

A növénytermelés döntéstámogatás fejlődése: termésmodellek, precíziós adatintegráció és mesterséges intelligencia

NYÉKI ANIKÓ

Széchenyi István Egyetem Albert Kázmér Mosonmagyaróvári Kar
Bioműszaki és Precíziós Technológiai Tanszék, Mosonmagyaróvár

Összefoglalás

Jelen tanulmány szakirodalmi-szintetizáló áttekintésként mutatja be a növénytermelés döntéstámogatás fejlődését a folyamat-alapú termésmodellezéstől a precíziós adatforrásokon át a mesterséges intelligencia és a hibrid modellek alkalmazásáig. Célja annak összehasonlító értelmezése, hogy a DSSAT, WOFOST és AquaCrop típusú modellek, a szenzoros, távérzékelési és hozamtérképezési adatok, valamint az AI-alapú módszerek milyen döntési helyzetekben és feltételek mellett növelik a termesztési döntések megbízhatóságát. Az áttekintés fő megállapítása, hogy a döntéstámogatás gyakorlati értéke nem egyetlen modell vagy technológia alkalmazásából, hanem a tudományosan megalapozott modellek, minőségellenőrzött helyspecifikus adatok és értelmezhető, adaptív algoritmusok integrációjából származik. A tanulmány következtetése szerint a hazai alkalmazhatóság kulcsa a helyi kalibráció, a tartamkísérleti és üzemi adatbázisok erősítése, valamint a felhasználói kompetenciák fejlesztése.

Kulcsszavak: növénytermelés döntéstámogatás, termésmodellezés, precíziós mezőgazdaság, adatintegráció, mesterséges intelligencia

The evolution of decision support in crop production: yield models, precision data integration and artificial intelligence

A. NYÉKI

Széchenyi István University, Albert Kázmér Faculty of Mosonmagyaróvár
Department of Biotechnology and Precision Technology, Mosonmagyaróvár

Summary

This study presents a literature review that traces the evolution of decision support for crop production, from process-based yield modeling through precision data sources to the application of artificial intelligence and hybrid models. Its aim is to provide a comparative analysis of how DSSAT, WOFOST, and AquaCrop-type models, as well as sensor, remote sensing, and yield mapping data, and AI-based methods, enhance the reliability of crop production decisions under various decision-making scenarios and conditions. The main finding of the review is that the practical value of decision support does not stem from the application of a single model or technology, but rather from the integration of scientifically sound models, quality-controlled site-specific data, and interpretable, adaptive algorithms. The study concludes that the key to domestic applicability lies in local calibration, strengthening long-term experimental and operational databases, and developing user competencies.

Keywords: crop production decision support, yield modeling, precision agriculture, data integration, artificial intelligence

Bevezetés

A növénytermesztésben meghozott döntések minősége egyre közvetlenebbül hat a gazdaságok jövedelmezőségére, környezeti teljesítményére és alkalmazkodóképességére. A klímaváltozásból fakadó szélsőségek, a vízkészletek bizonytalanabb rendelkezésre állása, az inputanyagok árának növekedése és a fenntarthatósági elvárások megerősödése miatt a

hagyományos, kizárólag tapasztalatra épülő döntéshozatal egyre kevésbé elegendő. A korszerű növénytermesztés döntéstámogatás ezért olyan rendszereket igényel, amelyek a termőhelyi adottságokat, a növényélettani folyamatokat, a terméstechnológiai beavatkozásokat és az üzemi visszacsatolásokat egyetlen értelmezési keretben képesek kezelni (Boote et al., 1996; Jones et al., 2017).

A tudományos fejlődés e területen három, egymásra épülő irányban ragadható meg. Az első pillért a folyamat-alapú termésmoდეllek jelentik, amelyek matematikai egyenletekkel írják le a növekedést, a fejlődést és a termésképződést. A második pillért a precíziós mezőgazdaság adatgyűjtő technológiái adják, amelyek nagy tér- és időbeli felbontású információt szolgáltatnak a talaj, a növényállomány és a környezet aktuális állapotáról. A harmadik pillér a mesterséges intelligencia és a gépi tanulás, amelyek lehetővé teszik a heterogén adatkészletek gyors feldolgozását, a nemlineáris összefüggések feltárását és az előrejelzések folyamatos finomítását (Wolfert et al., 2017; Liakos et al., 2018).

Jelen tanulmány e három fejlődési irány szintézisét adja. A cél nem pusztán az egyes megközelítések bemutatása, hanem annak értelmezése, hogy miként kapcsolhatók össze a növénytermesztés döntéstámogatás egységes rendszerévé. A vizsgálat alapját három háttéranyag képezi: a termésbecslő modellek összehasonlítása, a precíziós adatforrások döntéstámogatási szerepe, valamint a mesterséges intelligencia agráralkalmazásainak áttekintése. Ezek szintézise alapján amelletт érvel, hogy a jövő hatékony döntéstámogatása nem egyetlen módszer dominanciájára, hanem a modellek, adatok és algoritmusok tudatos kombinációjára épül.

A kézirat célja a termésmoდეllek, a precíziós adatforrások és az AI-módszerek döntéstámogatási szerepének összehasonlító értelmezése, valamint annak bemutatása, hogy ezek milyen feltételek mellett kapcsolhatók össze megbízható, gyakorlatorientált rendszerként.

A termésmoდეlezés elméleti alapjai és döntéstámogató szerepe

A termésmoდეlezés alapfeltevése szerint a növény fejlődése, biomassza-felhalmozása és termésképződése leírható olyan matematikai és logikai kapcsolatokkal, amelyek a környezeti, talajtani és menedzsmenttényezők

kölcsönhatásait reprezentálják. A modellek bemeneti oldalán tipikusan a meteorológiai adatok, a talaj fizikai és kémiai jellemzői, a genotípus-specifikus növényi paraméterek és a termesztéstechnológiai műveletek jelennek meg, míg kimenetként hozambecslések, fenológiai állapotok, víz- és tápanyagforgalmi mutatók vagy gazdasági indikátorok állhatnak elő (Jones et al., 2003; Keating et al., 2003).

