

SZEMLE**Review****Mesterséges intelligencia (MI) a precíziós mezőgazdaságban**

DOROGHÁZI OTTÓ

Debreceni Egyetem Kerpely Kálmán Doktori Iskola, Debrecen

Összefoglalás

A mesterséges intelligencia (MI) alapú technológiák az agrárium új korszakát nyitják meg, különösen a precíziós mezőgazdaság területén. A tanulmány célja, hogy szemléletes áttekintést adjon arról, miként alkalmazható az MI a hozambecslésben, a növényállapot-monitorozásban és a kártevők, betegségek előrejelzésében. A vizsgált kutatások alapján világossá válik: azok az országok és gazdálkodók, akik időben felismerik ezen technológiák jelentőségét, hosszú távon versenyelőnybe kerülnek.

A tanulmány rávilágít arra, hogy a magyar mezőgazdaság is egyre inkább kiszolgáltatottá válik az időjárási szélsőségeknek, munkaerőhiánynak és a piaci nyomásnak. A korszerű MI-alapú eszközök automatizálják a döntéseket, emelt pontosabb, gyorsabb és költséghatékonyabb termelést is lehetővé tesznek. Ehhez azonban nemcsak eszközök kellene, hanem érthető tudásanyag, gyakorlati példák és esettanulmányok, amelyek megmutatják, hogyan működik ez magyarországi körülmények között.

A jövő kulcsa tehát nem pusztán a technológiában, hanem a megértésben rejlik. Ezért is elengedhetetlen az áttekintő munkák szerepe, amelyek hidat képeznek a tudomány és a gazdálkodói gyakorlat között. A dolgozatban bemutatott módszerek, algoritmusok és adatelemzési példák alapot adhatnak hazai esettanulmányok és döntéstámogató rendszerek kidolgozásához, amelyek közvetlenül segítik majd a termelőket a gyakorlati döntéseikben.

Kulcsszavak: mesterséges intelligencia, precíziós mezőgazdaság, agrárdigitalizáció, hozambecslés, növényi stressz, döntéstámogatás

Artificial Intelligence (AI) in precision agriculture

O. DOROGHÁZI

University of Debrecen, Kerpely Kálmán Doctoral School, Debrecen

Summary

Artificial Intelligence (AI) is opening a new era in agriculture, particularly in the field of precision farming. This paper aims to provide an insightful overview of how AI technologies can be applied to yield prediction, crop health monitoring, and early pest and disease detection. Findings from international research clearly indicate that those countries and producers who adopt these tools early will gain a long-term competitive advantage.

The Hungarian agricultural sector faces increasing challenges: climate change, labor shortages, and market pressure. AI-based tools offer solutions through automation, precision, and cost efficiency. However, implementation requires not only access to technology but also a clear understanding, practical examples, and local case studies that demonstrate how AI works under Hungarian conditions and supports Hungarian farmers.

The future lies not only in technology but in its comprehension. Therefore, review articles like this one play a key role in bridging the gap between science and farm-level decision-making. The methods and models discussed here provide a foundation for developing domestic case studies and decision-support systems that directly benefit farmers in their everyday operations.

Key words: artificial intelligence, precision agriculture, yield forecasting, digital farming, crop stress, decision support

Bevezető

A precíziós mezőgazdaság, más néven okos mezőgazdaság vagy digitális mezőgazdaság, jelentős fejlődést eredményezett a hagyományos gazdálkodási módszerekhez képest (*Fountas et al.* 2020, *Padhiary et al.* 2024, *Thotho és*

Macheso 2024). Ez egy adatvezérelt megközelítés, amely korszerű technológiák alkalmazásával segíti a mezőgazdasági tevékenységek hatékonyságának növelését (*Thotho és Macheso* 2024). Elsődleges célja a terméshozam maximalizálása mellett az erőforrás-felhasználás (pl. a víz, műtrágya, vetőmag és növényvédőszer) minimalizálása (*Mustafa et al.* 2021, *Madhumathi et al.* 2022, *Padhiary et al.* 2024). Ezt úgy éri el, hogy az inputokat pontosan a szükséges helyre, időben és megfelelő mennyiségben juttatja ki, alkalmazkodva a helyi természeti adottságokhoz, ezáltal hozzájárulva a globális élelmezésbiztonság garantálásához. A megközelítés magában foglalja az adatok gyűjtését, feldolgozását és elemzését annak érdekében, hogy megalapozott, adatvezérelt döntések szülessenek (*Padhiary et al.* 2024).

A mesterséges intelligencia (MI) a precíziós mezőgazdaság egyik alappillére, és az egyik legfontosabb technológia fejlődésének motorja (*Devapitchai et al.* 2024, *Thotho és Macheso* 2024). Az olyan MI-technológiák, mint a robotika, a mélytanulás, az IoT (dolgozók internete), a gépi tanulás (ML) és a képfeldolgozás, központi szerepet játszanak a mezőgazdasági szektor fenntarthatóságának elősegítésében és a termelékenység növelésében (*Neményi* 2018, *Devapitchai et al.* 2024, *Thotho és Macheso* 2024).

Az optimalizáláson túl a mesterséges intelligencia alkalmazásával a mezőgazdasági műveletek automatizálása is lehetővé válik (*Devapitchai et al.* 2024). A számítógépes látással felszerelt robotok képesek szelektív betakarításra vagy gyomirtásra, továbbá az MI-alapú rendszerek nagy pontossággal és hatékonysággal automatizálhatják a vetést, permetezést vagy betakarítást (*Lockie et al.* 2020, *Shaikh et al.* 2022). Ezt a precíziós gazdálkodás során keletkező hatalmas mennyiségű adat (dokumentált, georeferált adat) keletkezése teszi lehetővé. Amelyek szenzorokból, drónokból, műholdakból, betakarítási gépekből és más forrásokból (*Shafi et al.* 2019, *Madhumathi et al.* 2022) származnak. Az MI-algoritmusok ezekből az adatokból döntéstámogató információkat nyernek ki, például a táblán belüli heterogenitás feltérképezéséhez (*Case-Cohen* 2018, *Murugamani et al.* 2022).

