



Szántóföldi növények operatív termésbecslése gépi tanulással

Kovács Attila Viktor

HungaroMet Nonprofit Zrt., kovacs.av@met.hu


DOI: 10.56474/légkor.2026.1.3

A mezőgazdasági termés időben történő előrejelzése kulcsfontosságú nemcsak az élelmezés-biztonság, az agrárgazdasági tervezés és a klímakockázatok kezelése szempontjából, hanem a piaci döntések – például az értékesítés időzítése vagy a nemzetközi árupiaci folyamatokra való reagálás – szempontjából is, hiszen ez utóbbi esetben konkrét, pénzben mérhető, rövidtávú hatása lehet. A hagyományos statisztikai becslések mellett egyre nagyobb teret nyernek a gépi tanuláson alapuló módszerek, amelyek képesek a mezőgazdasági és a meteorológiai adatok komplex kapcsolatainak feltárására. Vizsgálatunk célja az volt, hogy több növénykultúrára (őszi búza, kukorica, napraforgó) építsünk olyan gépi tanulási alapú modellt, amely a vegetációs időszak során folyamatosan frissülő bemeneti adatok (5 és 8 napos hőmérséklet- és csapadékmutatók, talajnedvesség, műholdas vegetációs indexek) alapján ad megbízható termés-előrejelzést. Az eredmények alapján nem a legtöbb prediktort tartalmazó modell adja a legjobb teljesítményt, és a leginformatívabb prediktorváltozók növénykultúránként jelentősen eltérnek. A fejlesztés során célunk egy operatív, valós idejű előrejelző rendszer létrehozása volt.

Operational crop yield estimation for field crops using machine learning

Timely forecasting of agricultural yields is crucial not only for food security, agricultural economic planning, and the management of climate risks, but also for market decisions – such as timing sales or responding to international commodity-market dynamics – since in the latter case it can have a concrete, monetarily measurable short-term impact. Alongside traditional statistical estimates, machine-learning methods are gaining increasing prominence, as they are capable of uncovering the complex relationships between agricultural and meteorological data. The goal of our study was to develop machine-learning-based models for multiple crop types (winter wheat, maize, sunflower) that can provide reliable yield forecasts based on continuously updated input data throughout the growing season (5- and 8-day temperature and precipitation indicators, soil moisture, and satellite-derived vegetation indices). Our results show that the model incorporating the largest number of predictors does not necessarily deliver the best performance, and that the most informative predictor variables differ substantially between crop types. During the development, our goal was to create an operational, real-time forecasting system.

A szántóföldi növénytermesztésben évről évre jelentős termésingadozás tapasztalható, amelynek elsődleges oka az időjárási körülmények változékonysága. A hozamok mellett a termés minősége is erősen ingadozik, ami közvetlenül befolyásolja a piaci kínálatot és ezen keresztül az árakat is: jó években túlkínálat, kedvezőtlen években hiány alakulhat ki, így a felvásárlási árak szélsőségesen kilenghetnek (1. ábra). Ennek következményei messze túlmutatnak az egyes gazdaságok szintjén: a termelők jövedelmezősége, a felvásárlók készlet- és beszerzési stratégiái, a végfelhasználók ellátásbiztonsága és árszintje, valamint az állami piacszervezési és kockázatkezelési döntések egyaránt érzékenyek a várható termés mennyiségére. A biztosítók számára pedig a kárriskó és a díjkalkuláció miatt kulcskérdés, hogy a terméskilátások már a vegetáció során számszerűsíthetők legyenek. Minden érintett szeretne a vegetációs időszakban minél korábbi és minél pontosabb termésbecslést.



1. ábra. Kukorica országos termésátlagok és felvásárlási árak 2000 és 2024 között (forrás: KSH).

A hatályos 5/2018. (II. 23.) FM rendelet előírja, hogy a várható termés felmérése és megismerése érdekében termésbecslést, állapotminősítést, valamint a mezőgazdasági munkák állásáról szóló jelentést és tájékoztató jelentést kell készíteni. A jelentések elkészítéséről a Nemzeti Agrárgazdasági Kamara (NAK) gondoskodik.