A döntéstámogatás szempontjából a modellek legnagyobb előnye az, hogy alternatív forgatókönyvek összehasonlítására alkalmasak. Segítségükkel vizsgálható például, hogy eltérő vetésidők, öntözési stratégiák, trágyaszintek vagy fajták milyen kimenetekkel járhatnak azonos vagy éppen változó évi körülmények között. A modellek tehát nem egyszerűen „jósló” eszközök, hanem kísérleti keretet is biztosítanak a döntési alternatívák kockázatának és várható hasznának elemzéséhez (Boote et al., 1996; Jones et al., 2017).

Elméleti szempontból fontos különbség tehető a mechanisztikus és az empirikusabb megközelítések között. A mechanisztikus modellek részletesebben próbálják leírni a rendszer folyamatait – például a fotoszintézist, a transzspirációt vagy a fenológiai fejlődést –, míg az egyszerűsített modellek célja a könnyebb paraméterezhetőség és a szélesebb gyakorlati használhatóság. A mezőgazdasági döntéstámogatásban mindkét megközelítésnek helye van, de a választás mindig a célrendszerrel és az adatkörnyezettel függ (Steduto et al., 2009; Pereira & Marques, 2017).

A klasszikus termésmodellek összehasonlítása

A DSSAT a legismertebb komplex növénytermesztési modellrendszerek közé tartozik. Erőssége a részletes szerkezet: napi meteorológiai adatokkal, többretegű talajinformációval, genotípus-paraméterekkel és precízen leírt menedzsműveletekkel dolgozik, ezért alkalmas összetett agronómiai és klímaadaptációs kérdések vizsgálatára is (Jones et al., 2003). A DSSAT különösen hasznos akkor, ha a kutató vagy a szaktanácsadó a termesztés teljes életciklusát szeretné modellezni, illetve, ha a víz- és tápanyagfolyamatok összekapcsolt értelmezése szükséges. Ugyanakkor ez a részletesség magas adatigénnyel és jelentős kalibrációs igénnyel jár, ami korlátozhatja üzemi szintű, gyors alkalmazhatóságát (Nagy, 2021; Nyéki, 2016) (1. táblázat).

1. táblázat. A fő döntéstámogató megközelítések összehasonlítása

Megközelítés (1)	Elsődleges cél (2)	Adatigény (3)	Fő erősség (4)	Tipikus korlát (5)
DSSAT/CERES-típusú modellek (6)	részletes termés- és forgatókönyv-elemzés	magas	erős fiziológiai és menedzsment-reprezentáció	kalibráció- és adatintenzív
WOFOST (7)	regionális és monitoring célú termésbecslés	közepes	jó térinformatikai integrálhatóság	kevésbé üzemi szintű finomhangolás
AquaCrop (8)	vízgazdálkodási és öntözési döntések	alacsony-közepes	jó használhatóság vízstressz elemzésére	egyszerűsített rendszerleírás
AI/gépi tanulás (9)	predikció, mintázat-felismerés, adaptív döntéstámogatás	nagy	jól kezeli a heterogén és nemlineáris adatokat	adatminőség és interpretálhatóság kritikus

Table 1. A comparison of the main decision-support approaches. (1) Approach, (2) Primary aim, (3) Data demand, (4) Main strength, (5) Typical limit, (6) DSSAT/CERES type models, (7) WOFOST, (8) AquaCrop, (9) AI/machine learning

A WOFOST szintén folyamat-alapú modell, de európai agroökológiai környezetben különösen elterjedtté vált, részben azért, mert jól integrálható monitoring- és térinformatikai rendszerekbe. A modell a fotoszintézis, a biomassza-allokáció, a fenológiai fejlődés és a vízforgalom leírására koncentrált, és jól használható regionális hozambecslésekre, klímahatás-vizsgálatokra és agrármonitoringra (Van Diepen et al., 1989; Yahui et al., 2024). A WOFOST egyik előnye a relatív átláthatóság és a közepes adatigény, azonban a tápanyagkorlátozottság részletes kezelése vagy az üzemi szintű szélsőséges heterogenitás modellezése bizonyos esetekben korlátozottabb lehet, mint a részletesebb rendszerek esetében.

Az AquaCrop ezzel szemben a vízhasznosítás és a hozamkapcsolat leegyszerűsített, de tudományosan megalapozott reprezentációjára épít. A FAO által fejlesztett modellt kifejezetten az öntözéstervezés, a vízstressz-elemzés és a vízhasználati hatékonyság értékelésének támogatására készült, ezért alacsonyabb adatigényével és felhasználóbarátabb paraméterezésével sok esetben gyorsabban bevezethető a gyakorlatba (Steduto et al., 2009; Raes et al., 2012). Egyszerűsége ugyanakkor azt is jelenti, hogy bizonyos komplex fiziológiai vagy menedzsment-hatások kevésbé részletesen jelennek meg. A három modell összevetése alapján megállapítható, hogy nincs univerzális megoldás: a DSSAT kutatási és stratégiai célokra, a WOFOST regionális és monitoring feladatokra, az AquaCrop pedig vízgazdálkodási és gyors üzemi döntéstámogatásra különösen alkalmas.

Döntési helyzetek szerint a DSSAT akkor célszerű, amikor részletes agrotechnológiai foratókönyvek és klímaadaptációs stratégiák összevetése a cél; a WOFOST főként regionális, monitoring- és térinformatikai becslésekben erős; az AquaCrop pedig vízkorlátozott környezetben, öntözési ütemezés és vízhasználati hatékonyság értékelésekor ad gyorsan alkalmazható támogatást.

