

## A mesterséges intelligencia felhasználása a növénytermesztési kísérletekben

BERZSENYI ZOLTÁN

HUN-REN Agrártudományi Kutatóközpont, Martonvásár

### Összefoglalás

Az összefüggések megértése a termés, a talajtulajdonságok, az időjárás és az input applikáció között fontos a mezőgazdasági produkció optimalizálásához. A fenntartható intenzifikáció célja, hogy növeljük a produktivitást és az inputfelhasználás hatékonyságát, miközben fokozzuk a mezőgazdasági rendszerek rugalmasságát a kedvezőtlen környezeti tényezőkre a javított menedzsmenten és technológián keresztül. A mesterséges intelligencia (AI) a precíziós gazdálkodásban (PA) lehetővé teszi a gazdálkodóknak, hogy nagyon célirányos és pontos termesztési eljárásokat használjanak a helyspecifikus agroklimatikus szántóföldi mérések alapján. A legújabb fejlesztések az érzékelésben, a gépi tanulásban (ML) és a modellezésben lehetőséget kínálnak az új digitális technológiákra, hogy megvalósítsuk a fenntartható intenzifikációt.

Az újabb tudományos publikációk áttekintése alapján bemutattuk a digitális technológia alkalmazását a növénytermesztési kísérletekben három területen: (i) növény- és talajtulajdonságok folyamatos monitorozása, (ii) termésreakció térbeni és időbeni variabilitásának vizsgálata és (iii) gépi tanulás (ML) modellek felhasználása a termés előrejelzésére. Levonható az a következtetés, hogy az adatok varianciájának analízise, felhasználva a statisztikai és gépi tanulás megközelítéseket, segíthet azonosítani és megérteni azokat a termesztési eljárásokat, melyek optimalizálják a termést.

**Kulcsszavak:** fenntartható intenzifikáció, precíziós mezőgazdaság, mesterséges intelligencia, gépi tanulás, termés előrejelzés

## Use of artificial intelligence in crop production experiments

Z. BERZSENYI

HUN-REN Centre for Agricultural Research, Martonvásár

### Summary

Understanding the relationships between crop yields, soil properties, weather patterns and input applications is important for optimising agricultural production. Sustainable intensification aims to increase productivity and input-use efficiency while enhancing the resilience of agricultural systems to adverse environmental conditions through improved management and technology. Artificial intelligence (AI) in precision agriculture (PA) enables growers to deploy highly targeted and precise farming practices based on site-specific agro-climatic field measurements. Recent advances in sensing, machine learning (ML) and modelling offer opportunities for novel smart digital technologies to enable sustainable intensification.

Through the review of the newest scientific publications the application of digital technology in crop production experiments was demonstrated in three topics: (i) continues monitoring of crop and soil characteristics, (ii) quantification of spatial and temporal variability of crop response and (iii) forecasting of crop yield by the use of machine learning approaches. It was concluded that the variation analysis and machine learning approaches can help identify and understand the practices that optimise yield.

**Keywords:** sustainable intensification, precision agriculture, artificial intelligence, machine learning, yield forecasting

### Mesterséges intelligencia a fenntartható növénytermesztésben

A mesterséges intelligencia (AI) képvisel olyan technológiákat, melyek emberhez hasonló értelmi képességgel rendelkeznek a tanulásban, teljesítményben és a döntéshozatalban. Mesterséges intelligencia jelenti azt a


képességet, hogy megvizsgáljuk az adatokat a statisztikai analízisen keresztül, lehetővé téve, hogy megértsük, analizáljuk és új ismeretekhez jussunk az adatokból statisztikailag megtervezett algoritmuson keresztül. Ez a gépi intelligencia különbözik a természetes intelligenciától, amely a biológiai szervezetekben található, mivel létrehozott, mesterséges és digitális. Az AI egy szoftver, amely elindíthat logikus gondolkodást, tanulást és megoldhat komplex problémákat. Az AI-t gyakran definiálják számítógépes tudományos módszerekkel összefüggésben, melyeket alkalmaz, mint a gépi tanulás (ML), megerősítő tanulás és mély tanulás (DL). A szoftver kivitelezhető robot struktúrák (mint az automata autók, robot kezek, emberszerű robotok, stb.) fizikai formáiban. A mezőgazdaságban az AI használata úgy tekinthető, mint a „valós érték átadása” a termelőnek és a társadalom irányítása a „negyedik ipari forradalom” felé vagy a 4.0 jelű mezőgazdaság felé, okos (smart) gazdálkodási módszerekkel és döntéshozó eszközökkel. A precíziós mezőgazdaság egy ilyen „adatok által irányított stratégia”, melynek célja, hogy javítsuk a talaj és forrás menedzsmentet és szabályozzuk a növényeket (Gardezi et al. 2024).

A mesterséges intelligenciának (AI) széleskörű az alkalmazási lehetősége a mezőgazdaságban. Az AI egy fejlettebb verziója az egyszerűbb technológiáknak, a szántóföldi adatok folyamatos megfigyelésének, begyűjtésének és feldolgozásának. Alkalmassá teszi a gazdaságokat a legkorszerűbb technológiák szántóföldi bevezetésére. Ahhoz, hogy egészségesebb növényeket termesszünk, szabályozzuk a növényi károsítókat, folyamatosan megfigyeljük (monitorozzuk) a növényeket, a talajt és a termesztési feltételeket, analizáljuk az adatokat és növeljük az élelmiszerlánc különböző menedzsment tevékenységeit, a mezőgazdaságnak át kell térni az AI technológiákra.

Az AI felhasználja a technológiákat, mint a gépi tanulás (ML), mély tanulás, a robotok, a dolgok internete, 'big data' és analitika, a képfeldolgozás, a mesterséges ideghálózat (ANN), a vezeték nélküli szenzor hálózatot, és más korszerű módszerek, hogy megoldást találjon a mezőgazdasági kihívásokra (Javaid 2023, Storm et al. 2024). A 'big data' fogalma alatt azt a komplex technológiai környezetet (szoftvert, hardvert, hálózati modelleket) értjük, amely lehetővé teszi olyan adatállományok feldolgozását, amelyek annyira nagyméretűek és annyira komplexek, hogy feldolgozásuk a meglévő adatbázis-menedzsment eszközökkel jelentős nehézségekbe ütközik. A gépi

tanulás (machine learning, ML), mint a mesterséges intelligencia egyik ága, olyan rendszereket foglal magában, melyek tanulni képesek, azaz tapasztalatokból tudást generálnak. Ezek a technológiák segítenek a termelőknek, hogy valós időben folyamatosan gyűjtsenek adatokat, mint az időjárás, hőmérséklet, vízfelhasználás, talajviszonyok, és ezáltal jobban megalapozzák döntéseiket. Az AI rendszerek képesek folyamatosan megfigyelni a tápanyag szinteket a talajban és meghatározni azt a dózist, mely maximálja a produkciót, miközben legkisebb a környezetre gyakorolt kedvezőtlen hatása (Javaid et al. 2023). Az AI a precíziós gazdálkodásban (PA) lehetővé teszi a gazdálkodóknak, hogy nagyon célirányos és pontos termesztési eljárásokat használjanak a helyspecifikus agroklímikus szántóföldi mérések alapján. Az 1. ábra mutatja az AI alkalmazás folyamatát a mezőgazdaságban.