Emellett a mesterséges intelligencia lehetőséget nyújt prediktív modellek alkalmazására, amelyekkel előre jelezhetők a hozamok, azonosíthatók a betegségek és kártevők korai stádiumban, valamint előrejelzhetők az időjárási mintázatok (*Kowalska és Ashraf* 2021, *Batz et al.* 2023). Ezek révén a gazdák megelőző intézkedéseket tehetnek a potenciális problémák

kezelésére (Malhotra és Firdaus 2022, Chibuye és Phiri 2023, Ramteke és Kshirsagar 2023). Az MI-eszközök gyors adatfeldolgozási képességük révén időszerű javaslatokat adnak, támogatva a pontosabb és gyorsabb döntéshozatalt (Thotho és Macheso 2024).

Az erőforráshatékonyság terén az MI képes meghatározni a növény pontos vízigényét, így az öntözés csak akkor történik, amikor valóban szükséges (Devapitchai et al. 2024, Alahmad et al. 2025). Hasonló módon a növényvédőszer- és műtrágya-felhasználás is optimalizálható, csökkentve a túlhasználatot és a környezeti terhelést (Talaviya et al. 2020, Thorat et al. 2020). Ezzel javul az erőforrások elosztása, növekszik a hatékonyság és a terméshozam, miközben csökkennek a költségek. Kutatások szerint az MI akár 15–20%-kal növelheti a terméshozamot, 25–30%-kal mérsékelheti a befektetési költségeket, és 20–25%-kal javíthatja a gazdálkodás hatékonyságát (Padhiary et al. 2024).

Az MI a mezőgazdasági kihívások, például a betakarítási nehézségek, klímakockázatok, növényi betegségek és kártevők elleni védekezés, valamint a munkaerőhiány kezelésében is fontos szerepet játszik (Devapitchai et al. 2024). Összességében a mesterséges intelligencia képes a precíziós mezőgazdaságban keletkező adatokból hasznos, cselekvésre alkalmas tudást előállítani, támogatva az autonóm és félautonóm műveleteket. Ennek eredményeként a mezőgazdaság pontosabbá, hatékonyabbá, fenntarthatóbbá, termelékenyebbé és ellenállóbbá válik (Thotho és Macheso 2024).

A precíziós gazdálkodás adatvezérelt alapjai

Az adatok szerepe és értéke a precíziós gazdálkodásban

A precíziós mezőgazdaság adatvezérelt megközelítést alkalmaz, melynek keretében az olyan technológiák, mint az IoT (Internet of Things, dolgok internete), szenzorok, drónok és műholdak segítenek optimalizálni a mezőgazdasági gyakorlatokat (Amarasingam et al. 2022). Ezek az eszközök hatalmas mennyiségű adatot gyűjtenek többek között a talajállapotról, a növénynövekedésről, az időjárási viszonyokról, hőmérsékletről, páratartalomról, csapadékról, talaj pH-ról és a napsugárzás intenzitásáról (Vasudevan és Karthick 2024).

Az MI-algoritmusok ezeket a nagymennyiségű adatokat elemzik mintázatok és összefüggések felismerése céljából, prediktív modelleket építenek, és értékes betekintéseket nyújtanak számos mezőgazdasági feladathoz (*Amarasingam et al. 2022*).

A távérzékelés (RS) kiemelt jelentőségű technológia a térbeli információk mezőgazdasági felhasználásában, lehetővé téve az erőforrások pontos kezelését és a terméshozam maximalizálását (*Navalgund et al. 2007*). A műholdak, repülőgépek és pilóta nélküli légitjárművek (UAV-k) kulcsfontosságú RS-eszközök, amelyek naprakész adatokat szolgáltatnak a növényállapotról, fejlődési mintázatokról és a környezeti változásokról (*Sishodia et al. 2020*).

A Sentinel-2 műholdak a nagyfelbontású multispektrális képalkotás és a rövid visszatérési idő révén napjainkban nélkülözhetetlen adatforrássá váltak a precíziós mezőgazdaságban. A műholdas távérzékelés lehetővé teszi a növényállomány egészségi állapotának, a talajfelszín jellemzőinek és a víztartalom változásainak folyamatos, nagy területekre kiterjedő nyomon követését, ami alapvető a megbízható hozambecslés és a növényfejlődési szakaszok értékelése szempontjából (*Revel et al. 2019, Desloires et al. 2023*).

A távérzékelés ugyanakkor gyakran kiegészíti tésre szoruló közeli, helyszíni mérésekkel, amelyek pontosítják és validálják a műholdakról nyert adatokat. Ilyen kiegészítő módszer a felület alatti talajvizsgálat, különösen a talajszkenner alkalmazása. Ezek az eszközök a talaj fizikai és kémiai tulajdonságait mérik közvetlenül a helyszínen. Ezek működhetnek kontakt vagy nemkontakt, illetve aktív vagy passzív elven is (*Ragán et al. 2021*). A műholdas és talajszkenneres adatok kombinációja lehetővé teszi a felszíni és mélyebb talajrétegek állapotának integrált értékelését, ami jelentősen növeli a precíziós gazdálkodási döntések megalapozottságát.