Precíziós adatforrások és adatintegráció

A precíziós mezőgazdaság alapvető hozzájárulása a döntéstámogatáshoz abban rejlik, hogy képes a termőhelyi heterogenitást mérhetővé és elemezhetővé tenni. Míg a klasszikus modellek sokszor átlagos vagy aggregált bemeneti adatokkal dolgoznak, addig a szenzoros rendszerek, automata meteorológiai állomások, talajszkennerek, hozammérő rendszerek és távérzékelési technológiák helyspecifikus információt biztosítanak a növényállományról és a környezetről (Godwin, 2003; Gebbers & Adamchuk, 2010). Ez különösen fontos ott, ahol a parcellán belüli különbségek meghatározzák az inputok megtérülését és a termésstabilitást.

A talajnedvesség-, hőmérséklet- és mikroklíma-adatok valós idejű vagy közel valós idejű gyűjtése lehetővé teszi az öntözési, tápanyag-utánpótlási és stresszkezelési döntések pontosítását. A szenzorok által nyert adatok azonban önmagukban még nem jelentenek döntéstámogatást: azok csak akkor válnak hasznos információvá, ha megfelelő kalibrációval, adatminőségi ellenőrzéssel és értelmezési kerettel kapcsolódnak a termesztési célokhoz (Jones et al., 2017;

Soussi et al., 2024). A rosszul kalibrált vagy időben hiányos adatrendszer ugyanis könnyen félrevezető következtetésekhez vezethet.

A precíziós technológiák jelentőségét tovább növeli, hogy a gazdálkodási döntésekről közvetlen visszacsatolást is adnak. A géptelemetria és a hozamtérképek megmutatják, hol volt eredményes egy beavatkozás, és hol maradt el a várt hatás. Ez a visszacsatolás nem csupán az üzemi értékelést támogatja, hanem a termésmodellek kalibrációját és validációját is erősítheti, hiszen lehetővé teszi a szimulált és a tényleges kimenetek összevetését (Kitchen et al., 2010; Antle et al., 2017). A precíziós mezőgazdaság tehát nem alternatívája a modellezésnek, hanem annak adatbeli megerősítése.

Távérzékelés, drónok és hozamtérképezés

A távérzékelés és a drónalapú adatgyűjtés új minőséget hozott a növénytermesztés rendszereinek monitorozásába. A műholdas felvételek, multispektrális és hiperspektrális drónkamerák, valamint a vegetációs indexek – például az NDVI vagy az NDRE – alkalmasak a növényállomány vitalitásának, biomassza-felhalmozásának és stresszállapotának térképezésére (Zhang & Kovacs, 2012; Liakos et al., 2018). E módszerek különösen értékesek akkor, amikor nagy területet kell gyorsan, egységes módszertannal értékelni.

Friss hazai kísérleti eredmények is megerősítik, hogy a multispektrális UAV-felvételek a szezonközi állapotértékelés mellett közvetlen döntéstámogatási bemenetként is használhatók. Illés et al. (2025a) a Debrecen-Látókép kísérleti állomáson a kelés utáni kukoricaállomány tőszámának spektrális adatintegráción alapuló becslését vizsgálták, míg Lengyel et al. (2025) az NDVI és a terméshozam kapcsolatát különböző fenológiai fázisokban és eltérő UAV-repülési beállítások mellett értékelték. A tápanyag-gazdálkodási döntésekhez kapcsolódóan Illés et al. (2025b) az NDVI-alapú monitoringot a nitrogénellátás, a termés és a szemösszetétel összehangolt értelmezésére alkalmazták.

A drónalapú mérések előnye a nagy térbeli felbontás és az időzítés rugalmassága. Kritikus fenológiai szakaszokban – például intenzív vegetatív növekedés, virágzás vagy stresszhelyzetek idején – célzott adatfelvétel végezhető, ami segíti a differenciált zónák kialakítását és a gyors üzemi beavatkozásokat (Zhang & Kovacs, 2012; Liakos et al., 2018). Ugyanakkor a nagy felbontásból fakadó adatbőség új feldolgozási kihívásokat is teremt, mert a

döntéshozók számára nem az adatok mennyisége, hanem az abból előállított értelmezhető indikátorok a lényegesek.

A hozamtérképezés olyan gyakorlati visszacsatolási mechanizmus, amely összeköti a szezon közbeni megfigyeléseket a betakarítási eredményekkel. Ha a hozamtérképeket talajadatokkal, domborzati információval, meteorológiai sorozatokkal és távérzékelési mutatókkal együtt értelmezzük, akkor megérthetővé válnak azok a zónák, ahol a terméskülönbségek rendszeresen ismétlődnek vagy éppen évszámra változnak (Godwin, 2003; Kitchen et al., 2010). Ilyen módon a hozamtérképezés nem pusztán leíró eszköz, hanem a döntéstámogatási ciklus egyik alapvető validációs eleme.

Az adatintegráció módszertani kérdései

A növénytermesztési döntéstámogató rendszerek egyik legnagyobb kihívása nem az adathiány, hanem éppen az adatok heterogenitása. A szenzoros, meteorológiai, gépi, távérzékelési és laboratóriumi adatok eltérő térbeli és időbeli léptékben, különböző pontossággal és eltérő formátumban keletkeznek. Ha ezek összehangolása hiányos, akkor az adatbőség nem csökkenti, hanem növeli a bizonytalanságot (Verdouw et al., 2016; Wolfert et al., 2017).

Gyakorlati példaként említhető a rosszul kalibrált kombájn-hozammérő, amely a hozamtérképen mesterséges termésmaximumokat vagy – minimumokat hozhat létre; a hiányos agrotechnológiai napló, amelyből nem derül ki pontosan a vetésidő, a nitrogénkijuttatás vagy az öntözés időpontja; illetve az eltérő időpontban készült UAV- vagy műholdfelvétel, amely nem ugyanazt a fenológiai állapotot reprezentálja, mint amelyre a modellkalibráció vagy a döntés vonatkozik. Ilyen esetekben az integrált adatbázis látszólag részletes, mégis torz döntési alapot adhat.