1. ábra. A mesterséges intelligencia (AI) alkalmazásának folyamata a mezőgazdaságban



Forrás: Javaid et al. (2023)

Figure 1. Process of artificial intelligence adaptation in agriculture. (1) Data generation, (2) Data storage, (3) Data processing, (4) Artificial intelligence, (5) Agriculture monitoring, (6) Action/signal, (7) Prediction, Source: Javaid et al. (2023)

Harsányi et al. (2023) az adatbányászat és a gépi tanulás algoritmusok felhasználását tanulmányozta a kukoricatermés előrejelzésének optimalizálására Közép-Európában. Négy ML algoritmus teljesítményét becsülték a kukoricatermés előrejelzésében, négy különböző input szcenárió alapján. A begyűjtött adatok magukba foglaltak mezőgazdasági adatokat (produkció, kukorica vetésterülete) és klimatikus adatokat (évi átlagos hőmérséklet °C, csapadék (mm), esős napok,

fagyos napok és hőség napok). A kutatás eredménye alapján optimális modellként az ANN-MLP (artificial neural network-multilayer perceptron = mesterséges neuron hálózat többretegű perceptron) modellt javasolták a kukoricatermés előrejelzésére regionális szinten. Vizsgálták a klimatikus faktorokat különböző scenáriókban a termés előrejelzés modellezésében regionális skálán Közép-Európában. Az öt klimatikus inputváltozó közül az évi átlagos hőmérséklet rendelkezett a legjelentősebb befolyással a kukoricatermésre, pozitív korrelációval és jó előrejelzőnek bizonyult, párhuzamosan a csapadékkal a termés előrejelzés modellezésében. Összehasonlítva a klasszikus növény modell programokkal az ML algoritmusok azonosíthatnak mintázatokat, pontosabban és gyorsabban végezhetnek előrejelzéseket.

### **A precíziós mezőgazdaság szerepe a fenntartható intenzifikációban**

A precíziós mezőgazdaság (PA) célja, hogy növelje a mezőgazdaság produktivitását, miközben csökkenti a környezeti hatásokat, megőrizve a természeti forrásokat és támogatva a fenntarthatóságot. A precíziós technológiák képessé tehetik a termelőket, hogy alkalmazkodjanak a környezet szabályozásához és ott használjanak inputokat, mint a műtrágyák és peszticidek, ahol szükséges. A PA elősegíti a fenntartható intenzifikáció megvalósítását a fejlett technológiák használatán keresztül, mint a globális helymeghatározó rendszerek (GPS), térinformatikai rendszerek (GIS), szenzorok, drónok és gépi tanulás (ML). Ezek a technológiák lehetővé teszik a termelőknek, hogy hatékonyabb és pontosabb termesztéstechnológiákat alkalmazzanak (Nath 2024). A GPS-t és a GIS-t arra használjuk, hogy pontos térképeket készítsünk a talajjellemzőkről, a topográfiairól és más jellemzőkről, melyek hatással vannak a növény növekedésére. Szenzorok és drónok felhasználhatók a növény egészségi állapotának, a vízfelhasználás és a növényi károsítók fertőzésének monitorozására. Az ML algoritmusok felhasználhatók, hogy analizáljuk a begyűjtött hatalmas adatmennyiséget és valós idejű döntéstámogatást kapjunk. Ezen kívül a termés monitorok és az önjáró traktorok elősegítik a PA-t azáltal, hogy valós idejű növény teljesítmény adatokat adnak és pontos szántóföldi műveleteket végeznek.

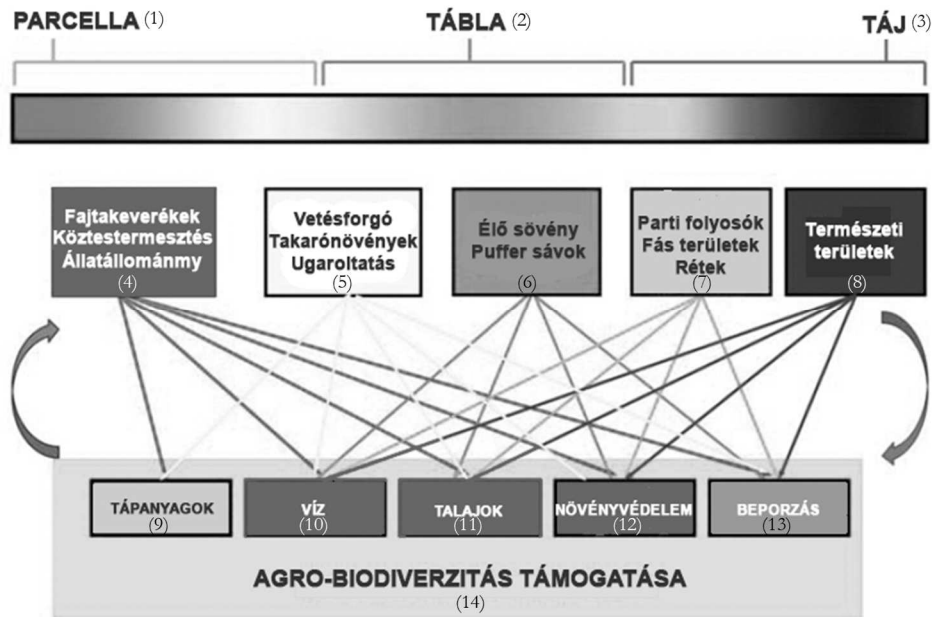
A fenntartható intenzifikáció hozzájárulhat a globális kihívások megoldásához, mint a klímaváltozás. A fenntartható PA felhasználja a fejlett

technológiákat, hogy optimalizáljuk az erőforrások hasznosítását és ily módon alkalmazkodjunk a klímaváltozás hatásához. A fenntartható intenzifikáció magában foglalja az ökológiai és genetikai intenzifikáció felhasználását, hogy növeljük a növények termését, miközben csökkentjük a mezőgazdasági inputokat. Egy másik stratégia a talaj egészségi állapotának javítása a megőrző (fenntartható) mezőgazdasági eljárásokon keresztül, mint a redukált talajművelés és a takarónövények termesztése. Ezen kívül a társadalmi-ökonómiai intenzifikáció képez egy alkalmas környezetet, hogy támogassa a technológia fogadását és létrehozzon piacokat a fenntartható intenzifikáció termékeinek (*Nath 2024*).

