (2013):* Hyperspectral remote sensing data analysis and future challenges, *IEEE Geosci. Remote Sens. Mag.* 1 (2) 6–36.

- Blanzieri, E. – Melgani, F.* (2008): Nearest neighbor classification of remote sensing images with the maximal margin principle, *IEEE Trans. Geosci. Remote Sens.* 46 (6) 1804–1811.
- Bulanon, D.M. – Hestand, T. – Nogales, C. – Allen, B. – Colwell, J.* (2020): Machine vision system for orchard management. In: Sergiyenko, O., Flores-Fuentes, W., Mercorelli, P. (Eds.), *Machine Vision and Navigation*. Springer, Switzerland, pp. 197–240.
- Chen, H. – Chen, A. – Xu, L. – Xie, H. – Qiao, H. – Lin, Q. – Cai, K.* (2020): A deep learning CNN architecture applied in smart near-infrared analysis of water pollution for agricultural irrigation resources. *Agricultural Water Management*, 240, 106303.
- Che'Ya, N.N.* (2016): *Site-Specific Weed Management Using Remote Sensing*. University of Queensland.
- Clark, M.L. – Roberts, D.A. – Clark, D.B.* (2005): Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. *Remote Sens. Environ.* 96, 375–398.
- Colomina, I. – Molina, P.* (2014) Unmanned aerial systems for photogrammetry and remote sensing: a review. *ISPRS J. Photogramm. Remote Sens.* 92, 79–97.
- Cortés, V. – Blasco, J. – Aleixos, N. – Cubero, S. – Talens, P.* (2019): Monitoring strategies for quality control of agricultural products using visible and near-infrared spectroscopy: A review. *Trends in Food Science & Technology* 85. 138–148.
- Dammer, K.H. – Intress, J. – Beuche, H. – Selbeck, J. – Dworak, V.* (2013): Discrimination of *Ambrosia artemisiifolia* and *Artemisia vulgaris* by hyperspectral image analysis during the growing season. *Weed Res.* 53, 146–156.
- Datt, B.* (2000): Recognition of eucalyptus forest species using hyperspectral reflectance data. In *Proceedings of the IGARSS. IEEE 2000 International Geoscience and Remote Sensing Symposium*, Honolulu, HI, USA, 24–28 July 2000; 1405–1407.
- De Castro, A. I. – Jurado-Expósito, M. – Gómez-Casero, M.T. – López-Granados, F.* (2012): Applying neural networks to hyperspectral and multispectral field data for discrimination of cruciferous weeds in winter crops. *Sci. World J.*, 1–11.
- De Castro, A.I. – Torres-Sánchez, J. – Peña J.N. – Jiménez-Brenes, F.M. – Csillik, O. – López-Granados, F.* (2018): An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using UAV Imagery. *Remote Sens.* 10, 285.
- De Clercq, M. – Vats, A. – Biel, A.* (2018): Agriculture 4.0: the future of farming technology. In: *Proceedings of the World Government Summit*, Dubai, UAE.