Az adatintegráció klasszikus problémája a skálák eltérése. Egy talajnedvesség-szenzor pontszerű adatot ad, a műholdkép több négyzetméter vagy hektár átlagát reprezentálja, a hozamtérkép pedig gépi mérésből származó, mozgás közben rögzített adatsorozat. Döntéstámogatási szempontból ezek csak akkor hasonlíthatók össze, ha világos, milyen döntési egységre – például zónára, parcellára vagy teljes gazdaságra – vonatkoztatjuk őket (Hatfield et al., 2011). A nem megfelelő térbeli aggregálás vagy időbeli interpoláció lényeges mintázatok eltűnéséhez vezethet. Az adat, információ, döntés láncolat ezért csak megfelelő feldolgozási architektúrával működik

megbízhatóan. Ehhez szükség van adatminőségi szűrésre, metaadat-kezelésre, térinformatikai összehangolásra, valamint olyan modellezési környezetre, amely a különböző forrásokból érkező információt a döntéshozó számára releváns kimenetűvé alakítja (Jones et al., 2017). A gyakorlati hasznosítás kulcsa tehát nem csupán a mérési technológia fejlettsége, hanem az adatintegráció módszertani fegyelme. Az 1. ábra a precíziós növénytermesztési döntéstámogatás fő adatforrásait és azok integrációs folyamatát mutatja be. A szemléltetés kiemeli, hogy a szimulációs és AI-modellek csak minőségellenőrzött, összehangolt adatok alapján képesek megbízható döntési kimeneteket támogatni.

1. ábra. Az adatintegráció folyamata a precíziós növénytermesztési döntéstámogatásban

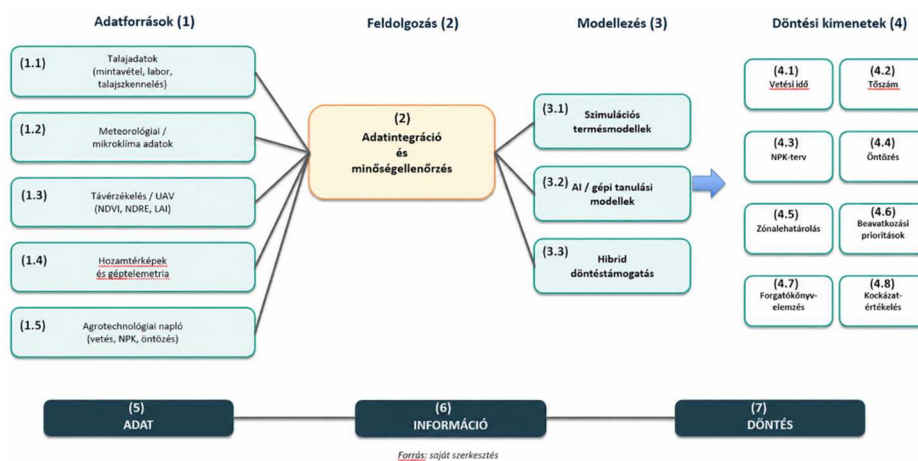


Figure 1. The process of data integration in precision crop production decision support. (1) Data sources, (1.1) Soil data (sampling, lab, soil scanning), (1.2) Meteorological/micro-climatic data, (1.3) Remote sensing/UAV (NDVI, NDRE, LAI), (1.4) Yield maps and machine telemetry, (1.5) Agrotechnological log (sowing, NPK, irrigation), (2) Processing – Data integration and quality inspection, (3) Modeling, (3.1) Simulation yield models, (3.2) AI/machine learning models, (3.3) Hybrid decision support, (4) Decision outputs, (4.1) Sowing date, (4.2) Plant number, (4.3) NPK plan, (4.4) Irrigation, (4.5) Zone delimitation, (4.6) Intervention priorities, (4.7) Scenario analysis, (4.8) Risk assessment, (5) DATA, (6) INFORMATION, (7) DECISION, Source: own construction

Hazai kutatási tapasztalatok és lokalizáció

A hazai szakmai környezetben a döntéstámogatás fejlődését nemcsak a nemzetközi modellek, hanem a magyar adaptációk és szaktanácsadási rendszerek is alakították. Külön említhető a 4M modell, amelyet hazai talajadatbázisok figyelembevételével adaptáltak a legfontosabb szántóföldi növényekre, valamint ennek továbbfejlesztett változatai, amelyek tápanyag-utánpótlási és klímahatás-vizsgálati célokra is használhatók. Szintén jelentős a ProPlanta és a 3RP System, amelyek azt mutatják, hogy Magyarországon a talajvizsgálati eredményekre, termőhelyi sajátosságokra és technológiai adatokra épülő szaktanácsadási rendszerek már a digitális áttörés előtt is jelen voltak.

A növénytermesztés döntéstámogatás hazai alkalmazhatóságát jelentősen befolyásolja, hogy a modellek és algoritmusok mennyire illeszkednek a magyarországi agroökológiai viszonyokhoz. Több hazai kutatás rámutatott arra, hogy a termőhelyi heterogenitás, az évjáráthatás, a talajfizikai sajátosságok és a természetstechnológiai beavatkozások kölcsönhatása különösen erős a kukoricatermesztésben, ezért az átlagos paraméterekre épülő döntéstámogatás sok esetben torzító lehet (Berzsenyi et al., 2011, Nyéki, 2016).

A Debrecen-Látókép tartamkísérletekhez kapcsolódó elemzések például azt mutatták, hogy a hosszú távú kísérleti adatbázisok és a CERES-Maize típusú modellek összekapcsolása képes a tápanyaghasznosulás és a hozamreakciók helyspecifikus értelmezésére, ami közvetlenül javítja a döntéstámogatás megbízhatóságát hazai körülmények között (Nyéki et al., 2020; Zelenák et al., 2022). Hasonlóképpen a talajtulajdonságok térbeli változékonyságát vizsgáló kutatások alátámasztották, hogy a parcellán belüli különbségek nem csupán statisztikai érdekességek, hanem gyakorlati inputoptimalizálási jelentőséggel bírnak (Nyéki & Neményi, 2022).