A fenntartható intenzifikáció fontos komponensét képezi a diverzifikált termesztési rendszerek kialakítása (*Berzsenyi 2024*). Az ökológiai skálákon át a diverzifikált termesztési rendszerek magukba foglalnak több eltérő genetikai összetételű fajtát, vagy több növényfaj köztestermesztését, és/vagy az állatállomány integrációját; vetésforgókat, takarónövényeket, zöldtrágyázást; továbbá minden olyan eljárást, amely megváltoztatja a vetést egy adott táblán az idő folyamán (pl. élő sövények vagy puffer sorok vetése, stb.). Az ilyen eljárások térben heterogén termesztési rendszerekhez vezetnek, a parcellától (táblarészlet) a táj skáláig és magukba foglalják a biodiverzitást. Ezek a termesztési eljárások elősegítik a kritikus ökoszisztéma szolgáltatásokat (pl. tápanyagok körforgása, talajképződés, növényi károsítók szabályozása, beporzás, stb.), mint a vonalak jelölik a 2. ábrán, melyek összekapcsolják mindegyik termesztési eljárást mindegyik ökoszisztéma szolgáltatással (*Kremen et al. 2012*).

Egyik fő terület, ahol a PA hozzájárulhat a fenntartható intenzifikációhoz, a nitrogén-műtrágyázás szabályozása. A PA csökkentheti a nitrogénműtrágya felhasználását és növelheti a nitrogén-felhasználás hatékonyságát (NUE) azáltal, hogy összehangolja a nitrogéninputot a növény szükségletével. Egy másik terület, ahol a PA hozzájárulhat a fenntartható intenzifikációhoz, az öntözés szabályozása. A PA segíthet a termelőknek, hogy az öntözést hatékonyabban szabályozzák, felhasználva szenzorokat, hogy monitorozzák a talajnedvesség szinteket és az időjárási körülményeket és csak akkor és ott juttassanak ki vizet, ahol szükséges. Ez nagyobb terméshez és kisebb vízfelhasználáshoz vezethet. A PA hatékonyan szabályozza a károsítókat, betegségeket és gyomnövényeket, csökkentve a peszticid szükségletet és minimalizálva a negatív környezeti hatásokat.

2. ábra. Egy diverzifikált termesztési rendszer fogalmi modellje



Forrás: Kremen *et al.* (2012)

Figure 2. Conceptual model of diversified cropping system. (1) Plot, (2) Field, (3) Landscape, (4) Mixed varieties, mixed crops, livestock, (5) Crop rotation, cover crops, fallow field, (6) Hedgerow, buffer strips, (7) Riparian corridors, woodlots, meadows, (8) Natural areas, (9) Nutrients, (10) Water, (11) Soils, (12) Pest control, (13) Pollination, (14) Supporting agro-biodiversity, Source: Kremen *et al.* (2012)

A precíziós növénytermesztés témakörében több fontos hazai tudományos dolgozat, tanulmány és szakkönyv jelent meg az elmúlt időszakban (Németh *et al.* 2007, Milics 2008, Balla *et al.* 2011, Nyéki *et al.* 2017, Gaál és Illés 2020, Nagy és Búvár 2022).

### A digitális technológia felhasználása a növénytermesztési kísérletekben

A növénytermesztési kísérletek jelentősen hozzájárulnak a mesterséges intelligencia alkalmazásához a mezőgazdaságban. Egyrészt a kísérletekben a

növény, a talaj és környezet folyamatos monitorozásával adatokat szolgáltatnak, másrészt összefüggéseket tárnak fel a termesztési környezet, a genotípus és az agrotechnika (menedzsment) között. Az adatok felhasználhatók a modellfejlesztéshez, az agronómiai inputok optimalizálásához és a termés előre jelzéséhez.

A kísérleti adatok fő forrásai a több évtizedes tartamkísérletek, melyek felbecsülhetetlen értékű adatokat szolgáltatnak az AI technológiák mezőgazdasági alkalmazásához. Másrészt több országban ún. georeferált precíziós kísérleteket állítanak be speciális gazdaságokban a termesztési műveletek megszakítása nélkül, korszerű kísérleti elrendezés szerint, felszerelve a precíziós adatszolgáltatáshoz szükséges technikával.

A digitalizáció napjainkban az egyik legjelentősebb trend globálisan. Magában foglalja a digitális technológiai innovációk bevezetését a meglévő rendszerekbe oly módon, hogy megváltozik ezeknek a rendszereknek a működése. A mezőgazdaságnak számos produktivitási és fenntarthatósági előnyt nyújt a digitalizáció a precíz gépesítésen, az automatizáláson és a javított döntéshozatalon keresztül (*Fielke et al. 2020*).

A digitális technológia felhasználását a növénytermesztési kísérletekben három kiemelt kutatási területen mutatjuk be, néhány fontos nemzetközi és hazai kutatási eredmény alapján: (1) növény- és talajtulajdonságok folyamatos monitorozása, (2) termésreakció térbeni és időbeni variabilitásának vizsgálata és (3) gépi tanulás (ML) modellek felhasználása a termés előrejelzésére. Ezt követően rámutatunk néhány hiányos kutatási területre (kutatási rések). Végül adatokat szolgáltatunk a mesterséges intelligenciára épülő, modern tartamkísérletek beállításáról a világ különböző régióban.

*(1) A növény- és talajtulajdonságok folyamatos megfigyelése (monitoring)*

A táblák monitorozását gyakran destruktív vagy labor-intenzív módszerekkel végzik. Újabban nem-invazív módszereket fejlesztettek ki, mint a multi- és hiperspektrális képkezelést vagy lézeres szkennelést, hogy nagyobb teljesítményt kapjanak. Az optikai módszerek pontossága nagyban javult és napjainkban az ember nélküli légi járművek (UAV) mm-alapú felbontóképességgel mérnek, megnyitva a lehetőséget a részletes, növényenkénti monitorozásra, kisskálájú tulajdonságok feltárására, beleértve a növénybetegségek azonosítását. Jelenleg

nincs megfelelő, nagy teljesítményű módszer a nem-invazív gyökérmérésekre, vagy a gyökéreloszlás vizsgálatára (*Storm et al.* 2024).

Folyamatos információ a növény állapotáról alapvető (1) a növénynevelésben, ahol funkcionális és strukturális növénytulajdonságokat kell jellemezni, hogy irányítsuk az ígéretes genotípusok szelekcióját, (2) a növénytermesztésben, ahol a valós idejű információ a növény állapotáról és a tábláról irányítja az agrotechnikai (menedzsment) műveleteket és (3) a növénymodellezésben, ahol vizsgálják az összefüggéseket a források rendelkezésre állása, a fiziológiai folyamatok és az ökoszisztéma szolgáltatások között.