Míg a hagyományos távérzékelési és talajadat-feldolgozási módszerek gyakran idő- és munkaerő-igényesek, a mesterséges intelligencia – különösen a gépi tanulási (ML) és mélytanulási (DL) technikák – alkalmazása forradalmasította ezeket a folyamatokat. Az MI-algoritmusok képesek a műholdakról, drónokról és talajszkennerből származó nagy mennyiségű, heterogén adathalmaz gyors és pontos elemzésére, ezáltal új szintre emelve a precíziós mezőgazdaság adatvezérelt döntéstámogatását.

MI-alapú terméshozam-előrejelzés

Hozambecslés módszertana

A terméshozam előrejelzése a mezőgazdasági termelés egyik kulcsfontosságú eleme, mivel lehetővé teszi a gazdálkodók számára, hogy megalapozott döntéseket hozzanak az erőforrások optimális elosztásáról, a növénytermesztési gyakorlatok megválasztásáról és a piaci stratégiák kialakításáról (*Zhang et al. 2023*). A mesterséges intelligencia (MI) alkalmazásai napjainkban képesek pontos és valós idejű hozambecsléseket készíteni, nagyméretű és sokféle adatforrás – például műholdfelvételek, talajállapot- és növényegészségügyi mutatók – integrált felhasználásával (*Aslan et al. 2024*).

A gépi tanulási (ML) algoritmusok e heterogén adatállományokat feldolgozva képesek feltárni azokat az összefüggéseket és mintázatokat, amelyeket a hagyományos statisztikai módszerek gyakran nem tudnak megfelelően kezelni (*Aslan et al. 2024*). A több évre kiterjedő hozamtérképes adatok feldolgozása különösen értékes, mivel lehetővé teszi az évjáráthatás számszerűsítését és a hozamok stabilitásának objektív értékelését (*Ragán et al. 2023*).

Alkalmazott technikák, adatforrások és kiemelt kutatások a hozambecslésben

A hozambecsléshez széles körben alkalmaznak gépi tanulási (ML) és mélytanulási (DL) modelleket, például támogatott vektorgépeket (SVM), döntési erdőket (Random Forest – RF) és boostolt regressziókat (*Aslan et al. 2024*). Ezeket a módszereket többek között búza, rizs, kávé, kukorica és szója termésének előrejelzésére használták.

Az adatforrások közé tartoznak a műholdképek (pl. Sentinel-2, Landsat, PlanetScope), UAV-alapú multispektrális felvételek, környezeti adatok, gazdálkodási gyakorlatok, valamint történeti és valós idejű adatsorok. A vegetációs indexek (NDVI, EVI, GNDVI, GCVI) különösen fontosak a növényzet sűrűségének és egészségi állapotának nyomon követésében (*Kayad et al. 2019, Desloires et al. 2023*).

– Sentinel-2 alapú hozambecslés

Aslan et al. (2024) Sentinel-2 adatok felhasználásával több MI-modell teljesítményét vizsgálta.

A kukorica hozambecslésében *Kayad et al.* (2019) RF, SVM és MLR modelleket hasonlítottak össze. A Random Forest bizonyult a legpontosabbnak, a GNDVI pedig volt a legpontosabb növényi index a parcellán belüli variabilitás nyomon követésére.

Nepálban, több időpontban készült Sentinel-2 felvételek és 3D CNN modell felhasználásával próbálták a rizs hozamát előrejelezni. A kutatás alapján a CNN felülmúlta a hagyományos ML-megoldásokat a rizs hozambecslésében (*Fernandez-Beltran et al.* 2021).

Őszi búza esetében Sentinel-2 és figyelemalapú 1D-CNN kombináció jobb teljesítményt nyújtott, mint az önálló 1D-CNN vagy RF modellek (*Xiao et al.* 2024).

– Műholdas adatok fúziója és integrációja

Sentinel-2 és PlanetScope adatok kombinációjával DNN és ML-alapú modellek lényegesen pontosabb szójatermés-előrejelzést adtak, mint az egyedi műholdak adatai külön-külön (*Amankulova et al.* 2023).

– Modellösszehasonlítások és új algoritmusok

Kukorica hozambecslésében Sentinel-2 idősoros spektrális és hőmérsékleti adatok felhasználásával a STACK modell bizonyult a legjobbnak több algoritmus (RR, RF, SVR, MLP, XGBoost) közül (*Desloires et al.* 2023).

Szőlőtermesztésben N-szintű CNN modellt kombináltak meteorológiai, talaj- és növényparaméterekkel, amely a hozambecslés mellett betegségdetektálásra is alkalmas volt (*Aslan* 2023).

– Folyamatmodellezés és ML integrációja

A CERES-Maize modell a kukorica növekedését és fejlődését szimulálta, talaj-, időjárási és termesztéstechnológiai adatok bevonásával (*Zelenák et al.* 2022).

– Talaj- és meteorológiai adatok szerepe

Tér- és időbeli talaj-, domborzati és meteorológiai adatok elemzésekor az XGBoost bizonyult a legeredményesebbnek (AUC=97,5%), kiemelve a talajtermékenység térbeli eloszlásának szerepét (*Nyéki et al.* 2021).

A Gradient Boosting Regressor (GBR) modell csökkent adatmennyiség mellett is pontos talajnedvesség-előrejelzést adott, mérsékelve a terepi

mintavételezés igényét és javítva a vízfelhasználás és öntözés menedzsmentjét (*Alahmad et al. 2025*).

A kukorica növekedésének és biomasszájának előrejelzésére a Gradient Boosted Trees (GBT) modellt alkalmazták Sentinel-2 műholdfelvételek és IoT-alapú talajnedvesség-, hőmérséklet- és páratartalom-adatok integrációjával, amely $R^2 > 0,9$ pontosságot ért el, és a SHAP-elemzés kimutatta, hogy az NDVI, a talajnedvesség és a hőmérséklet voltak a legfontosabb prediktorok (*Nyéki et al. 2024*).