- Delalieux, S. – Somers, B. – Haest, B. – Spanhove, T. – Vanden, B.J. – Múcher, C.A.* (2012): Heathland conservation status mapping through integration of hyperspectral mixture analysis and decision tree classifiers, *Remote Sens. Environ.* 222–231.
- Delalieux, S. – Zarco-Tejada, P.J. – Tits, L. – Bello, M.Á.J. – Intrigliolo, D.S. – Somers, B.* (2014): Unmixing-Based Fusion of Hyperspatial and Hyperspectral Airborne Imagery for Early Detection of Vegetation Stress. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 7, 2571–2582.
- Dian, R. – Li, S. – Sun, B. – Guo, A.* (2020): Recent advances and new guidelines on hyperspectral and multispectral image fusion. *Information Fusion*. Available online 13 November 2020.
- Dyrmann, M. – Karstoft, H. – Midtiby, H.S.* (2016): Plant species classification using deep convolutional neural network. *Biosyst. Eng.* 151, 72–80.
- Espinoza, C.Z. – Khot, L.R. – Sankaran, S. – Jacoby, P.W.* (2017): High Resolution Multispectral and Thermal Remote Sensing-Based Water Stress assessment In Subsurface Irrigated Grapevines. *Remote Sens.*, 9, 961.
- Fawakherji, M. – Bloisi, D. – Pretto, A. – Nardi, D.* (2019): Crop and weeds classification for precision agriculture using context-independent pixel-wise segmentation. 2019 Third IEEE International Conference on Robotic Computing (IRC), 146–152.
- Fernandes, M.R. – Aguiar, F.C. – Silva, J.M. – Ferreira, M.T. – Pereira, J.M.* (2013): Spectral discrimination of giant reed (*Arundo donax* L.): A seasonal study in riparian areas. *ISPRS J. Photogramm. Remote Sens.*, 80, 80–90.
- Gao, J. – Liao, W. – Nuytens, D. – Lootens, P. – Vangeyte, J. – Pizurica, A. – He, Y. – Pieters, J. G.* (2018): Fusion of pixel and object-based features for weed mapping using unmanned aerial vehicle imagery. *International Journal of Applied Earth Observation and Geoinformation*, 67, 43-53.
- García-Santillán, I.D. – Pajares, G.* (2018): On-line crop/weed discrimination through the Mahalanobis distance from images in maize fields. *Biosyst. Eng.* 166, 28–43.
- Gerhards, M. – Schlerf, M. – Mallick, K.* (2019): Challenges and Future Perspectives of Multi-/ Hyperspectral Thermal Infrared Remote Sensing for Crop Water-Stress Detection: A Review.
- Gharde, Y. – Singh, P. – Dubey, R. – Gupta, P.* (2018): Assessment of yield and economic losses in agriculture due to weeds in India. *Crop Protection* 107, 12–18.

- Giselsson, T.M. – Jørgensen, R.N. – Jensen, P.J. – Dyrmann, M. – Midtby, H.S.* (2017): A public image database for benchmark of plant seedling classification algorithms. Available from: arXiv preprint < arxiv.org/abs/1711.05458 >
- Goel, P. – Prasher, S. – Landry, J. – Patel, R. – Bonnell, R. – Viau, A. – Miller, J.* (2003): Potential of airborne hyperspectral remote sensing to detect nitrogen deficiency and weed infestation in corn. *Comput. Electron. Agric.* 38 (2), 99–124.
- Golhani, K. – Balasundram, S.K. – Vadamalai, G. – Pradhan, B.* (2018): A review of neural networks in plant disease detection using hyperspectral data. *Information Processing in Agriculture* 5, 354–371.
- Gonzalez-Dugo, V. – Zarco-Tejada, P. – Nicolás, E. – Nortes, P.A. – Alarcón, J.J. – Intrigliolo, D.S. – Fereres, E.* (2013): Using High Resolution UAV Thermal Imagery to assess The Variability In The Water Status of Five Fruit Tree Species within A Commercial Orchard. *Precis. Agric.* 14, 660–678.
- Goshtasby, A.A. – Nikolov, S.* (2007): Image fusion: Advances in the state of the art, *Inf. Fus.* 8 (2) 114–118.
- Guerrero, J.M. – Ruzb, J.J. – Pajares, G.* (2017): Crop rows and weeds detection in maize fields applying a computer vision system based on geometry. *Com. and El. in Agriculture* Vol. 142, 461-472.
- Hamuda, E. – Mc Ginley, B. – Glavin, M. – Jones, E.* (2018): Improved image processing-based crop detection using Kalman filtering and the Hungarian algorithm. *Comput. Electron. Agric.* 148, 37–44.
- Haug, S. – Michaels, A. – Biber, P. – Ostermann, J.* (2014): Plant classification system for crop /weed discrimination without segmentation. In: 2014 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, pp. 1142–1149.
- Haug, S. – Ostermann, J.* (2015): A crop/weed field image dataset for the evaluation of computer vision based precision agriculture tasks. In: Agapito, L., Bronstein, M., Rother, C. (Eds.), *Computer Vision - ECCV 2014 Workshops*. Springer, Switzerland, pp. 105–116.
- Hassanein, M. – Lari, Z. – El-Sheimy, N. – Hassanein, M. – Lari, Z. – El-Sheimy, N.* (2018): A new vegetation segmentation approach for cropped fields based on threshold detection from hue histograms. *Sensors* 18, 1253.
- Havasy, Gy. – Molnár, M. – Szunyogh, Zs. – Tóth, M. – Korpás, A. – Csernyák, L.* (1996): *Általános statisztika I.* Budapest. Nemzeti Tankönyvkiadó Rt. 209-218.