*Storm et al.* (2024) kifejlesztett egy adatfeldolgozási keretrendszert a nitrogén-műtrágyázás valós idejű optimalizálására, felhasználva agroökoszisztéma modelleket, földi és drón alapú távérzékelési adatokat, a növények, gyökerek és a talajok folyamatos földi megfigyelését. Folyamatosan mérik a talaj víztartalmát és a vízpotenciált és adatokat szolgáltatnak valós időben. A drónokkal készített képeket felhasználják a levélterület index és/vagy a biomassa becslésére. A táblán, a magas felbontású növény- és talajadatokat begyűjtik és felhasználják a modellek inputjaként vagy adatfeldolgozásra. A modell felhasználható a növény N-műtrágyázásának optimalizálására, miközben figyelembe veszi az ökoszisztéma szolgáltatásokat (vagy azok hiányát), a bizonytalanságot és a költségeket.

*Széles et al.* (2024) a PA technológia fejlesztésében a SPAD (klorofilltartalom becslése) és UAV-alapú NDVI (normalizált differenciájú vegetációs index) adatokat használta fel a kukoricánövény monitorozására különböző szántóföldi kísérletekben, öntözött és öntözés nélküli körülmények között. A SPAD értékek szignifikánsan emelkedtek minden kezelésben a kukorica V6-V8 fejlettségi fázisától és csökkentek az érési (R1-R3) fázisban. Az öntözés szignifikánsan növelte a SPAD értékeket. Öntözött és öntözés nélküli körülmények között a legnagyobb NDVI értékeket (0,703 és 0,642) a kukorica V12-es, illetve egy későbbi V<sub>n</sub> fejlettségi fázisában (0,728 és 0,662) kapták, 120 kg N/ha műtrágya felhasználásnál. A kukorica szemtermése öntözés nélkül szignifikánsan kisebb (6,26 t/ha) volt, mint öntözés esetén (8,51 t/ha). Egy újabb tanulmányban (*Zagyi et al.* 2024) az alap- és fejtrágyázás, valamint az öntözés hatását eltérő fenológiai fázisokban vizsgálták a levélfelület indexre (LAI) és a kukorica termésére. A legnagyobb LAI értéket a virágzás

körüli  $V_n$  fenológiai fázisban (öntözött kezelésekben 3,074, öntözés nélkül 2,495), 120 kg N/ha műtrágyakezelésnél mérték. A különböző fenológiai fázisokban végzett öko-fiziológiai mérések eredményei feltárták a vizsgált tulajdonságok időbeni dinamikáját az alkalmazott kezelésektől (öntözés, műtrágyázás) függően és kapcsolatukat a termésképződéssel.

*Bretas et al.* (2024) tanulmányozta a tövises disznóparéj (*Amaranthus spinosus* L.) felismerését és feltérképezését csillagpázsit legelőkön, felhasználva a drón képeket és a mély tanulást a hely-specifikus gyomszabályozásban. Az *A. spinosus* világszerte elterjedt gyomfaj a legelőkön (réteken) és nagy inváziós potenciálja miatt kihívást jelent megfelelő szabályozása. A gyomnövények tipikusan nem egyenletes eloszlásúak a táblán, hanem specifikus foltokba koncentrálnak, miáltal a védekezésben a foltpermetezés egy alternatív módszer. A helyspecifikus gyomszabályozás egy stratégia, amely a helyspecifikus mezőgazdaság koncepcióján alapul, és célja a térbeni és időbeni variáció szabályozása a növénytermesztési táblákon. A vezető nélküli járművekről (UAV) nyert képek értékes információt nyújthatnak a gyomtérképezéshez, hogy irányítsuk a herbicid applikációt a legelőkön.

A mesterséges intelligencia, különösen a gépi tanulás (ML) technológiák felhasználhatók gyom felismerésre és gyomtérképek készítésére. A különböző ML technikák közül a mély tanulás (DL) kiemelkedő hatékonyságú a képosztályozásban, a tárgy felismerésben és a képszegmentálásban, összehasonlítva a hagyományos ML technikákkal. Kifejlesztettek egy mély konvolúciós neurális hálózat (CNN) alapú képszegmentálási modellt az U-Net architektúrával, hogy észleljék és feltérképezzék az *A. spinosus* gyomnövényt a csillagpázsit legelőkön, felhasználva az UAV technikával készült vörös-zöldkék képeket. A képeket tizenkét legelőben készítették három kezelésben (gyommentes, gyomos sávok és gyommal fertőzött). A CNN modell képes volt detektálni az *A. spinosus* 80%-át, átlagosan 94%-os előrejelzési pontossággal. A gyomtérképek megmutatták a lehetőségét az U-Net modell használatának egy herbicid applikációs térkép készítésére és a permetező rendszerbe történő beépítésre, miáltal 70%-kal csökkent a herbicid felhasználás.

## (2) A termésreakció térbeni és időbeni variabilitásának vizsgálata

A növények termésreakciója a szabályozható inputokra, mint a vetőmag és a műtrágya, nagymértékű és jól strukturált térbeni variabilitást mutat. Továbbá,

ezeokról a mintázatokról feltételezhető, hogy többé-kevésbé következetesek a különböző években. Tehát a termésreakció függvények ismerete, továbbá megértése azoknak a faktoroknak, amelyek hatással vannak a reakcióra, kulcsfontosságú a szabályozható inputok meghatározásához.

Számos tanulmányban vizsgálták az összefüggést a termés és az időjárás és a helyspecifikus jellemzők között, hogy előre jelezzék a termést vagy kifejlesszenek menedzsment zónákat. A tanulmányok beszámoltak a táblán belüli reakció szignifikáns térbeni és időbeni variabilitásáról. A térbeni variabilitás összefüggött a hely-specifikus faktorok vagy a talajtulajdonságok közötti interakcióval. A bizonytalanság legnagyobb forrása a reakciókban gyakran az időjárási körülmények évek közötti variabilitásával volt kapcsolatban.

*Alesso et al.* (2024) hét georeferált üzemi precíziós kísérletben, 2017 és 2018 években vizsgálta (1) a kukorica (*Zea mays* L.) nitrogéndózisra (NR) és vetőmagdózisra (SR) adott reakciójának táblán belüli térbeni variabilitását, felhasználva a precíziós kísérleti adatokat és a területi szabályozási regresszió (GWR) modelleket, (2) meghatározta a térbeni megegyezést az NR és SR reakció között, és időbeni stabilitásukat, és (3) modellezte az időjárás és a hely-specifikus tulajdonságok hatását a reakciók térbeni eloszlására. A reakció térképeket a GWR modellek illesztésével becsülték a termésre és az alkalmazott NR-re és SR-re. A reakciókat csoportosították pozitív és nem-pozitív reakció osztályokba és térben egyesítették az időjárás, a talaj és a táj kovariánsokkal, hogy lefuttassanak egy random forest (RF, véletlen erdő) ML modellt. A GWR modellek a termésvariáció 30–60%-át értelmezték. A pozitív reakciók az NR-re és SR-re a táblaterületek 46%-át, illetve 33%-át értelmezték, nagy variációval a tábla-év kombinációkban. Az időbeni megegyezés 50–60% volt az NR-re, illetve az SR-re. A térbeni megegyezés az NR és SR reakció osztályok között arra utal, hogy hasonlóak azok a faktorok, amelyek szabályozzák a növény reakcióját ezekre az inputokra. Mindkét esetben, az időjárási változók voltak a legfontosabb előrejelző változók, melyeket a táj- és a talajtulajdonságok követtek.