A hozambecslés kihívásai

A technológiai fejlődés ellenére a hozambecslés továbbra is kihívásokkal küzd:

- Skálázhatóság és általánosíthatóság hiánya: egyes modellek csak meghatározott környezetekben működnek megfelelően (*Aslan et al. 2024, Manzoor 2024*).
- Modellösszetettség és adatminőség problémák.
- Validációs hiányosságok: sok modell nem esik át alapos validáción eltérő földrajzi régiókban.
- Módszertani különbségek: Az azonos növényfajokra alkalmazott eltérő vegetációs indexek és AI-módszerek megnehezítik az eredmények összehasonlíthatóságát (*Aslan et al. 2024*).
- Továbbá a modellek többsége főként RS-adatokra épül, miközben gyakran figyelmen kívül hagyják az olyan környezeti tényezőket, mint a talajnedvesség, a tápanyagszint vagy az öntözési adatok.

Növényállapot-monitorozás mesterséges intelligenciával

Az MI-alapú növényállapot-monitorozás lehetővé teszi a gazdálkodók számára, hogy valós idejű betekintést nyerjenek a növények egészségi állapotába, a talajviszonyokba és a kártevők aktivitásába. Ennek célja a gyors reagálást lehetővé tevő, proaktív gazdálkodási stratégiák alkalmazása (*Aslan et al. 2024*). *Sári-Barnácz et al. (2023)* Sentinel-2 és Landsat 8 adatok MI-alapú elemzésével – K-means klaszterezéssel és lineáris regresszióval – értékelte a gyapottokmányos lepke (CBW) kukoricafülön okozott kártételét. A módszer kimutatta a különböző érési csoportok eltérő korrelációs mintázatait, a

Sentinel-2 látható sávjai pedig a legpontosabb becslést adták, alapot nyújtva a CBW előrejelzéséhez.

Monitorozási technológiák és adatok

Az MI-algoritmusok műholdfelvételek és távérzékelési adatok elemzésével követik nyomon a növények egészségi állapotát nagy területeken. Az NDVI és más vegetációs indexek révén az MI képes felmérni a növényi vitalitást és korán azonosítani a stresszfaktorokat. A távérzékelési technikák kombinálva az MI-vel képesek olyan elváltozásokat észlelni, amelyeket szabad szemmel nem lehet észrevenni pl. vízihiányt hőkamerás felvételek, vagy tápanyaghiányt multispektrális képalkotás segítségével (Aslan et al. 2024).

További adatforrások közé tartoznak az IoT-eszközök, talaj- és növény szenzorok, valamint drónok, amelyek valós idejű adatokat szolgáltatnak a talajállapot, kultúrnövény növekedési dinamikák és időjárási tényezők vonatkozásában (Aslan et al. 2024, Vasudevan és Karthick 2024).

A növényállapot-felmérés előnyei

Az MI jelentősen javítja az adatelemzés pontosságát és sebességét a hagyományos módszerekhez képest, így valós idejű döntéstámogatást biztosít. A folyamatos monitorozás révén a termelők képesek fenntartani az optimális növekedési feltételeket, ami végső soron hozzájárul a hozam maximalizálásához (Aslan et al. 2024).

Egy gyakorlati példa: a Taranis nevű rendszer nagy felbontású légi felvételeket és mesterséges intelligenciát használ a növényállomány állapotának elemzésére. Képes levélszintű pontossággal észlelni a kártevőfertőzéseket, növénybetegségeket és tápanyaghiányt (Aslan et al. 2024).

Betegségek felismerése és kártevők elleni védekezés

Kórokozók és kártevők detektálása MI-vel

A növénybetegségek és kártevők korai felismerése és kezelése alapvető fontosságú a jelentős terméskiesések megelőzése és a fenntartható mezőgazdasági gyakorlatok biztosítása érdekében (Manzoor 2024, Vasudevan és Karthick 2024). A mesterséges intelligencia kulcsszerepet tölt

be e területen, mivel képes automatizálni és pontosítani a diagnózist (*Monika et al. 2025*).

Technológiák és adatok a növényvédelemben

Az MI-rendszerek történeti adatok, időjárási mintázatok, valós idejű monitorozás és képfelvételek alapján képesek azonosítani és előre jelezni a kártevőfertőzéseket és betegségeket (*Monika et al. 2025*). A gépi tanulási (ML) és mélytanulási (DL) technikák közül a leggyakrabban használtak a YOLO-alapú objektumfelismerés, konvolúciós neurális hálók (CNN-ek), hiperspektrális képalkotás, gépi látás (machine vision) és az SVM (támogatott vektorgép) osztályozók. Az adatforrások közül a legfontosabbak az UAV-alapú távérzékelés, a multispektrális képek, a műholdfelvételek, a növényállományról és levelekről készült fotók, valamint az időjárási és környezeti adatok (*Sishodia et al. 2020, Vasudevan és Karthick 2024*).

Ezek a technológiák számos kutatásban és ipari megoldásban bizonyították hatékonyságukat.

- Alapvető ML és képfeldolgozási megközelítések
SVM osztályozók és automatikus képfeldolgozás segítségével megkülönböztették az egészséges és fertőzött rizs palántákat.
Eperházakban tripszek kimutatására alkalmaztak automatikus képfeldolgozást és SVM osztályozást.
Banán- és görögdinnye-növények esetében távérzékelési eszközök és ML technikák, valamint spektrális vegetációs indexek segítségével végeztek betegségfelismerést.
- CNN-alapú megoldások
Ferentinos (2018) CNN-modelleket alkalmazott különböző növénybetegségek diagnosztizálására.
- YOLO-alapú megközelítések
Transfer learning módszereket használtak agronómiai betegségek detektálására.
Morbekar et al. (2020) YOLO-t alkalmazott gyapot- és rizsnövények esetében, bár a vizsgálat fókusza korlátozott volt.
Liu és Wang (2020) YOLOv3-alapú rendszert fejlesztett paradicsombetegségek és kártevők korai felismerésére.