Nemzetközi szinten elérhetőek rendszeresen frissülő, nyilvánosan publikált termésbecslések hazánkra vonatkozóan. Ilyen, folyamatosan közölt előrejelzéseket készítő többek között az Európai Bizottság Közös Kutatóközpontjának JRC MARS havi kiadványa, valamint az Egyesült Államok Mezőgazdasági Minisztériuma (USDA) is.

A termésbecslési eljárások a gyakorlatban több nagy módszercsoportba sorolhatók (Szász, 1988.). Az empirikus módszerek jellemzően helyszíni megfigyelésekre, állományminősítésre és szakértői tapasztalatra építenek, ugyanakkor az eredményük érzékeny lehet a mintavételre és a szubjektív tényezőkre. A statisztikai módszerek a hosszú időre vonatkozó meteorológiai és a termés adatok kapcsolatát becsülik, de az összefüggések sokszor csak korlátozottan vihetők át szélsőséges vagy megváltozó körülmények közé. Az agrometeorológiai modellezés ezzel szemben a növény–talaj–légtér rendszer folyamatait írja le (vízháztartás, hő és sugárzási viszonyok, fejlődési ütem), így fizikai-biológiai értelmezhetőséget ad a becslésnek, ugyanakkor nagyobb adat- és paramétrázási igénnyel jár (Dunkel és Zárbok, 1980).

A termésbecslő eljárások fejlődése

Termésbecsléssel, termés-előrejelzéssel régóta foglalkoznak a szakemberek, ezek hosszú időn át szubjektívek voltak (Simon, 1974.). A termés időjárási adatokra épülő előrejelzése Magyarországon az 1930-as években indult meg. Berényi (1931) korrelációs módszert alkalmazott a terméseredmények és az időjárási elemek közötti összefüggés vizsgálatában, majd a kukorica terméshozamának előrejelzését is erre alapozta (Berényi, 1945). Szász (1961), majd Dunay (1974) az időjárási elemeknek a rizs termésére gyakorolt hatását vizsgálta statisztikai módszerekkel. Szalay (1981) a kukorica termésátlagának becslését végezte megyénként három független változós másodfokú polinom segítségével 1951–75 közötti 25 éves tanuló adatsoron havi csapadékösszeg, havi középhőmérséklet és havi napfénytartam összeg adatok segítségével. Termésbecslést az 1976–81 évekre készített, az átlagos hiba 10% alatt alakult. Kmettyó (1984) a kukorica területi termésátlagának kapcsolatát vizsgálta 22 meteorológiai paraméter segítségével Tolna vármegyére vonatkozóan 10 éves időszakra (1970–1979), majd ez alapján az 1980–1982 évekre készített előrejelzést. Megalapította, hogy a tényleges terméshozamot azokban az években tudta viszonylag jó eredménnyel közelíteni, amikor a tenyészidőszak időjárása kedvezően alakult, tartós szárazság, aszály nem fordult elő. Vizsgálatok zajlottak többek között a vetőburgonya (Ajtay et al., 1984) és a burgonya (Bussay, 1992) terméshozama és a meteorológiai tényezők kapcsolatának becslésére, de a fűszerpaprika festéktartalmának és termésátlagának előrejelzésére (Erdős és Lambert, 1987) is.

Az 1970-es évektől a műholdas távérzékelésre épülő növény-monitoring egyre fontosabbá vált, miközben kulcskérdés (élelmezésbiztonság, piaci bizonytalanságok, döntéstámogatás) lett a közel valós idejű, megbízható információ a kultúrnövények

állapotáról és a várható termésről (Wu *et al.*, 2023). Bár ma már a műholdas adatok mennyisége és hozzáférhetősége, ill. az adatfeldolgozási kapacitás egyre kisebb korlátot jelentenek, a termésbecslő módszerek még nem elég objektívek és kiforrottak, ezért az operatív alkalmazhatóságuk és az eredményeik megbízhatósága sok esetben korlátozott. A gyakran használt indikátorok (pl. NDVI-anomáliák) sokszor csak kvalitatív értékelést adnak, nem fordíthatók könnyen „érthető” és mennyiségileg értelmezett növényállapot-információra, és a stresszhatások (aszály, tápanyaghiány, kártevők/betegségek) szétválasztása is nehéz. A növényállomány megfigyelés egyik leggyengébb eleme a termés hozam előrejelzés a nagy bizonytalanság miatt, különösen szélsőséges időjárási helyzetekben.