- Huang, Y. – Lee, M.A. – Thomson, S.J. – Reddy, K.N.* (2016): Ground-based hyperspectral remote sensing for weed management in crop production. *Int. J. Agric. Biol. Eng.* 9, 98–109.
- Jha, K. – Doshi, A. – Patel, P. – Shah, M.* (2019): A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*. 2, 1–12.
- Jinru, X. – Su, B.* (2017): Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*. Article ID 1353691.
- Jones, T.G. – Coops, N.C. – Sharma, T.* (2010): Employing ground-based spectroscopy for tree-species differentiation in the Gulf Islands National Park Reserve. *Int. J. Remote Sens.* 31, 1121–1127.
- Kakkad, V. – Patel, M. – Shah, M.* (2019): Biometric authentication and image encryption for image security in cloud framework. *Multiscale and Multidiscip. Model. Exp. and Des.*, 1–16.
- Kazmi, W. – Garcia-Ruizb, F.J. – Nielsen, J. – Rasmussen, J. – Andersen, H.J.* (2015): Detecting creeping thistle in sugar beet fields using vegetation indices. *Com. El. Agriculture*. 112, 10–19.
- Khan, A. – Vibhute, A.D. – Mali, S. – Patil, C.H.* (2022): A systematic review on hyperspectral imaging technology with a machine and deep learning methodology for agricultural applications. *Ecol. Info.* 69, 101678.
- Knipling, E.B.* (1970): Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sens. Environ.* 1970, 1, 155–159.
- Kumar, A. – Pacheco, D.A.D.J. – Kaushik, K. – Rodrigues, J.J.P.C.* (2022): Futuristic view of the Internet of Quantum Drones: Review, challenges and research agenda. *Vehicular Communications* 36. 100487.
- Kundalia, K. – Patel, Y. – Shah, M.* (2020): Multi-label movie genre detection from a movie poster using knowledge transfer learning. *Augment Hum Res* 5, 11.
- Li, X. – Levin, N. – Xie, J. – Li, D.* (2020): Monitoring hourly night-time light by an unmanned aerial vehicle and its implications to satellite remote sensing. *Remote Sensing of Environment*, 247, 111942.
- Li, Y. – Guo, Z. – Shuang, F. – Zhang, M. – Li, X.* (2022): Key technologies of machine vision for weeding robots: A review and benchmark. *Comput. Electron. Agric.* 196. 106880.

- Lin, C.* (2009): A support vector machine embedded weed identification system. University of Illinois at Urbana-Champaign.
- Liu, K. – Zhou, Q. – Wu, W. – Xia, T. – Tang, H.* (2016): Estimating the crop leaf area index using hyperspectral remote sensing. *J. Integr. Agric.* 15 (2), 475–491.
- Lobet, G.* (2017): Image analysis in plant sciences: publish then perish. *Trends Plant Sci.* 22, 559–566.
- Lodhi, V. – Chakravarty, D. – Mitra, P.* (2019): Hyperspectral imaging system: development aspects and recent trends. *Sens Imaging.*
- Longchamps, L. – Panneton, B. – Samson, G. – Leroux, G.D. – Thériault, R.* (2009): Discrimination of corn, grasses and dicot weeds by their UV-induced fluorescence spectral signature. *Precis. Agric.* 11, 181–197.
- López-Granados, F.* (2011): Weed detection for site-specific weed management: mapping and real-time approaches. *Weed Res.* 51, 1–11.
- Lottes, P. – Behley, J. – Chebroly, N. – Milioto, A. – Stachniss, C.* (2018): Joint stem detection and crop-weed classification for plant-specific treatment in precision farming. In: 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems IEEE, pp. 8233–8238.
- Lottes, P. – Hoferlin, M. – Sander, S. – Muter, M. – Schulze, P. – Stachniss, L.C.* (2016): An effective classification system for separating sugar beets and weeds for precision farming applications. In: 2016 IEEE International Conference on Robotics and Automation (ICRA). IEEE, pp. 5157–5163.
- Maes, W.H. – Steppe, K.* (2019): Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture Volume 24, Issue 2, 152-164.
- Mahlein, A.K.* (2016): Plant disease detection by imaging sensors – parallels and specific demands for precision agriculture and plant phenotyping. *Plant Dis.* 100, 241–251.
- Matese, A. – Capraro, F. – Primicerio, J. – Gualato, G. – Di Gennaro, S.F. – Agati, G.* (2013): Mapping of vine vigor by UAV and anthocyanin content by a non-destructive fluorescence technique. In *Precision Agriculture*; Wageningen Academic Publishers: Lleida, Spain, pp. 201–208.
- Mavridou, E. – Vriochidou, E. – Papakostas, G.A. – Pachidis, T. – Kaburlasos, V.G.* (2019): Machine vision systems in precision agriculture for crop farming. *J. Imaging* 5, 59.