Amarasingam et al. (2022) UAV-alapú távérzékelést és DL-t (YOLOv5) használt a cukornád fehérlevél-betegségének (WLD) felismerésére.

– Fejlett, kísérleti módszerek

A DoubleGAN és az N-szintű CNN-ek fejlesztés alatt állnak növénybetegségek diagnosztizálására.

Az MI alkalmazása a gyomfelismerés és gyomirtás területén is növekvő figyelmet kap. Mélytanulási modellek, mint a U-Net, SegNet, FCN és DeepLabV3+, hatékonyan különböztetik meg a gyomokat és a termesztett növényeket UAS (drónos) képalkotás alapján (*Aslan et al. 2024*).

– Ipari alkalmazások

A Blue River Technology „See & Spray” rendszere számítógépes látástechnikát használ a gyomok azonosítására és célzott kezelésére, ezzel jelentősen csökkentve a felhasznált gyomirtószer mennyiségét.

Integrált növényvédelem (IPM)

Az MI támogatja az IPM-rendszereket azáltal, hogy valós idejű adatokat elemel, és javaslatokat ad a természetes ellenségek alkalmazására, valamint a vegyszerhasználat minimalizálására.

Kihívások a növényvédelemben

A betegség- és kártevőfelismerés terén az alábbi kihívások merülnek fel:

- A modellek korlátozott általánosíthatósága különböző növényti pusokra és ökológiai környezetekre.
- Környezeti tényezők, mint az időjárás vagy a természetes fény változása, befolyásolhatják a modellek pontosságát.
- Szükség van széleskörű validációra különböző földrajzi területeken.
- Adatminőségi problémák, különösen a jól címkézett (annotált) képadatok hiánya.
- A talajtulajdonságok nagy változatossága is befolyásolhatja a felismerési modellek teljesítményét (*Aslan et al. 2024*).

Átfogó trendek és jövőbeli lehetőségek

Tartós kihívások

Az MI-megoldások kiemelkedő potenciálja ellenére több súlyos kihívás is akadályozza azok széles körű alkalmazását:

- Adatminőség: A pontos és megbízható előrejelzésekhez nagy mennyiségű, jó minőségű adatra van szükség. A hibás, hiányos vagy nem reprezentatív adatok jelentősen rontják a modellek teljesítményét.
- Modellek skálázhatósága és általánosíthatósága: Az MI-algoritmusok gyakran egy adott térségre vagy növénykultúrára optimalizáltak, így más régiókra való átvitelük nehézségekbe ütközik (Manzoor 2024).
- Regionális validáció szükségessége: A modelleket gyakran nem tesztelik különböző agroökológiai környezetekben, ami korlátozza gyakorlati alkalmazhatóságukat.
- Adatvédelem és kiberbiztonság: A mezőgazdasági szenzorok és felhőalapú rendszerek nagy mennyiségű érzékeny adatot gyűjtenek, ezért fokozott figyelmet kell fordítani a személyes és üzleti adatok védelmére.
- Technikai szakértelem hiánya: Sok termelő és agrárvállalkozás nem rendelkezik az MI-rendszerek használatához szükséges technikai háttérrel és képzéssel.
- Befektetési és eszközigény: A fejlett MI-alapú precíziós rendszerek gyakran jelentős kezdeti beruházást igényelnek, ami különösen a kis- és közepes méretű gazdaságok számára lehet korlátozó tényező.

Lehetőségek és javasolt irányok

Az alábbi irányok kulcsfontosságúak az MI-megoldások robusztusabb és szélesebb körű alkalmazhatóságának biztosításához a mezőgazdaságban:

- Adatintegráció: A különböző forrásokból (talajvizsgálatok, meteorológiai állomások, műholdak, IoT-eszközök) származó adatok egyesítése javíthatja a modellek prediktív teljesítményét.
- Modellek értelmezhetősége: A felhasználók számára fontos, hogy megértsék a döntéstámogatási rendszerek működését. Az átlátható és magyarázható AI rendszerek növelhetik a bizalmat és a használhatóságot.

- Interdiszciplináris együttműködés: A kutatók, mérnökök, agronómusok és gazdálkodók közötti szorosabb együttműködés segíthet a technológiák gyakorlati alkalmazásának fejlesztésében.
- Képzés és oktatás: Az MI-megoldások hatékony alkalmazásához elengedhetetlen a gazdák és agrárszakemberek megfelelő képzése.

Összességében elmondható, hogy a mesterséges intelligencia a precíziós mezőgazdaság egyik legígéretesebb eszköze, amely képes forradalmasítani a növénytermesztési gyakorlatokat. Az MI-alapú rendszerek megfelelő adatinfrastruktúrával, regionális validációval és felhasználóbarát kialakítással hozzájárulhatnak egy fenntarthatóbb, hatékonyabb és ellenállóbb mezőgazdasági jövő kialakításához (Aslan et al. 2024).

Átfogó trendek és fejlődési pályák

Az MI-alapú termés hozam-előrejelzés, növényállapot-monitorozás és betegségdetektálás területén jelentős fejlődés és sokszínűség figyelhető meg (Aslan et al. 2024). Egyre elterjedtebb a Sentinel-2 műholdképek és a különféle vegetációs indexek (VIs) alkalmazása elsődleges bemenetként, amelyeket különböző ML és DL modellekkel kombinálnak (Aslan et al. 2024).