A távérzékelés a kísérletek folyamatos megfigyelésének hatékony és gyors módszere és lehetővé teszi részletes adatok begyűjtését, biztosítva új lehetőséget a tudományos kutatásban. *Csajbók et al.* (2022) kispárcellás kísérletek multispektrális analizisét hasonlította össze földi és távérzékelési mérésekkel. Kispárcellás kísérletben, őszi zabban (*Avena sativa* L.) többféle földi és légi mérést végeztek, vizsgálva a zabfajták reakcióját a levéltrágya kezelésekre és monitorozták

hatásukat a fiziológiai tulajdonságokra, a produkcióra és a stressz-toleranciára. Mivel a növényállomány spektrális reakcióját befolyásolja a növény egészségi állapota, növekedési stádiuma, az agrotechnikai eljárások és a stresszkörülmények, a kísérlet monitorozása UAV mérésekkel hasznos a növény tápanyag-ellátottságának megközelítő jellemzésére. Szoros pozitív korrelációt állapítottak meg a kézi úton és az UAV technikával mért NDVI (normalizált differenciájú vegetációs index) között. Mind a távérzékeléssel és mind a földi technikával mért paraméterek (SPAD, vegetációs indexek, termés, 1000 magtömeg, stb.) alapján diszkriminancia analízissel el tudták különíteni a zabfajtákat és a trágyakezeléseket. Jóllehet a távérzékelés előnyét a kisparcellás kísérletekben bemutatta a tanulmány, azonban a kézi műszerekkel végzett földi mérésekre változatlanul szükség van.

A gépi tanulás (ML) módszereknek, beleértve a mesterséges neurális hálózatot (ANN), fontos szerepük van a komplex összefüggések feltárásában a spektrális mérések és a növényállomány tulajdonságai között. *Raya-Sereno et al.* (2024) vizsgálta a búza (*Triticum aestivum* L.) genotípusok N-tápanyag- és víz-ellátottságát vegetációs indexekkel (földi hiperspektrális mérésekből), továbbá növénytulajdonságokból (felhasználva ML módszereket) és termálmérésekből származó adatokkal. Szántóföldi kísérletekben két búza genotípus (szárazságra érzékeny és rezisztens) reakcióját vizsgálták, három nitrogénszinten és két öntözési mennyiségnél. A klorofilltartalom és a kombinált vegetációs index adta a legjobb megegyezést a nitrogéntáplálkozási indexszel (NNI) virágzáskor, illetve tejes éréskor, genotípustól függően. A szemtermés jó összefüggést mutatott a vegetációs indexekkel. A legjobb megkülönböztetést a genotípusok teljesítménye között a klorofilltartalom és a levélterület index (LAI) alapján kapták. A vízhiány index (WDI) és a  $T_c - T_a$  (növényállomány hőmérséklete - léghőmérséklet) kimutatta, hogy a szárazságtűrőbb genotípus kevésbé érzékeny a vízhiány-stresszre. Megállapították, hogy a távérzékelés lehetőséget kínál adatok nyerésére a növényteljesítmény korai meghatározásához, amely alapvető a víz- és nitrogénfelhasználás szabályozásához. Az optikai és termál adatok kombinációja javította az agronómiai paraméterek becslését.

### *(3) A termés előrejelzése gépi tanulás (ML) modellekkel*

Az összefüggések megértése a termés, a talajtulajdonságok és az input-alkalmazások között fontos a mezőgazdasági produkció optimalizálásához. Az

adatok variációjának analízise, felhasználva statisztikai és gépi tanulás (ML) megközelítéseket, segíthet azonosítani és megérteni azokat a természetési eljárásokat, melyek optimalizálják a termést.

A termés-előrejelzés kutatása alapvető a jelenlegi mezőgazdasági rendszerekben, minthogy fontos tájékoztatási pontként szolgál a gazdaságmenedzsmentnek a különböző agrotechnikai műveletekhez, így a vetéshez és a tenyészidőszakban végzett eljárásokhoz. A termés optimalizálása a tábla minden részében a precíziós mezőgazdaság (PA) fő célja. A termés előrejelzése fontos az informált döntéshozatalhoz és a PA megvalósításához. Megfelelő előrejelzések nyújtása azonban kihívást jelenthet a sokféle faktornak tulajdoníthatóan, melyek befolyásolják a szükséges inputokat egy táblán a tenyészidőszakban. Ahhoz, hogy elérjük a maximális termést a precíziós agrotechnikai eljárásokon keresztül, először fel kell ismerni a domináns térbeni faktorokat és meg kell érteni kölcsönös kapcsolataikat (*Masenko et al. 2024*).

Egy járható megoldás erre a kihívásra a georeferált kísérletek adatforrásainak alapos és célzott analízise. Fejlett technológiák – mint a változó dózisu vetőgépek, műtrágyaszórók – megjelenése lehetővé tette a helyi specifikus adatok nyerését költséghatékonyan, és utat nyitott új döntéstámogató rendszerek kifejlesztéséhez, melyek kezelni tudnak bonyolultabb és adatintenzív feladatokat, szemben a jelenleg használatban lévő hagyományos rendszerekkel.

Ahhoz, hogy teljesen hasznosítsuk a 'big data' analízist a mezőgazdaságban, szükséges alkalmazni az új tudományos módszertant. A mesterséges intelligencia (AI), különösen a gépi tanulás (ML) technikák, rendkívül fontosakká váltak. Az elmúlt évtizedben az ML módszereket egyre gyakrabban használják a mezőgazdaságban, mivel megvan az a képességük, hogy hatékonyan kezeljék a komplex mezőgazdasági tevékenységeket és képesek analizálni a nemlineáris összefüggéseket, amely pontosabb eredményekhez vezethet. Egyik terület, ahol különösen megnőtt az ML használata, a növények termésének előre jelzése (*Maseko et al. 2024*).

Nagy adatsorozatok segítségével most lehetséges induktív kutatási módszereket alkalmazni és vizsgálni komplex interakciókat a növénytermesztési eljárások, környezeti faktorok és a termés között. Felhasználva az AI adatanalízist, az előrejelzést és az értékelési technikákat, lehetővé válik az informált döntéshozatal a növénytermesztési eljárásokról. A termés

előrejelzésével adott helyen a termelők képesek szabályozni az inputok, mint a műtrágya, felhasználását a növény igénye és a talajvizsgálat alapján.