- McCarthy, A. – Raine S.* (2022): Automated variety trial plot growth and flowering detection for maize and soybean using machine vision. *Com. El. Agriculture*. 194, 106727
- McCool, C. – Perez, T. – Upcroft, B.* (2017): Mixtures of lightweight deep convolutional neural networks: Applied to agricultural robotics. *IEEE Rob. Autom. Lett.* 2 (3), 1344–1351.
- Melgani, F. – Bruzzone L.* (2004): Classification of hyperspectral remote sensing images with support vector machines, *IEEE Trans. Geosci. Remote Sens.* 42 (8) 1778–1790.
- Meng, Q.K. – Qiu, R.C. – He, J. – Zhang, M. – Ma, X.D. – Liu, G.* (2015): Development of agricultural implement system based on machine vision and fuzzy control. *Com. El. Agriculture*. 112, 128–138.
- Mika, J. – Utasi, Z. – Biró, Cs.P. – Kónya E.* (2011): Műholdakról távérzékelt adatok feldolgozása és hasznosítása. *EKF TTK 71-74*.
- Mogili U.R. – Deepak B.B.V.L.* (2018): Review on Application of Drone Systems in Precision Agriculture. *Procedia Computer Science* 133. 502–509.
- Mohanty, S.P. – Hughes, D.P. – Salathé, M.* (2016): Using deep learning for image-based plant disease detection. *Front. Plant Sci.* 22.
- Montalvo, M. – Pajares, G. – Guerrero, J.M. – Romeo, J. – Guijarro, M. – Ribeiro, A. – Ruz, J.J. – Cruz, J.M.* (2012): Automatic detection of crop rows in maize fields with high weeds pressure. *Expert Syst. Appl.* 39, 11889–11897.
- Moshou, D. – Bravo, C. – Oberti, R. – West, J. – Bodria, L. – McCartney, A. – Ramon, H.* (2005): Plant disease detection based on data fusion of hyper-spectral and multi-spectral fluorescence imaging using Kohonen maps. *Real-Time Imaging* 11 (2), 75–83.
- Ollinger, S.V.* (2011): Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytol.*, 189, 375–394.
- Olsen, A. – Konovalov, D.A. – Philippa, B. – Ridd, P. – Wood, J.C., – Johns, J., et al.* (2019): Deepweeds: a multiclass weed species image dataset for deep learning. *Sci Rep*;9(1):2058.
- Otsu, N.*, (1979): A threshold selection method from gray-level histogram. *IEEE Trans. Syst. Man Cybern.* 9, 62–66.
- Padró, J.C. – Muñoz, F.J. – Planas, J. – Pons, X.* (2019): Comparison of four UAV georeferencing methods for environmental monitoring purposes focusing on the combined use with airborne and satellite remote sensing platforms. *International Journal of Applied Earth Observation and Geoinformation*, 75, 130–140.