Míg a hagyományos ML-módszerek – például a Random Forest (RF) és a támogatott vektorgép (SVM) – továbbra is népszerűek, a legújabb kutatások egyre inkább a fejlettebb technikák felé mozdulnak el, úgymint a konvolúciós neurális háló (CNN-ek), rekurrens neurális háló (RNN-ek), figyelemalapú (attention) hálózatok és összetett együttes (ensemble) modellek (Aslan et al. 2024).

Összegzés és gyakorlati tanulságok

A mesterséges intelligencia (MI) és a hozzá kapcsolódó technológiák mint a gépi tanulás (ML), mélytanulás (DL), távérzékelés (RS), IoT és képfeldolgozás, új távlatokat nyitnak a precíziós mezőgazdaságban. Az MI jelentős hatással bír a mezőgazdasági gyakorlatok automatizálására, az adatelemzésre és a döntéshozatal támogatására. Az MI eszközei révén lehetőség nyílik pontos hozambecslések készítésére, a növényállapot valós idejű nyomon követésére, valamint a betegségek és kártevők korai felismerésére.

A Sentinel-2 és más műholdak által szolgáltatott multispektrális adatok, valamint az ezekből számított vegetációs indexek (pl. NDVI, GNDVI) kiemelkedő

jelentőséggel bírnak a hozambecslési modellek és a növényállapot-monitorozás fejlesztésében. A GNDVI és az NDRE indexek különösen érzékenyen reagálnak a klorofill-koncentráció változásaira, így hatékonyan alkalmazhatók a növényállomány nitrogénellátottságának becslésére (Csajbók *et al.* 2022). E modellek gyakorlati alkalmazását azonban továbbra is számos tényező korlátozza, mindenekelőd az adatminőség, a régiós léptékű skálázás és a megbízható validáció területén jelentkező kihívások.

A tanulmányokban részletesen ismertetett kutatások azt mutatják, hogy a mesterséges intelligencia a fenntartható és hatékony mezőgazdaság irányába mutat. A jövőbeli fejlődéshez azonban szükség van adatvezérelt döntéstámogatási rendszerek továbbfejlesztésére, a technológiák integrálására, az értelmezhetőség növelésére, valamint a gazdálkodók képzésére és bevonására.

IRODALOM

- Alahmad, T.-Neményi, M.-Nyéki, A.*: 2025. Soil moisture content prediction using Gradient Boosting Regressor (GBR) model: soil-specific modeling with five depths. *Applied Sciences*. 15. 11: 5889. <https://doi.org/10.3390/app15115889>
- Amankulova, K.-Farmonov, N.-Akramova, P.-Tursunov, I.-Mucsi, L.*: 2023. Comparison of PlanetScope, Sentinel-2, and Landsat 8 Data in Soybean Yield Estimation Within-Field Variability with Random Forest Regression. *Heliyon*. 9. 6: e17432. <https://doi.org/10.1016/j.heliyon.2023.e17432>
- Amarasingam, N.-Gonzalez, F.-Salgadoe, A. S. A.-Sandino, J.-Powell, K.*: 2022. Detection of White Leaf Disease in Sugarcane Crops Using UAV-Derived RGB Imagery with Existing Deep Learning Models. *Remote Sensing*. 14. 23: 6137. <https://doi.org/10.3390/rs14236137>
- Aslan, M. F.-Sabanci, K.-Aslan, B.*: 2024. Artificial Intelligence Techniques in Crop Yield Estimation Based on Sentinel-2 Data: A Comprehensive Survey. *Sustainability*. 16. 18: 8277. <https://doi.org/10.3390/su16188277>
- Aslan, M. F.*: 2023. A hybrid end-to-end learning approach for breast cancer diagnosis: convolutional recurrent network. *Computers and Electrical Engineering*. 105: 108562. <https://doi.org/10.1016/j.compeleceng.2022.108562>
- Batz, P.-Will, T.-Thiel, S.-Ziesche, T. M.-Joachim, C.*: 2023. From Identification to Forecasting: The Potential of Image Recognition and Artificial Intelligence for Aphid Pest Monitoring. *Frontiers in Plant Science*. 14. <https://doi.org/10.3389/fpls.2023.1150748>