*Maseko et al. (2024)* georeferált kísérletben összehasonlította a gépi tanulás (ML) modelleket a kukoricatermés előrejelzésében és a termést befolyásoló faktorok azonosításában. A tanulmány célja volt, hogy értékeljék kiválasztott ML modellek előrejelzési pontosságát a kukorica szemtermés becslésében a szántóföldi kísérletekben, különböző vetőmag- és műtrágyadózis kombinációknál és vizsgálják meg az ML modellek képességét a termést korlátozó faktorok azonosításában. Többszörös lineáris regresszió analízist, továbbá a többrétegű perceptron (MLP), a döntési fa és a véletlen erdő (RF) gépi tanulás (ML) modelleket tesztelték, felhasználva növénymenedzsment és talajtulajdonság adatokat az adat-intenzív georeferált kísérletből, valamint távérzékelési adatokat. Az adatsorozat a növény menedzsment, a talajtulajdonságok és a normalizált differenciájú vegetációs index (NDVI) parcella adatait tartalmazta, összekapcsolva a szemterméssel a 2019/2020 és 2020/2021. években. Az RF (véletlen erdő) modell rendelkezett a magas korreláció ( $R^2 = 0,69$  és  $0,80$ ) és alacsony hiba (MAPE =  $5,4$  és  $8,4\%$  és RMSE =  $0,69$  és  $0,95$  t/ha) kombinációjával, amikor összehasonlították a többi modellel. A tulajdonságok fontosságának analízise feltárta, hogy a nitrogén műtrágya volt következetesen a legkritikusabb változó és a legnagyobb mértékben értelmezte a termés variációt, míg a talaj foszfor (P), növényszám és a nátrium 2020-ban, és a talaj P, pH, agyagtartalom és a növényszám volt 2021-ben a legfontosabb faktor a termésingadozás értelmezésében. A tanulmányban arra következtettek, hogy az RF (véletlen erdő) modell volt a legjobb a kukorica térbeni termésének előrejelzésében. Ahhoz, hogy hatékonyan használjuk a termést előrejelző modelleket, kritikus, hogy a modellbe bevont változók szignifikáns kapcsolatban legyenek a terméssel és az eredmények átvihetők legyenek a menedzsment döntésekbe. A georeferált kísérletek, kombinálva ML módszerrel, fontos szerepet játszanak a precíziós mezőgazdaság fejlesztésében azáltal, hogy értékes betekintést nyújtanak a növények, talajok és a menedzsment gyakorlat közötti komplex interakciókba és azonosítanak új lehetőségeket a termés és a környezeti fenntarthatóság növelésére.

*Fiorentini et al. (2023)* négy tartamkísérletben, 16 változó adatainak felhasználásával vizsgálta különböző ML modellek alkalmasságát a durum

búza (*Triticum turgidum* subsp. *durum* Desf.) termés előrejelzésére a fejtrágyázási nitrogén szintek és a távérzékelési adatok alapján. A talaj szerves szén, térfogatsűrűség, 11 különböző N-műtrágyaszint és a vegetációs index (NDVI, NDRE (normalizált differenciájú vörös szegély)) adatokat pilóta nélküli légi jármű (UAV) felhasználásával kapták meg. Négy ML modellt vizsgáltak és a lineáris regresszió modell volt a kontroll. A modellek előre jelezték a durum búza szemtermését, felhasználva kiegészítő adatokat, így a feltalaj fizikai és kémiai tulajdonságait, multispektrális drón képeket, klimatikus adatokat. A négy ML algoritmus közül a „stochasztic gradient boosting” modell volt a legjobb (RMSE= 0,58 t/ha) termés előrejelzésére. A N volt a legfontosabb változó az előrejelzés pontosságának javításában mind a négy ML modell estében. A nitrogénen kívül a modell előrejelzés pontosságának javításában fontos változó volt az átlagos hőmérséklet és a csapadék mennyisége.

Mivel a szójanövények, hüvelyek, mag/hüvely kézi számolása nem megfelelő a szójatermés előrejelzésére, alternatív módszerekre van szükség. *Joshi et al.* (2024) a mesterséges intelligencia és a szatellit alapú távérzékelés felhasználhatóságát vizsgálta a szójatermés (*Glycine max* (L.) Merr.) előrejelzésére. A kísérlet célja volt meghatározni, hogy a szatellit távérzékelés alapú mesterséges intelligencia (AI) modellek felhasználhatók-e a szójatermés előrejelzésére. Több AI modellt vizsgáltak a szójanövény különböző fejlődési fázisaiban, a keléstől (VE/VC) az érés kezdetéig (R6/R7). Megállapították, hogy a távérzékelés alapú mesterséges intelligencia (AI) modellek képesek becsülni a szójatermést. A vizsgált AI technikák közül a mély neurális hálózat (DNN: deep neural network) általában a termésvariabilitás nagy részét értelmezte. A termés előrejelzések javultak a begyűjtött szatellit képek kombinálásával több növekedési stádiumban.

### **Kutatási rések és kitekintés**

Az okos digitális technológiák kifejlesztése és bevezetése a mezőgazdasági gyakorlatba szükségessé teszi a fő kutatási rések (gaps) zárását, melyek különösen összefüggnek (1) a multi-skálájú multi-szenzoros monitoring hasznosításával térben és időben, (2) a folyamat alapú és a gépi tanulás (ML) módszerek kombinálásával, (3) a döntéshozatalnak és a növénytermesztésbe történő beavatkozásnak a javításával, és végül (4) a termelők általi elfogadás

körülményeinek és következményeinek vizsgálatával (*Storm et al. 2024*). Ezeknek a réseknek a zárása interdiszciplináris megközelítést indokol. Az együttműködés megvalósításához szükség van stratégiai kutatási programokra (közös kísérleti program és központi adatbázis, interdiszciplináris oktatás és intézményi együttműködés és hálózat).

Ahhoz, hogy megvalósítsuk a forrásfelhasználás hatékonyságát és optimalizáljuk a menedzsment (agrotechnikai) döntéseket, képesnek kell lenni lokalizálni, felismerni és kezelni egyes táblafoltokat, táblarészeket és ideálisan egyetlen növényt a megcélzott módon. A döntéshozatal javítása magában foglalja a tábla elrendezést, a növényfaj- és fajtaválasztást, a vetésidőt, a műtrágyázást, az öntözést, valamint a gyomnövények, kártevők és betegségek szabályozását. Ideálisan ezek a döntések az eredmény (mint a potenciális termés vagy ökológiai szolgáltatások) előrejelzésén alapulnak, beavatkozásokkal vagy nélkülük, alternatívákon keresztül, és a bizonytalanság becslésével. A modell alapú menedzsmentdöntések szükségessé tesznek egy integrált multi-skálájú megközelítést, hogy modellezzük a növény növekedését a talaj-növény-légkör változók és fluxusok valós idejű méréseivel és az adatfeldolgozási módszerekkel egy integrált működési keretben.