A lokalizáció tehát nem csupán a modellek technikai adaptációját jelenti, hanem a hazai viszonyokra jellemző kalibrációs és validációs háttér megteremtését. Ebben kiemelt szerepe van a tartamkísérleteknek, az üzemi adatok standardizált gyűjtésének és a hazai szaktanácsadási rendszer digitális fejlesztésének. A döntéstámogatás valódi megbízhatósága csak akkor

növelhető, ha a modellek és az adatok közötti kapcsolatot hazai viszonyok között is empirikusan alá tudjuk támasztani.

A fenti hazai vizsgálatok azért illeszkednek közvetlenül a lokalizáció kérdéséhez, mert a távérzékelési mutatókat, a tápanyag-ellátottságot és a termésválaszt magyarországi tartamkísérleti környezetben kapcsolják össze. Ez erősíti azt az értelmezést, hogy a döntéstámogató rendszerek megbízhatósága nemcsak a modellstruktúrán, hanem a helyi kalibrációs és validációs adatok minőségén is múlik (Illés et al., 2025ab; Lengyel et al., 2025).

A tartamkísérleti hozam- és kezelési adatok a mechanisztikus modellek alapkálibrációját, míg a szezonközi NDVI-, NDRE- és állománysűrűségi UAV-adatok a modellállapotok évjáraton belüli korrekcióját támogatják. Ennek gyakorlati jelentősége, hogy a modell nemcsak utólagos hozamszimulációra, hanem operatív döntéstámogatásra is alkalmassá válik: például a tápanyag-ellátottság, a vízstressz vagy az állománysűrűség helyspecifikus eltérései alapján módosíthatók a beavatkozási zónák és a kezelési javaslatok.

Mesterséges intelligencia és hibrid modellek

A mesterséges intelligencia mezőgazdasági jelentősége elsősorban abban áll, hogy képes a nagymennyiségű, heterogén és gyakran nemlineáris kapcsolatokat tartalmazó agráradatok feldolgozására. A gépi tanulási módszerek nem előre rögzített élettani egyenletekből indulnak ki, hanem az adatokból tanulják meg a bemenetek és a kimenetek közötti kapcsolatokat. Ez különösen előnyös olyan helyzetekben, ahol a rendszerek bonyolultak, az összefüggések részben ismeretlenek, vagy a rendelkezésre álló adatbázis nagy és változatos (Russell & Norvig, 2010; Kamilaris & Prenafeta-Boldú, 2018).

A felügyelt tanulási algoritmusok – például a random forest vagy a support vector machine – széles körben alkalmazhatók hozam-előrejelzésre, talajosztályozásra, zóna-lehatárolásra és stresszdetektálásra. E módszerek egyik előnye, hogy jól kezelik a nagyszámú bemeneti változót és a köztük lévő összetett, nemlineáris kapcsolatokat, miközben sok esetben jobb predikciós teljesítményt adnak, mint az egyszerűbb statisztikai modellek (Jeong et al., 2016; Zhang et al., 2020). A mélytanulási megoldások, különösen a konvolúciós neurális hálózatok, a képalapú feladatokban – például növénybetegségek

azonosításában vagy drónfelvételek elemzésében – váltak meghatározóvá (Mohanty et al., 2016; Ferentinos, 2018).

A gépi tanulás döntéstámogató értéke azonban nem pusztán a predikciós pontosságban mérhető. Jelentősége abban is áll, hogy képes összekapcsolni az eltérő forrásból származó adatokat, és folyamatosan aktualizálható modelleket biztosítani. A precíziós mezőgazdasági szenzorok, hozamtérképek és távérzékelési adatok olyan dinamikus adatfolyamot generálnak, amelyet a gépi tanulási algoritmusok adaptív módon tudnak hasznosítani a döntéstámogatásban (Wolfert et al., 2017; Nyéki & Neményi, 2022).

A mesterséges intelligencia hazai agráralkalmazásaira jó példa Fejér et al. (2025) munkája, amely többéves kukorica szántóföldi kísérleti adatokon, eltérő bemeneti változó-kombinációkkal tesztelt MLP neurális hálózatokat. A vizsgálat a hozam-előrejelzés szempontjából azért releváns, mert a kezelések, az évjárat-környezeti hatások és a beltartalmi paraméterek összetett, nemlineáris kapcsolatait egy prediktív döntéstámogató modellben kezelte.

Az ilyen prediktív modellek akkor illeszthetők biztonságosan a szaktanácsadásba, ha a bemeneti változók minősége ellenőrzött, a modell teljesítményét független adatokon validálják, és az eredmények agronómiai értelmezése nem szakad el a természetstechnológiai háttértől.

Hibrid modellek: klasszikus modellek és AI kapcsolata

A mesterséges intelligencia megjelenése nem jelenti a klasszikus növénytermelési modellek háttérbe szorulását. A mechanisztikus modellek – például a DSSAT, a WOFOST vagy az AquaCrop – továbbra is nélkülözhetetlenek azért, mert értelmezhető, élettani alapú keretet kínálnak a rendszer működésének megértéséhez (Jones et al., 2003; Van Ittersum et al., 2003; Raes et al., 2009). A gépi tanulás ezzel szemben elsősorban prediktív erősséget hoz, mert gyorsan képes felismerni a mintázatokat és javítani az előrejelzéseket olyan összetett környezetben, ahol a teljes mechanisztikus leírás nehézkes vagy hiányos.

A két megközelítés integrációja ezért ígéretes irány. A folyamat-alapú modellek kimenetei felhasználhatók tanítóadatként gépi tanulási modellek számára, míg a szenzoros és távérzékelési megfigyelések segítségével a klasszikus modellek paraméterei finomíthatók és helyspecifikusan aktualizálhatók (Jin et al., 2018; Li et al., 2024). Ilyen hibrid rendszerekben a

mechanisztikus modell biztosítja az oksági és biológiai konzisztenciát, a gépi tanulás pedig korrigálhatja a hibákat és javíthatja a valós idejű döntéstámogatás teljesítményét (2. táblázat).