- Panchiwala, S. – Shah, M.* (2020): A comprehensive study on critical security issues and challenges of the IoT world. *J. of Data, Inf. and Manag.*
- Pandya, R. – Nadiadwala, S. – Shah, R. – Shah, M.* (2020): Buildout of methodology for meticulous diagnosis of K-complex in EEG for aiding the detection of Alzheimer's by artificial intelligence. *Augmented Human Research* 5. 3.
- Park, S. – Ryu, D. – Fuentes, S. – Chung, H. – Hernández-Montes, E. – O'Connell, M.* (2017): Adaptive Estimation of Crop Water Stress In Nectarine and Peach Orchards Using High-Resolution Imagery From An Unmanned Aerial Vehicle (UAV). *Remote Sens.* 9, 828.
- Pathan, M. – Patel, N. – Yagnik, H. – Shah, M.* (2020): Artificial cognition for applications in smart agriculture: A comprehensive review. *Artificial Intelligence in Agriculture.*
- Patrício, D.I. – Rieder, R.* (2018): Computer vision and artificial intelligence in precision agriculture for grain crops: a systematic review. *Comput. Electron. Agric.* 153, 69–81.
- Paxton, K.W. – Mishra, A.K. – Chintawar, S. – Roberts, R.K. – Larson, J.A. – English, B.C. – Lambert, D.M. – Marra, M.C. – Larkin, S.L. – Reeves, J.M. – Martin, S.W.* (2011): Intensity of Precision Agriculture Technology Adoption by Cotton Producers. *Agricultural and Resource Economics Review* 40 (01), 133–144.
- Peteinatos, G.G. – Weis, M. – Andújar, D. – Rueda Ayala, V. – Gerhards, R.* (2014): Potential use of ground-based sensor technologies for weed detection. *Pest Manag. Sci.* 70, 190–199.
- Pivoto, D. – Waquil, P.D. – Talamini, E. – Finocchio, C.P.S. – Corte, V.F.D. – Mores, G.D.V.* (2018): Scientific development of smart farming technologies and their application in Brazil. *Information Processing in Agriculture* 5 (1), 21–32.
- Poblete, T. – Ortega-Farias, S. – Ryu, D.* (2018): Automatic Coregistration Algorithm to Remove Canopy Shaded Pixels in UAV-Borne Thermal Images to Improve The Estimation of Crop Water Stress Index of A Drip-Irrigated Cabernet Sauvignon Vineyard. *Sensors.* 18, 397.
- Raja, R. – Slaughter, D.C. – Fennimore, S.A. – Nguyen, T.T. – Vuong, V.L. – Sinha, N. – Tourte, L. – Smith, R.F. – Siemens M.C.* (2019): Crop signalling: A novel crop recognition technique for robotic weed control *Biosystems Engineering* 187. 278-291.

- Ranjan, R. – Chandel, A. K. – Khot, L. R. – Bahlol, H. Y. – Zhou, J. – Boydston, R. A. – Miklas, P. N.* (2019): Irrigated pinto bean crop stress and yield assessment using ground based low altitude remote sensing technology. *Information Processing in Agriculture*.
- Redmon, J. – Farhadi, A.* (2018): YOLOv3: An Incremental Improvement. Available from arXiv preprint < <https://arxiv.org/abs/1804.02767> > .
- Reiser, D. – Martín-López, J. – Memic, E. – Vázquez-Arellano, M. – Brandner, S. – Griepentrog, H.* (2017): 3D imaging with a sonar sensor and an automated 3-axes frame for selective spraying in controlled conditions. *J. Imag.* 3, 9. <https://doi.org/10.3390/jimaging3010009>.
- Romeo, J. – Pajares, G. – Montalvo, M. – Guerrero, J.M. – Guijarro, M. – de la Cruz, J.M.* (2013): A new Expert System for greenness identification in agricultural images. *Expert Syst. Appl.* 40, 2275–2286.
- Ruchelshausen, A. – Biber, P. – Dorna, M. – Gremmes, H. – Klose, R. – Linz, A. – Rahe, R. – Resch, R. – Thiel, M. – Trautz, D. – Weiss, U.* (2009): BoniRob: an autonomous field robot platform for individual plant phenotyping. *Precis. Agric.* 09, 841–847.
- Rumpf, T. – Roemer, C. – Weis, M. – Sokefeld, M. – Gerhards, R. – Pluemer, L.* (2012): Sequential support vector machine classification for small-grain weed species discrimination with special regard to *Cirsium arvense* and *Galium aparine*. *Comput. Electron. Agric.* 80, 89–96.
- Sa, I. – Chen, Z. – Popovic, M. – Khanna, R. – Liebisch, F. – Nieto, J. – Siegwart, R.* (2017): weedNet: dense semantic weed classification using multispectral images and MAV for smart farming. *IEEE Rob. Autom. Lett.* 3, 588–595.
- Sa, I. – Popovic, M. – Khanna, R. – Chen, Z. – Lottes, P. – Liebisch, F. – Nieto, J. – Stachniss, C. – Walter, A. – Siegwart, R.* (2018): WeedMap: a large-scale semantic weed mapping framework using aerial multispectral imaging and deep neural network for precision farming. *Remote Sensing* 10, 1423.
- Sakthipriya, D. – Chandrakumar, T.* (2022): A study on agriculture engineering implements using machine learning. *Materialstoday: Proceedings*. Available online 28 April 2022.
- Shaner, D.L. – Beckie, H.J.* (2014): The future for weed control and technology. *Pest Manag. Sci.* 70, 1329–1339.
- Shapira, U. – Herrmann, I. – Karnieli, A. – Bonfil, D.J.* (2013): Field spectroscopy for weed detection in wheat and chickpea fields. *Int. J. Remote Sens.* 34, 6094–6108.