- Case-Cohen, A. L.*: 2018. Understanding the soil health knowledge of farmers in the Yakima Valley. PhD értekezés. Evergreen State College. Olympia. Washington. USA.
- Chibuye, M.–Phiri, J.*: 2023. Current Trends in Machine-Based Predictive Analysis in Agriculture for Better Crop Management – A Systematic Review. *Zambia ICT Journal*. 7: 29–37. <https://doi.org/10.33260/zictjournal.v7i1.147>
- Csajbók, J.–Buday-Bódi, E.–Nagy, A.–Fehér, Z. Z.–Tamás, A.–Virág, I. C.–Bojtor, C.–Forgács, F.–Vad, A. M.–Kutasy, E.*: 2022. Multispectral Analysis of Small Plots Based on Field and Remote Sensing Surveys – A Comparative Evaluation. *Sustainability*. 14. 6: 3339. <https://doi.org/10.3390/su14063339>
- Desloires, J.–Ienco, D.–Botrel, A.*: 2023. Out-of-Year Corn Yield Prediction at Field-Scale Using Sentinel-2 Satellite Imagery and Machine Learning Methods. *Computers and Electronics in Agriculture*. 209: 107807. <https://doi.org/10.1016/j.compag.2023.107807>
- Devapitchai, J. J.–St. Joseph, J.–Murugan, S.–Vethamanikam, A.–Hudson, G.–Dheenadhayalan, K.–Muthalagu, M.*: 2024. AI-Driven Decision-Making and Optimization in Modern Agriculture Sectors. [In: *AI-Driven Decision Making in Healthcare and Environmental Sciences: Nurturing Wellness, Sustaining Nature – Navigating AI Frontiers in Healthcare and Environmental Science.*] IGI Global. March 2024.
- Ferentimos, K. P.*: 2018. Deep Learning Models for Plant Disease Detection and Diagnosis. *Computers and Electronics in Agriculture*. 145: 311–318. <https://doi.org/10.1016/j.compag.2018.01.009>
- Fernandez-Beltran, R.–Baidar, T.–Kang, J.–Pla, F.*: 2021. Rice-Yield Prediction with Multi-Temporal Sentinel-2 Data and 3D CNN: A Case Study in Nepal. *Remote Sensing*. 13: 1391. <https://doi.org/10.3390/rs13071391>
- Fountas, S.–García, B.–Kasimati, A.–Mylonas, N.–Darra, N.*: 2020. The Future of Digital Agriculture: Technologies and Opportunities. *IT Professional*. 22: 24–28. <https://doi.org/10.1109/MITP.2019.2963412>
- Kowalska, A.–Ashraf, H.*: 2021. Advances in Deep Learning Algorithms for Agricultural Monitoring and Management. *Applied Research in Artificial Intelligence and Cloud Computing*. 4. 1: 68–88.
- Malhotra, K.–Firdaus, M.*: 2022. Application of Artificial Intelligence in IoT Security for Crop Yield Prediction. *ResearchBerg Review of Science and Technology*. 2. 1: 136–157.
- Kayad, A.–Sozzi, M.–Gatto, S.–Marinello, F.–Pirotti, F.*: 2019. Monitoring Within-Field Variability of Corn Yield Using Sentinel-2 and Machine Learning Techniques. *Remote Sensing*. 11: 2873. <https://doi.org/10.3390/rs11232873>
- Rahman, S.M.–Ravi, G.*: 2022. Role of Artificial Intelligence in Pest Management. *Current Trends in Agricultural Sciences*. 7. <https://doi.org/10.9734/bpi/ctas/v7/2141B>

- Liu, J.-Wang, X.*: 2020. Tomato Diseases and Pests Detection Based on Improved Yolo V3 Convolutional Neural Network. *Frontiers in Plant Science*. 11: 898. <https://doi.org/10.3389/fpls.2020.00898>
- Lockie, S.-Fairley-Grenot, K.-Ankeny, R.-Botterill, L.-Howlett, B.-McBratney, A.-Probyn, E.-Sorrell, T.-Sukkarieh, S.-Woodhead, I.*: 2020. The Future of Agricultural Technologies. Australian Council of Learned Academies (ACOLA). Canberra. Australia.
- Madhumathi, R.-Arumuganathan, T.-Shruthi, R.*: 2022. Internet of Things in Precision Agriculture: A Survey on Sensing Mechanisms, Potential Applications, and Challenges. [In: *Intelligent Sustainable Systems: Proceedings of ICISS 2021.*] 539-553. https://doi.org/10.1007/978-981-16-2422-3_42
- Manzoor, M.*: 2024. A Review of Machine Learning Techniques for Precision Agriculture and Crop Yield Prediction. *Premier Journal of Plant Biology*. <https://doi.org/10.70389/PJPB.100005>
- Monika, T.-Thangadurai, K.-Sivaguru, R.-Abdulkalamazad, G.-Lakshmi, R.*: 2025. AI-driven pest and disease detection in smart farming systems. *International Research Journal on Advanced Engineering and Management (IRJAEM)*. 3: 2315-2319. <https://doi.org/10.47392/IRJAEM.2025.0365>
- Morbekar, A.-Parihar, A.-Jadhav, R.*: 2020. Crop Disease Detection Using YOLO. [In: *Proceedings of the 2020 International Conference for Emerging Technology (INCET)*]. 1-5. <https://doi.org/10.1109/INCET49848.2020.9153986>
- Murugamani, C.-Shitharth-Hemalatha, S.-Kshirsagar, P.-Riyazuddin, K.-Quadri, N. N. N.-Islam, S.-Ali, S.-Batu, A.*: 2022. Machine Learning Technique for Precision Agriculture Applications in 5G-Based Internet of Things. *Wireless Communications and Mobile Computing*. 2022. Article ID 6534238. <https://doi.org/10.1155/2022/6534238>
- Mustafa, M.-Abbas, A.-Bsoul, Q.-Shabbir, A.*: 2021. Smart Irrigation System Based on the Internet of Things and the Cloud. *International Journal of Modern Trends in Science and Technology*. 7. 9: 19-24.
- Navalgund, R. R.-Jayaraman, V.-Roy, P.*: 2007. Remote Sensing Applications: An Overview. *Current Science*. 93: 1747-1766.
- Neményi, M.*: 2018. Precision crop production and artificial intelligence - the future of sustainable agriculture. *Acta Agraria Debreceniensis*. 47-58. <https://doi.org/10.34101/actaagrar/150/1701>
- Nyéki, A.-Kerepesi, C.-Daróczy, B.-Benczúr, A.-Milics, G.-Nagy, J.-Harsányi, E.-Kovács, A. J.-Neményi, M.*: 2021. Application of spatio-temporal data in site-specific maize yield prediction with machine learning methods. *Precision Agriculture*. <https://doi.org/10.1007/s11119-021-09833-8>