Az ML/AI technológiáknak megvan a lehetőségük, hogy segítsék megvalósítani a precíziós gazdálkodást olyan algoritmus kialakításával, amely egyedülálló módon megfelel a specifikus gazdaságoknak és termőhelyeknek. Az ML intelligens előrejelzéseket készít azáltal, hogy megtalál komplex mintázatokat a nagy adatsorozatokban. Ezek az algoritmusok rendkívül pontosak lehetnek, mivel tanulnak és módosítják magukat, ahogy az adatok összegyűlnek.

Az előnyök ellenére azonban számos akadály van az ML/AI technológiák elfogadásának, beleértve a költségeket, és azt, hogy a termelők vonakodhatnak attól, hogy elfogadjanak egy olyan döntési formát, melyet nem ismernek (*Clay et al. 2024*). Az AI felhasználásának számos akadályát figyelték meg a precíziós mezőgazdaságban (*Gardezi et al. 2024*). Ezek magukba foglalják a gazdálkodók aggodalmát amiatt, hogy kinek a tulajdonában lesznek az adatok és kinek lesz hozzáférése a gazdasági adatokhoz, hogyan lesz tárolva az információ a gazdálkodási eljárásokról. Az ilyen kérdések elválaszthatatlanul kapcsolódnak az AI etikai kihívásaihoz.

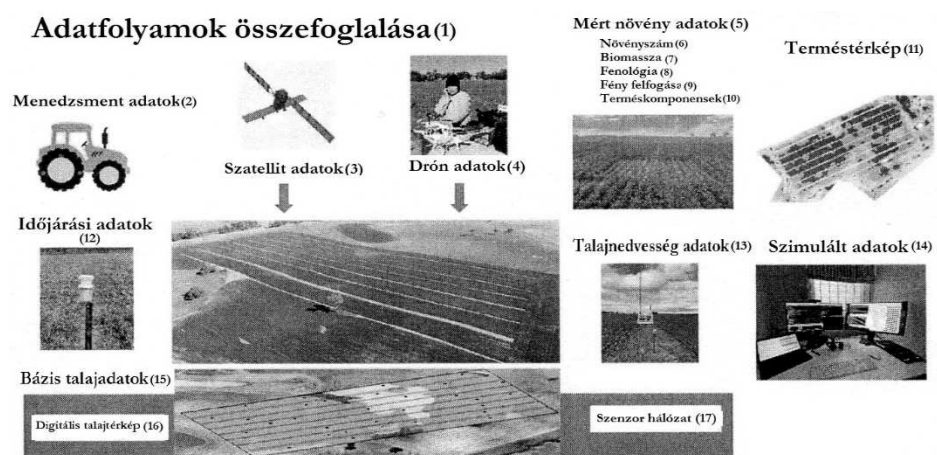
### Újabb tartamkísérletek digitális technológiával

A mezőgazdasággal szembeni új kihívások szükségessé tették a növénytermesztési tartamkísérletek új generációjának tervezését, amely a termesztési rendszert tekinti a kutatás egységének, és összehasonlítja az alternatív rendszerek teljesítményét többféle kritérium alapján. A kutatás kimutatja a menedzsment (agrotechnikai) változás direkt és indirekt hatásait a többféle eredményre (output). Ezek lehetnek additív, szinergista vagy antagonistista reakciók, különböző térbeni és időbeni skálán. Nem valószínű, hogy csak egyetlen optimális megoldás lenne, sokkal inkább alternatív menedzsment pályák komplex sorozata fordul elő. Ilyen okból nem lehet elérni optimális megoldást a hagyományos faktoriális kezelés megközelítés alapján.

2017-ben és 2018-ban, két eltérő helyen a Rothamsteddi Kutatóintézetben (UK) állítottak be – a fenti alapelveknek megfelelően – egy modern tartamkísérletet (Large Scale Rotation Experiment, LSRE), amely négy menedzsmentfaktort tartalmaz. Ezek a faktorok kombinálva vannak egy kiegyensúlyozott elrendezésben, eredményezve 24 növénytermesztési rendszert mindegyik helyen, a jelenlegi és a jövőbeni mezőgazdasági rendszerek kihívásaira fókuszálva. A kísérletek analizálhatók a rendszer szintjén vagy a komponens menedzsment faktorok szintjén (*Li et al. 2023*).

Az AI felhasználása a növénytermesztési kísérletekben még korai kutatási stádiumban van, azonban egyre több kísérletet állítanak be a digitális technológia alkalmazásával a világ különböző részein. Ausztráliában 2021-ben egy új, a digitális kor igényeinek megfelelő termesztési rendszer kísérletet állítottak be 290 ha területen (Boorowa Agricultural Research Station, BARS) (*Kirkegaard 2023*). A mesterséges intelligencia korszerű eszközeivel és eljárásaival megfigyelik a talajt és a növényállományt, hogy (i) választ adjanak az elkövetkező 10–20 év fontos növénytermesztési kihívásaira, (ii) összehasonlítsák négy különböző termesztési rendszer paramétereit, (iii) alkalmazzák a digitális technológiákat, (iv) számba vegyék az ökoszisztéma szolgáltatásokat/fogyasztók aggodalmait, (v) bevonják a termelőket a kutatás és az innováció folyamatába. Az adatképzés, az adatáramlás és az adatfeldolgozás folyamatát a tartamkísérletben a 3. ábra szemlélteti.

3. ábra. Az adatáramlás és adatfeldolgozás folyamata az új termesztési rendszerek tartamkísérletben Ausztráliában



Forrás: Kirkegaard (2023)

Figure 3. Summary of data streams and data processing in the new Australian long term crop systems experiment. (1) Summary of data streams, (2) Management data, (3) Satellite data, (4) Drone data, (5) Measured crop data, (6) Plant population, (7) Biomass, (8) Phenology, (9) Light interception, (10) Yield components, (11) Yield map, (12) Weather data, (13) Soil water data, (14) Simulated data, (15) Baseline soil data, (16) Digital soil map, (17) Sensor network, Source: Kirkegaard (2023)

## IRODALOM

- Alesso, C. A.–Martin, N. F.: 2024. Spatial and temporal variability of corn response to nitrogen and seed rates. *Agron. J.* 116: 897–916.
- Balla I.–Milics G.–Deákvári J.–Fenyvesi L.–Neményi M.–Jolánkai M.: 2011. Talajnedvesség meghatározás fajlagos elektromos vezetőképesség alapján a precíziós mezőgazdaságban. *Növénytermelés.* 60. 4: 5–25.
- Berzsenyi Z.: 2024. Fenntartható növénytermesztés. MATE Egyetemi Szolgáltató Nonprofit Kft. Gödöllő.
- Bretas, I. L.–Dubeux Jr., J. C. B.–Zhao, C.–Queiroz, L. M. D.–Flynn, S.–Ingram, S.–Oduor, K. T.–Cruz, P. J. R.–Ruiz-Moreno, M.–Loures, D. R. S.–Valente, D. S. M.–Chizzotti, F. H. M.: 2024. Detection and mapping of *Amaranthus spinosus* L. in bermudagrass pastures using drone imagery and deep learning for a site-specific weed management. *Agron. J.* 116: 900–1002.