Az EU-28 országaira vizsgálták, hogy a JRC MARS M-CYFS rendszerében futó WOFOST növénymodellből származó prediktorok és néhány egyszerű, kumulált meteorológiai mutató mennyire képes előrejelezni a termésingadozást, 10 napos léptékben az 1988–2015 közötti időszoron (Lecerf *et al.*, 2019). Megállapították, hogy a növénymodell-alapú prediktorok általában következetesebbek és több hozamvariabilitást magyaráznak, különösen a vízstressznek kitett években, ugyanakkor a nedves/„túl sok víz” helyzetekhez kötődő folyamatok és az agrotechnikai tényezők (öntözés, tápanyagellátás, fajtaválasztás) hiányos kezelése korlátozza az előrejelzés teljesítményét.

Az elmúlt években számos búzára vonatkozó termésbecslő vizsgálat zajlott műholdas mérések felhasználásával hazánkban. MODIS műholdas mérésekre alapozva, az azokból számított vegetációs indexek (NDVI, GN) felhasználásával készítettek búza termés hozam becslést 10 éves (Kern *et al.*, 2014), illetve 13 éves adatsorok alapján (Bognár *et al.*, 2017).

Ahogy a gépi tanulás egyre könnyebben elérhetővé vált, a termésbecslő eljárások is egyre nagyobb mértékben alkalmazták ezt szerte a világon. Kínában például járási léptékben vizsgálták az őszi búza termésének előrejelezhetőségét többforrású adatok integrálásával, nyolc gépi tanulási algoritmus összevetésével (Han *et al.*, 2020). Fő megállapításaik, hogy a termés 1–2 hónappal betakarítás előtt is nagy pontossággal becsülhető (jellemzően $R^2 > 0,75$ és $< 10\%$ hiba), általában a Random Forest modell adta a legjobb eredményeket, a hosszabb (október–május) időablak javítja a teljesítményt, és az EVI műholdas index bizonyult a leginformatívabb prediktornak, miközben a pontosság régióként is eltért. A módszert továbbfejlesztették, a klíma- és térbeli információk érdemben javították a becslést, a többforrású (műhold + klíma + lokáció)

kombináció adta a legjobb teljesítményt, és a modell már nagy léptékben is kb. két hónappal a betakarítás előtt jó előrejelzést ad: a pontosság tavaszra gyorsan nő, március körül $R^2 \approx 0,87$ és $RMSE \approx 489$ kg/ha (Sun *et al.*, 2022).

A konkrét, esettanulmány-szerű termésbecslő módszerek nem vihetők át más növénykultúrára és más területekre, így fölmerült az igény általánosabb eljárások kidolgozására is. Növényeszimulációs kimenetek, valamint a JRC MCYFS adatbázisából származó időjárási, távérzékelt és talajadatok felhasználásával előállított prediktorok segítségével a növénytermesztési modellezést gépi tanulással kombinálva nagytérségű termés hozam-előrejelzésre alkalmas gépi tanulási munkafolyamatot hoztak létre, hogy kis konfigurációs módosításokkal eltérő növénykultúrák és különböző országok esetén is felhasználható legyen (Paudel *et al.*, 2021).

Vizsgálatok zajlottak Európában a gépi tanulással előrejelezett regionális becslések országos szintű összeállításánál fellépő tipikus problémák (a területarányos aggregálásból származó hibák felhalmozódása, illetve az a jelenség, hogy a kedvezőtlen régiók hatását más régiók „kiátlagolják”, így a nemzeti átlag elrejtje a térbeli különbségeket) csökkentésére is (Paudel *et al.*, 2022).