- Nyéki, A.–Daróczy, B.–Neményi, M.–Ambrus, B.–Teschner, G.–Alahmad, T.: 2025. Predicting maize growth and biomass: Integrating gradient boosted trees with Sentinel images and IoT. *Progress in Agricultural Engineering Sciences*. <https://doi.org/10.1556/446.2025.00202>
- Padhiary, M.–Saha, D.–Kumar, R.–Sethi, L. N.–Kumar, A.: 2024. Enhancing Precision Agriculture: A Comprehensive Review of Machine Learning and AI Vision Applications in All-Terrain Vehicle for Farm Automation. *Smart Agricultural Technology*. 8: 100483. <https://doi.org/10.1016/j.atech.2024.100483>
- Ragán P.–Rátonyi T.–Birkás M.–Harsányi E.: 2021. Talajvizsgálatok és távérzékelte adatok alkalmazhatósága a precíziós mezőgazdaságban. *Mezőgazdasági Technika*. 62. 2: 33–35.
- Ragán P.–Tamás A.–Rátonyi T.–Nagy J.–Harsányi E.–Széles A.: 2023. Évjáráthatás vizsgálata hozamtérkép adatok felhasználásával. [In: Kakuszi-Széles A. (szerk.) *Növény és környezet: a debreceni tartamkísérletek 40 éve*. Debreceni Egyetem MÉK Fölhasznosítási, Műszaki és Precíziós Technológiai Intézet. Debrecen. 50. ISBN: 9789634905400
- Ramteke, P.–Kshirsagar, U.: 2023. The Role of Machine Intelligence in Agriculture: A Case Study. [In: Suresh et al. (eds.) *Research trends in artificial intelligence: Internet of Things*.] Bentham Science Publishers. Singapore. 54–79. <https://doi.org/10.2174/9789815136449123010007>
- Revel, C.–Lonjou, V.–Marçq, S.–Desjardins, C.–Fougnie, B.–Luche, C.–Guillemintot, N.–Lacamp, A. S.–Lourme, E.–Miquel, C.–Lenot, X.: 2019. Sentinel-2A and 2B absolute calibration monitoring. *European Journal of Remote Sensing*. 52: 122–137. <https://doi.org/10.1080/22797254.2018.1562311>
- Sári-Barnácz, F. E.–Zalai, M.–Toepfer, S.–Milics, G.–Iványi, D.–Tóthné Kun, M.–Mészáros, J.–Árvai, M.–Kiss, J.: 2023. Suitability of satellite imagery for surveillance of maize ear damage by cotton bollworm (*Helicoverpa armigera*) larvae. *Remote Sensing*. 15. 23: 5602. <https://doi.org/10.3390/rs15235602>
- Shafi, U.–Mumtaz, R.–García-Nieto, J.–Hassan, S. A.–Zaidi, S. A. R.–Iqbal, N.: 2019. Precision Agriculture Techniques and Practices: From Considerations to Applications. *Sensors*. 19. 17: 3796. <https://doi.org/10.3390/s19173796>
- Shaikh, T. A.–Rasool, T.–Lone, F. R.: 2022. Towards Leveraging the Role of Machine Learning and Artificial Intelligence in Precision Agriculture and Smart Farming. *Computers and Electronics in Agriculture*. 198: 107119. <https://doi.org/10.1016/j.compag.2022.107119>
- Sishodia, R. P.–Ray, R. L.–Singh, S. K.: 2020. Applications of Remote Sensing in Precision Agriculture: A Review. *Remote Sensing*. 12: 3136. <https://doi.org/10.3390/rs12193136>

- 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. <https://doi.org/10.1016/j.aiaa.2020.04.002>
- Thorat, T.-Patle, B. K.-Kashyap, S. K.:* 2022. Intelligent Insecticide and Fertilizer Recommendation System based on TPF-CNN for Smart Farming. *Smart Agricultural Technology*. 3: 100114. <https://doi.org/10.1016/j.atech.2022.100114>
- Thotho, D.-Macheso, P.:* 2024. Comprehensive Survey on Applications of Internet of Things, Machine Learning and Artificial Intelligence in Precision Agriculture. *Tanzania Journal of Engineering and Technology*. 42: 30–45. <https://doi.org/10.52339/tjet.v42i4.922>
- Vasudevan, N.-Karthick, T.:* 2024. Big Data Analytics for Yield Prediction in Precision Agriculture. [In: Shamshiri et al. (eds.) *Precision agriculture – emerging technologies.*] IntechOpen. London. 1–15. <https://doi.org/10.5772/intechopen.114165>
- Xiao, G.-Zhang, X.-Niu, Q.-Li, X.-Li, X.-Zhong, L.-Huang, J.:* 2024. Winter Wheat Yield Estimation at the Field Scale Using Sentinel-2 Data and Deep Learning. *Computers and Electronics in Agriculture*. 216: 108555 <https://doi.org/10.1016/j.compag.2023.108555>
- Zelenák, A.-Szabó, A.-Nagy, J.-Nyéki, A.:* 2022. Using the CERES-Maize model to simulate crop yield in a long-term field experiment in Hungary. *Agronomy*. 12: 785. <https://doi.org/10.3390/agronomy12040785>
- Zhang, H.-Zhang, Y.-Liu, K.-Lan, S.-Gao, T.-Li, M.:* 2023. Winter Wheat Yield Prediction Using Integrated Landsat 8 and Sentinel-2 Vegetation Index Time-Series Data and Machine Learning Algorithms. *Computers and Electronics in Agriculture*. 213: 108250. <https://doi.org/10.1016/j.compag.2023.108250>

A szerző levelezési címe – Address of the author:

Dorogházi Ottó
Debreceni Egyetem
Kerpely Kálmán Doktori Iskola
Debrecen
Böszörményi út 138.
H-4032
otto.doroghazi@mailbox.unideb.hu