- Shendryk, Y. – Sofonia, J. – Garrard, R. – Rist, J. – Skocaj, D. – Thorburn, P.* (2020): Fine-scale prediction of biomass and leaf nitrogen content in sugarcane using UAV LiDAR and multispectral imaging, *Int. J. Appl. Earth Obs. Geoinformation*, 92 (2020), p. 102177,
- Sladojevic, S. – Arsenovic, M. – Anderla, A. – Culibrk, D. – Stefanovic, D.* (2016): Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, 1–11.
- Soubry, I. – Patias, P. – Tsioukas, V.* (2017): Monitoring Vineyards with UAV and Multi-sensors for the assessment of Water Stress and Grape Maturity. *J. Unmanned Veh. Syst.* 5, 37–50.
- Stagakis, S. – Gonzalez-Dugo, V. – Cid, P. – Guillen-Climent, M. – Zarco-Tejada, P.* (2012): Monitoring Water Stress and Fruit Quality In An Orange Orchard Under Regulated Deficit Irrigation Using Narrow-band Structural and Physiological Remote Sensing Indices *ISPRS J. Photogramm. Remote Sens.* 71, 47–61.
- Su, H. – Cai, Y. – Du, Q.* (2017): Firefly-algorithm-inspired framework with band selection and extreme learning machine for hyperspectral image classification, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 10 (1) 309–320.
- Sukhadia, A. – Upadhyay, K. – Gundeti, M. – Shah, S. – Shah, M.* (2020): Optimization of smart traffic governance system using artificial intelligence. *Augment Hum Res* 5, 13.
- Sun, C. – Shrivastava, A. – Singh, S. – Gupta, A.* (2017): Revisiting unreasonable effectiveness of data in deep learning era. In: *The IEEE International Conference on Computer Vision (ICCV)*, Venice, Italy, pp. 843–852.
- Sun, J. – Li, Y. P. – Zhuang, X. W. – Jin, S. W. – Huang, G. H. – Feng, R. F.* (2017): Identifying water resources management strategies in adaptation to climate change under uncertainty. *Mitigation and Adaptation Strategies for Global Change*, 23(4), 553–578.
- Talaviya, T. – Shah, D. – Patel, N. – Yagnik, H. – Shah, M.* (2020): Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. *Artificial Intelligence in Agriculture*. 4- 58-73.
- Tang, J. – Chen, X.Q. – Miao, R.H. – Wang, D.* (2016): Weed detection using image processing under different illumination for site-specific areas spraying. *Comput. Electron. Agric.* 122, 103–111.