2. táblázat. A döntéstámogató rendszerbe integrálható fő adatforrások és várható felhasználásuk

Adatforrás (1)	Példa (2)	Felhasználás (3)	Kritikus minőségi kérdés (4)
Talajadatok (5)	mintavétel, labor, talajszkenelés	zónalehatárolás, víz- és tápanyagmodellek	mintavételi sűrűség, rétegzettség
Meteorológiai adatok (6)	állomási és mikroklíma- mérések	fenológia, vízmérleg, stresszbecslés	napi felbontás, hiányzó adatok
Távérzékelés/UAV (7)	NDVI, NDRE, LAI-becslés	állapotmonitoring, stresszdetektálás, modellkorrekció	időzítés, felhőzet, radiometriai konzisztencia
Gépadatok és hozamtérképek (8)	kombájnhozam, kijuttatási naplók	utólagos értékelés, validáció, differenciált menedzsment	szenzorkalibráció, helymeghatározási pontosság
Agrotechnológiai adatok (9)	vetésidő, tőszám, NPK, öntözés	forgatókönyv- elemzés, oksági értelmezés	naplózási pontosság, időbélyegek

Table 2. Major data sources that can be integrated into the decision support system and their expected uses. (1) Data sources, (2) Examples, (3) Uses, (4) Critical quality issues, (5) Soil data, (6) Weather data, (7) Remote sensing/UAV, (8) Machine data and yield maps, (9) Agrotechnological data

A hibrid megközelítések különösen fontosak lehetnek a klímaadaptációban és a kockázatkezelésben. A jövőbeli évjáratokra vonatkozó forgatókönyvek szimulációja mechanisztikus modellekkel stabilabban elvégezhető, míg a

szezon közbeni friss mérések és üzemi visszacsatolások AI-alapú feldolgozása segíthet a helyzetfüggő korrekciókban. Ez a kombináció teszi lehetővé, hogy a döntéstámogatás egyszerre legyen tudományosan megalapozott és operatívan rugalmas.

Korlátok, kockázatok és gyakorlati kihívások

Bár a modellezés, a precíziós adatgyűjtés és a mesterséges intelligencia jelentős lehetőségeket kínál a növénytermesztés döntéstámogatásában, alkalmazásuk számos korláttal jár. Az egyik alapvető probléma az adatminőség kérdése. A hiányos, zajos, rosszul kalibrált vagy nem reprezentatív adatok a legkifinomultabb modell esetén is bizonytalan, sőt félrevezető eredményekhez vezethetnek (Confalonieri et al., 2016; Shepherd et al., 2020). A döntéstámogatás minősége ezért nem haladhatja meg a bemeneti adatrendszer minőségét.

További kihívás a modellek interpretálhatósága. Míg a mechanisztikus modellekben általában világos, hogy egy paraméter milyen élettani vagy környezeti folyamatot reprezentál, addig sok gépi tanulási modell „fekete doboz” jellegű, ami csökkentheti a felhasználói bizalmat és a szaktanácsadási beágyazhatóságot (Rudin, 2019). Nagy jelentősége van ezért azoknak a megoldásoknak, amelyek növelik az algoritmusok értelmezhetőségét, vagy olyan hibrid architektúrát alkalmaznak, ahol az AI nem önmagában, hanem jól értelmezhető szakmai keretben működik.

A gyakorlati elterjedést gazdasági és kompetenciajellegű akadályok is lassítják. A precíziós technológiák és digitális rendszerek bevezetése beruházási költséggel jár, a modellek működtetése és az eredmények értelmezése pedig speciális tudást igényel (Paustian & Theuvsen, 2017). Emiatt a döntéstámogatás jövője nem pusztán technológiai kérdés, hanem oktatási, adatpolitikai és intézményi fejlesztési feladat is.

Következtetések

A tanulmány következtetései több, egymással összefüggő megállapításban ragadhatók meg. A mechanisztikus termésmoდეlek akkor növelik a döntéstámogatás megbízhatóságát, ha a bemeneti meteorológiai, talaj- és menedzsmentadatok kellően részletesek, a genotípus- és helyspecifikus

paramétereket kalibrálták, a modellkimeneteket pedig független üzemi vagy kísérleti adatokkal validálták. A precíziós adatforrások érdemi többletet akkor biztosítanak, ha a szenzoros, UAV- és hozamtérképezési adatok minőségellenőrzöttek, térben és időben összehangoltak, és a döntési egységekhez – kezelési zónákhoz, parcellákhoz vagy gazdasági szinthez – igazítottan kerülnek értelmezésre. Az AI- és gépi tanulási módszerek prediktív értéke akkor hasznosítható biztonságosan, ha reprezentatív tanítóadatokra épülnek, független validációval rendelkeznek, és az eredmények interpretálhatósága elegendő a szaktanácsadói és gazdálkodói döntésekhez.

A legnagyobb gyakorlati potenciált azok a hibrid rendszerek jelentik, amelyekben a mechanisztikus modellek oksági keretet, a precíziós adatok helyspecifikus visszacsatolást, az AI pedig adaptív korrekciót és mintázatfelismerést biztosít. Hazai környezetben a megbízható döntéstámogatás kulcsa a lokalizáció: a tartamkísérleti és üzemi adatbázisok standardizált gyűjtése, a magyar agroökológiai viszonyokra végzett kalibráció és validáció, valamint a felhasználói kompetenciák fejlesztése. E feltételek együttes teljesülése esetén a döntéstámogató rendszerek érdemben hozzájárulhatnak a versenykéesebb, fenntarthatóbb és alkalmazkodóbb mezőgazdasági termeléshez.