- Clay, D. E.–Brugler, S.–Joshi, B.: 2024. Will artificial intelligence and machine learning change agriculture: A special issue. *Agron. J.* 116: 791–794.
- Csajbók, J.–Budai-Bódi, E.–Nagy, A.–Fehér, Zs. Z.–Tamás, A.–Virág, I. Cs.–Bojtor, Cs.–Forgács, F.–Vad, A. M.–Kutassy, E.: 2022. Multispectral analysis of small plots based on field and remote sensing surveys – A comparative evaluation. *Sustainability.* 14: 3339.
- Fielke, S.–Taylor, B.–Jakku, E.: 2020. Digitalisation of agricultural knowledge and advice networks: A state-of-the-art review. *Agricultural Systems.* 180: 102763.
- Fiorentini, M.–Schillaci, C.–Denora, M.–Zenobi, S.: 2024. A machine learning modelling framework for *Triticum turgidum* subsp. *durum* Desf. yield forecasting in Italy. *Agron. J.* 116: 1050–1070.
- Gaál M.–Illés I.: 2020. A precíziós szántóföldi növénytermesztés helyzete és ökonómiai vizsgálata. NAIK Agrárgazdasági Kutatóintézet. Budapest.
- Gardezi, M.–Joshi, B.–Rizzo, D. M.–Ryan, M.–Prutzer, E.–Brugler, S.–Dadkhah, A.: 2024. Artificial intelligence in farming: Challenges and opportunities for building trust. *Agron. J.* 116: 1217–1228.
- Harsányi, E.–Bashir, B.–Arshad, S.–Ocwa, A.–Vad, A.–Alsalman, A.–Bácskai, I.–Rátonyi, T.–Hijazi, O.–Széles, A.–Mohammed, S.: 2023. Data mining and machine learning algorithms for optimizing maize yield forecasting in Central Europe. *Agronomy.* 13: 1297.
- Javaid, M.–Haleem, A.–Khan, I. H.–Suman, R.: 2023. Understanding the potential application of artificial intelligence in agricultural sector. *Advanced Agrochem.* 2: 15–30.
- Joshi, D. R.–Clay, S.–Sharma, P.–Rekabdarkolace, H. M.–Kharel, T.–Rizzo, D. M.–Thapa, R.–Clay, D. E.: 2024. Artificial intelligence and satellite-based remote sensing can be used to predict soybean yield. *Agron. J.* 116: 917–930.
- Kirkegaard, J.: 2023. A contemporary long-term farming systems experiment for the digital age. Előadás. Long-term experiments: Meeting future challenges. Conference. Rothamsted Research. Harpenden. UK. 20<sup>th</sup> – 22<sup>nd</sup> June 2023.
- Kremen, C.–Iles, A.–Bacon, C.: 2012. Diversified farming system: An agroecological, system-based alternative to modern industrial agriculture. *Ecology and Society.* 17. 4: 44.
- Li, X.–Storkey, J.–Mead, A.–Shield, I.–Clark, R.–Ostler, R.–Roberts, B.–Dobermann, A.: 2023. A new Rothamsted long-term field experiment for the twenty-first century: principles and practice. *Agronomy for Sustainable Development* 43: 60.
- Maseko, S.–van der Laan, M.–Tesfamariam, E. H.–Delpont, M.–Otterman, H.: 2024. Evaluating machine learning models and identifying key factors influencing spatial maize yield predictions in data intensive farm management. *Europ. J. Agron.* 157: 127193.

- Milics G.*: 2008. A térinformatika és a távérzékelés alkalmazása a precíziós (helyspecifikus) növénytermesztésben. PhD értekezés. Pécsi Tudományegyetem Természettudományi Kar Földtudományok Doktori Iskola.
- Nagy J.-Búvár G.*: 2022. Precíziós növénytermesztés Magyarországon. Növénytermelés. 71. 3-4: 105-118.
- Nath, S.*: 2024. A vision of precision agriculture: Balance between agricultural sustainability and environmental stewardship. *Agron. J.* 116: 1126-1143.
- Németh T.-Neményi M.-Harnos Zs.*: 2007. A precíziós mezőgazdaság módszertana. JATE Press - MTA TAKI. Szeged.
- Nyéki, A.-Milics, G.-Kovács, A. J.-Neményi, M.*: 2017. Effects of soil compaction on cereal yield. A review. *Cereal Res. Commun.* 45: 1-22.
- Raya-Sereno, M. D.-Camino, C.-Pancorbo, J. L.-Alonso-Ayuso, M.-Gabriel, J. L.-Beck, P. S. A.-Quemada, M.*: 2024. Assessing wheat genotype response under combined nitrogen and water stress scenarios coupling high-resolution optical and thermal sensors with radiative transfer models. *Europ. J. Agron.* 154: 127102.
- Storm, H.-Seidel, S. J.-Klingbeil, L.-Ewert, F.-Vereecken, H.-Amelung, W.-Behnke, S.-Bennewitz, M.-Böner, J.-Döring, T.-Gall, J.-Mahlein, A. K.-McCool, C.-Rascher, U.-Wrobel, S.-Schnepf, A.-Stachniss, C.-Kuhlmann, H.*: 2024. Research priorities to leverage smart digital technologies for sustainable crop production. *Eur. J. Agron.* 156: 127178.
- Széles, A.-Huzsvai, L.-Mohamed, S.-Nyéki, A.-Zagyi, P.-Horváth, É.-Simon, K.-Arshad, S.-Tamás, A.*: 2024. Precision agricultural technology for advanced monitoring of maize yield under different fertilization and irrigation regimes: A case study in Eastern Hungary (Debrecen). *Journal of Agriculture and Food Research.* 15. 100967: 1-16.
- Zagyi P.-Horváth É.-Tamás A.-Simon K.-Széles A.*: 2024. Az alap- és fejtrágyázás, valamint az öntözés hatása a levélfelület indexre és a termés mennyiségére kukoricaállományban. *Növénytermelés.* 73. 2: 101-118.

A szerző levelezési címe – Address of the authors:

Dr. Berzsenyi Zoltán  
HUN-REN  
Agrártudományi Kutatóközpont  
Martonvásár  
Brunszvik u. 2.  
H-2462  
profberzsenyi.zoltan@gmail.com