- Teke, M. – Deveci, H.S. – Haliloglu, O. – Gurbuz, S.Z. – Sakarya, U.* (2013): A short survey of hyperspectral remote sensing applications in agriculture. 2013 6th International Conference on Recent Advances in Space Technologies (RAST).
- Thenkabail, P. – Smith, R. – De Pauw, E.* (1999): Hyperspectral Vegetation Indices for Determining Agricultural Crop Characteristics, CEO Research Publication Series No. 1; Center for Earth Observation, Yale University Press: New Haven, CT, USA.
- Tremblay, N. – Wang, Z. – Ma, B.L. – Belec, C. – Vigneault, P.* (2009): A comparison of crop data measured by two commercial sensors for variable-rate nitrogen application. *Precis. Agric.* 10, 145–161.
- Tripathi, S.P. – Yadav, R.K. – Rai, H.* (2022): A deep neural net for weed identification. *Deep Learning for Sustainable Agriculture.* 223-236.
- Turcsányi, G. – Siller, I.* (2005): Növénytan. Budapest, Kossuth Kiadó. (Csak CD formátumban jelent meg)
- Vijayalakshmi, S. – Kumar, M. – Arun, M.* (2020): A study of various classification techniques used for very high-resolution remote sensing [VHRRS] images. *Materials Today: Proceedings Volume 37, Part 2, 2021, Pages 2947-2951*
- Waheed, T. – Bonnell, R.B. – Prasher, S.O. – Paulet, E.* (2006): Measuring performance in precision agriculture: CART—A decision tree approach. *Agriculture Water Management* 84, 173–185.
- Wang, A. – Zhang, W. – Wei, X.* (2019): A review on weed detection using ground-based machine vision and image processing techniques. *Comput. Electron. Agric.* 158, 226–240.
- Wang, T. – Chen, B. – Zhang, Z. – Li, H. – Zhang, M.* (2022): Applications of machine vision in agricultural robot navigation: A review. *Comput. Electron. Agric.* 198, 107085.
- Wei, F. – Yan, Z. – Yongchao, T. – Weixing, C. – Xia, Y. – Yingxue, L.* (2008): Monitoring leaf nitrogen accumulation in wheat with hyper-spectral remote sensing. *Acta Ecol. Sin.* 28 (1), 23–32.
- Yang, X. – Yu, Y. – Fan, W.* (2015): Chlorophyll Content Retrieval from Hyperspectral Remote Sensing Imagery Chlorophyll Content Retrieval from Hyperspectral Remote Sensing Imagery
- Yanga, Y. – Ye, Z. – Su, Y. – Zhao, Q. – Li, X. – Ouyang, D.* (2019): Deep learning for in vitro prediction of pharmaceutical formulations *Acta Pharmaceutica Sinica B* Volume 9, Issue 1, 177-185.

- Yost, M. – Kitchen, N. – Sudduth, K. – Sadler, E. – Drummond, S. – Volkmann, M. (2017):* Long-term impact of a precision agriculture system on grain crop production. *Precision Agriculture* 18 (5), 823–842.
- Zarco-Tejada, P. – González-Dugo, V. – Williams, L. – Suárez, L. – Berni, J. – Goldhamer, D. – Fereres, E. (2013):* A PRI-based Water Stress Index Combining Structural and Chlorophyll Effects: Assessment Using Diurnal Narrow-band Airborne Imagery and The CWSI Thermal Index. *Remote Sens. Environ.* 138, 38–50.
- Zhang, M. – Qin, Z. – Liu, X. – Ustin, S.L. (2003):* Detection of stress in tomatoes induced by late blight disease in California, USA, using hyperspectral remote sensing. *Int. J. Appl. Earth Obs. Geoinf.* 4 (4), 295–310.
- Zhang, T. – Tan, Q. – Zhang, S. – Wang, S. – Gou, T. (2020):* A robust multi-objective model for supporting agricultural water management with uncertain preferences. *Journal of Cleaner Production*, 120204.
- Zheng, L. – Zhang, J. – Wang, Q. (2009):* Mean-shift-based color segmentation of images containing green vegetation. *Comput. Electron. Agric.* 65, 93–98.
- Zwiggelaar, R. (1998):* A review of spectral properties of plants and their potential use for crop/weed discrimination in row-crops. *Crop Prot.* 17, 189–206.

*A szerzők címe – Adress of the author:*

ZSEBŐ SÁNDOR

Széchenyi István Egyetem, Albert Kázmér Mosonmagyaróvári Kar, Biológiai Rendszerek és Precíziós Technológiai Tanszék  
9200 Mosonmagyaróvár, Vár tér 2.  
zsebo.sandor@gmail.com

MILICS GÁBOR

Magyar Agrár- és Élettudományi Egyetem, Gödöllő Precíziós Gazdálkodási és Agrárdigitalizációs Tanszék 2100 Gödöllő, Páter Károly utca 1.  
milics.gabor@uni-mate.hu



KOVÁCS ATTILA JÓZSEF

Széchenyi István Egyetem, Albert Kázmér Mosonmagyaróvári Kar,

Biológiai Rendszerek és Precíziós Technológiai Tanszék

9200 Mosonmagyaróvár, Vár tér 2.

kovacs.attila@sze.hu