IRODALOM

- Antle, J. M., Jones, J. W. & Rosenzweig, C. (2017). Next generation agricultural system models and knowledge products: Synthesis and strategy. *Agricultural Systems*, 155, 179–185. <https://doi.org/10.1016/j.agsy.2017.05.006>
- Berzsenyi, Z., Árendás, T., Bónis, P., Micskei, G. & Sugár, E. (2011). Long-term effect of farmyard manure and mineral fertiliser on the yield and yield stability of maize (*Zea mays* L.) in dry and wet years. *Acta Agronomica Hungarica*, 59(4), 303–315. <https://doi.org/10.1556/AAgr.59.2011.4.2>
- Boote, K. J., Jones, J. W. & Pickering, N. B. (1996). Potential uses and limitations of crop models. *Agronomy Journal*, 88(5), 704–716. <https://doi.org/10.2134/agronj1996.00021962008800050005x>

- Confalonieri, R., Orlando, F., Paleari, L., Stella, T., Gilardelli, C., Movedi, E., Pagani, V., Cappelli, G., Vertemara, A., Alberti, L., Alberti, P., Atanassiu, S., Bonaiti, M., Cappelletti, G., Ceruti, M., Confalonieri, A., Corgatelli, G., Corti, P., Dell'Oro, M., Ghidoni, A., Lamarta, A., Maghini, A., Mambretti, M., Manchia, A., Massoni, G., Mutti, P., Pariani, S., Pasini, D., Pesenti, A., Pizzamiglio, G., Ravasio, A., Rea, A., Santorsola, D., Serafini, G., Slavazza, M. & Acutis, M. (2016). Uncertainty in crop model predictions: What is the role of users? *Environmental Modelling & Software*, 81, 165–173. <https://doi.org/10.1016/j.envsoft.2016.04.009>
- Fejér, P., Széles, A., Ragán, P., Juhász, C., Horváth, É. & Rátonyi, T. (2025). Predicting maize yield with a multilayer perceptron (MLP) model using multivariate field data. *Precision Crop Production*, 1(01). <https://doi.org/10.65006/pcp.v1i01.15904>
- Ferentinos, 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>
- Gebbers, R. & Adamchuk, V. I. (2010). Precision agriculture and food security. *Science*, 327(5967), 828–831. <https://doi.org/10.1126/science.1183899>
- Godwin, R. J., Wood, G. A., Taylor, J. C., Knight, S. M. & Welsh, J. P. (2003). Precision farming of cereal crops: A review of a six year experiment to develop management guidelines. *Biosystems Engineering*, 84(4), 375–391. [https://doi.org/10.1016/S1537-5110\(03\)00031-X](https://doi.org/10.1016/S1537-5110(03)00031-X)
- Hatfield, J. L., Boote, K. J., Kimball, B. A., Ziska, L. H., Izaurralde, R. C., Ort, D. R., Thomson, A. M. & Wolfe, D. (2011). Climate impacts on agriculture: Implications for crop production. *Agronomy Journal*, 103(2), 351–370. <https://doi.org/10.2134/agronj2010.0303>
- Illés, Á., Horváth, É., Bojtó, C., Zagyai, P. & Széles, A. (2025a). Precision maize stand analysis using remote sensing methods: plant density measurement with spectral data integration. *Precision Crop Production*, 1(01). <https://doi.org/10.65006/pcp.v1i01.15901>
- Illés, Á., Bojtó, C., Harsányi, E., Nagy, J., Lengyel, L. & Széles, A. (2025b). Optimizing Nitrogen Fertilization in Maize Production to Improve Yield and Grain Composition Based on NDVI Vegetation Assessment. *Agriculture*, 15(21), 2279. <https://doi.org/10.3390/agriculture15212279>
- Jeong, J. H., Resop, J. P., Mueller, N. D., Fleisher, D. H., Yun, K., Butler, E. E., Timlin, D. J., Shim, K. M., Gerber, J. S., Reddy, V. R. & Kim, S. H. (2016). Random forests for global and regional crop yield predictions. *PLoS ONE*, 11(6), e0156571. <https://doi.org/10.1371/journal.pone.0156571>
- Jin, X., Kumar, L., Li, Z., Feng, H., Xu, X., Yang, G. & Wang, J. (2018). A review of data assimilation of remote sensing and crop models. *European Journal of Agronomy*, 92, 141–152. <https://doi.org/10.1016/j.eja.2017.11.002>

- Jones, J. W., Hoogenboom, G., Porter, C. H., Boote, K. J., Batchelor, W. D., Hunt, L. A., Wilkens, P. W., Singh, U., Gijsman, A. J. & Ritchie, J. T. (2003). The DSSAT cropping system model. *European Journal of Agronomy*, 18(3–4), 235–265. [https://doi.org/10.1016/S1161-0301\(02\)00107-7](https://doi.org/10.1016/S1161-0301(02)00107-7)
- Jones, J. W., Antle, J. M., Basso, B., Boote, K. J., Conant, R. T., Foster, I., Godfray, H. C. J., Herrero, M., Howitt, R. E., Janssen, S., Keating, B. A., Munoz-Carpena, R., Porter, C. H., Rosenzweig, C. & Wheeler, T. R. (2017). Toward a new generation of agricultural system data, models, and knowledge products: State of agricultural systems science. *Agricultural Systems*, 155, 269–288. <https://doi.org/10.1016/j.agsy.2016.09.021>
- Kamilaris, A. & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Keating, B. A., Carberry, P. S., Hammer, G. L., Probert, M. E., Robertson, M. J., Holzworth, D., Huth, N. I., Hargreaves, J. N. G., Meinke, H., Hochman, Z., McLean, G., Verburg, K., Snow, V., Dimes, J. P., Silburn, M., Wang, E., Brown, S., Bristow, K. L., Asseng, S., Chapman, S., McCown, R. L., Freebairn, D. M. & Smith, C. J. (2003). An overview of APSIM, a model designed for farming systems simulation. *European Journal of Agronomy*, 18(3–4), 267–288. [https://doi.org/10.1016/S1161-0301\(02\)00108-9](https://doi.org/10.1016/S1161-0301(02)00108-9)
- Kitchen, N. R., Sudduth, K. A., Drummond, S. T., Scharf, P. C., Palm, H. L., Roberts, D. F. & Vories, E. D. (2010). Ground-based canopy reflectance sensing for variable-rate nitrogen corn fertilization. *Agronomy Journal*, 102(1), 71–84. [10.2134/agronj2009.0114](https://doi.org/10.2134/agronj2009.0114)
- Lengyel, L., Széles, A., Bojtor, C., Harsányi, E., Nagy, J. & Illés, Á. (2025). NDVI és terméshozam összefüggésvizsgálata kukoricában különböző fenológiai fázisokban eltérő repülési beállításokkal. *Növénytermelés*, 74(3), 31–50.
- Li, Z., Nie, Z. & Li, G. (2024). Integrating crop modeling and machine learning for the improved prediction of dryland wheat yield. *Agronomy*, 14(4), 777. <https://doi.org/10.3390/agronomy14040777>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S. & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674. <https://doi.org/10.3390/s18082674>
- Mohanty, S. P., Hughes, D. P. & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419. <https://doi.org/10.3389/fpls.2016.01419>
- Nagy, J. (2021). *Kukorica. A nemzet aranya. Ételmiszer, takarmány, bioenergia*. Szaktudás Kiadó, Budapest.
- Nyéki, A. É. (2016). *A precíziós növénytermesztés és a fenntartható mezőgazdaság kapcsolata*. PhD értekezés, Széchenyi István Egyetem. 179.

- Nyéki, A., Gombos, B. & Nagy, J. (2020). Evaluating the efficiency of nitrogen fertilisation using the CERES-Maize model and the long-term experiment results of Debrecen-Látókép. *Növénytermelés*, 61(1), 33–52.
- Nyéki, A. & Neményi, M. (2022). Crop Yield Prediction in Precision Agriculture. *Agronomy*, 12(10), 2460. <https://doi.org/10.3390/agronomy12102460>
- Paustian, M. & Theuvsen, L. (2017). Adoption of precision agriculture technologies by German crop farmers. *Precision Agriculture*, 18, 701–716. <https://link.springer.com/article/10.1007/s11119-016-9482-5#citeas>
- Pereira, H. & Marques, R. C. (2017). An analytical review of irrigation efficiency measured using deterministic and stochastic models. *Agricultural Water Management*, 184, 28–35. DOI: 10.1016/j.agwat.2016.12.019
- Raes, D., Steduto, P., Hsiao, T. C. & Fereres, E. (2009). AquaCrop – The FAO crop model to simulate yield response to water. *Agronomy Journal*, 101(3), 426–437. <https://doi.org/10.2134/agronj2008.0218s>
- Raes, D., Steduto, P., Hsiao, T. C., & Fereres, E. (2012). Reference manual: AquaCrop version 4.0. FAO, Land and Water Division, Rome, Italy.
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1, 206–215. <https://www.nature.com/articles/s42256-019-0048-x#citeas>
- Russell, S. J. & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach* (3rd ed.). Prentice Hall. 1132.
- Shepherd, M., Turner, J. A., Small, B. & Wheeler, D. (2020). Priorities for science to overcome hurdles thwarting the full promise of the digital agriculture revolution. *Journal of the Science of Food and Agriculture*, 100(14), 5083–5092. <https://doi.org/10.1002/jsfa.9346>
- Soussi, A., Zero, E., Sacile, R., Trincherio, D. & Fossa, M. (2024). Smart sensors and smart data for precision agriculture: A review. *Sensors*, 24(8), 2647. <https://doi.org/10.3390/s24082647>
- Steduto, P., Hsiao, T. C., Raes, D. & Fereres, E. (2009). AquaCrop – The FAO crop model to simulate yield response to water: I. Concepts and underlying principles. *Agronomy Journal*, 101(3), 426–437. https://ui.adsabs.harvard.edu/link_gateway/2009AgrJ..101..426S/doi:10.2134/agronj2008.0139s
- Van Diepen, C. A., Wolf, J., Keulen, H. & Rappoldt, C. (1989). WOFOST: a simulation model of crop production. *Soil Use and Management*, 5(1), 16–24. <https://doi.org/10.1111/j.1475-2743.1989.tb00755.x>
- van Ittersum, M. K., Leffelaar, P. A., van Keulen, H., Kropff, M. J., Bastiaans, L. & Goudriaan, J. (2003). On approaches and applications of the Wageningen crop models. *European Journal of Agronomy*, 18(3–4), 201–234. [https://doi.org/10.1016/S1161-0301\(02\)00106-5](https://doi.org/10.1016/S1161-0301(02)00106-5)

- Verdouw, C. N., Wolfert, S., Beulens, A. J. M. & Rialland, A. (2016). Virtualization of food supply chains with the internet of things. *Journal of Food Engineering*, 176, 128–136. <https://doi.org/10.1016/j.jfoodeng.2015.11.009>
- Wolfert, S., Ge, L., Verdouw, C. & Bogaardt, M. J. (2017). Big data in smart farming – A review. *Agricultural Systems*, 153, 69–80. <https://doi.org/10.1016/j.agsy.2017.01.023>
- Yahui, G., Fanghua, H., Xuan, Z., Yuhong, H. & Yongshuo, H. F. (2024). Improving maize yield estimation by assimilating UAV-based LAI into WOFOST model. *Field Crops Research*, 315. <https://doi.org/10.1016/j.fcr.2024.109477>
- 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(4), 785. <https://doi.org/10.3390/agronomy12040785>
- Zhang, C. & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. *Precision Agriculture*, 13(6), 693–712. <https://doi.org/10.1007/s11119-012-9274-5>
- Zhang, M., Shi, W. & Xu, Z. (2020). Systematic comparison of five machine-learning models in classification and interpolation of soil particle size fractions using different transformed data. *Hydrology and Earth System Sciences*, 24, 2505–2526. <https://doi.org/10.5194/hess-24-2505-2020>

A szerző levelezési címe – Address of the author:

Dr. Nyéki Anikó Éva
Széchenyi István Egyetem AKMK
Bioműszaki és Precíziós Technológiai Tanszék
Mosonmagyaróvár
Vár tér 2.
9200
nyeki.aniko@sze.hu