Anda és munkatársai (2024) kimutatták, hogy az őszi búza termését és a terméskockázatot érdemben befolyásolják a meteorológiai tényezők, és néhány alapváltozóra (pl. léghőmérséklet, relatív nedvesség) építve a fuzáriumos kalászfertőzés kockázata is megfelelően modellezhető.

Adatok és módszer

A vizsgálatunk célja egy szezon közben folyamatosan frissülő, operatíván működő, szántóföldi kultúrák termés hozamát országos átlagban becslő modell fejlesztése volt, amely a hazai adatfolyamokra támaszkodva, a vegetáció előrehaladtával mind több mérési és távérzékelt információt épít be, és így időben egyre stabilabb, gyakorlatban felhasználható előrejelzést ad. A prediktorok közvetlenül a szezonális állapotváltozások követésére és az operatív frissíthetőségre vannak kialakítva.

A termésbecslési rendszerünk több, egymást kiegészítő adatforrásra épül. A prediktor változók között szerepelnek rövid időablakokra (5 nap) számított hőmérséklet, csapadék és talajnedvesség adatok, valamint az NDVI műholdas vegetációs index (8 nap), amely a növényállomány aktuális kondícióját és fenológiai alakulását követi. A célváltozót (termés hozam) a KSH hivatalos termésstatisztikái biztosítják. A modellezés során kiemelt figyelmet fordítunk az adatok időbeli konzisztenciájára és az operatív frissítésből adódó

követelményekre. Fontos hangsúlyozni, hogy a termést nem kizárólag az időjárás határozza meg, léteznek olyan tényezők, melyekről nincsenek adataink. Többek között a fajtaválasztás, a tápanyagellátás, az öntözés, a növényvédelem, illetve a technológiai és gazdálkodási döntések érdemben módosíthatják a hozamot, ezért az eredmények értelmezésénél és értékelésénél ezt a korlátot végig szem előtt kell tartanunk.

A modell kialakításához a mesterséges intelligencia egyik ágához tartozó gépi tanulás (Machine Learning: ML) módszertanát használtuk: olyan adatvezérelt eljárásokat, amelyek képesek a bemeneti változók és a hozam közötti – gyakran nemlineáris – összefüggések megtanulására. Nincs szükség a folyamatok ok-okozati szabályszerűségeinek leírására, hanem ezek a gépi tanulási eljárások a kényszer (esetünkben az időjárási adatok) és a rendszer által erre adott válasz (termés) közötti szabályokat képesek közelítőleg meghatározni (Jordan and Mitchell, 2015). A gépi tanulás egyik ága a mélytanulás, amely neurális hálózatokra épül, és különösen akkor előnyös, ha a bemenetek sokrétűek és összetett mintázatok rejtőznek bennük (Schmidhuber, 2015). A gépi tanulási módszerek gyakorlati alkalmazását az is megkönnyítette, hogy az elmúlt években széles körben hozzáférhetővé váltak a megbízható, nyílt forráskódú eszköztárak (Nguyen et al., 2019, Harris et al., 2020, Virtanen et al., 2020).

A modellezés során több, egymást kiegészítő algoritmust alkalmaztunk, mert a különböző modellek eltérő erősségekkel rendelkeznek. A Random Forest sok döntési fa átlagolásával robusztus, jól általánosító alapmodellt ad, amely képes a változók kölcsönhatásait is megragadni. Az XGBoost és a LightGBM gradiens-boostolt faegyüttesek, míg a neurális hálózatok (Neural Network) rugalmasan tanulnak összetett mintázatokat. A különböző modellek előrejelzéseit átlagolt, együttes (ensemble) megközelítésben is kombináltuk (a három legjobb modellt), mert így a hibák részben „kioltják” egymást, illetve a becslés jellemzően stabilabbá és megbízhatóbbá válik operatív környezetben.

A gépi tanulási modellek hozzáadott értékét több egyszerű bázis-előrejelzéshez viszonyítottuk. Referenciaként alkalmaztuk az 5 éves mozgóátlagot, a perzisztencia-előrejelzést (az előző évi hozam átvitele), valamint egy lineáris trendmodellt. E mellett a szezon közbeni operatív környezethez kapcsolódó összehasonlításként a JRC (MARS) havi termés-előrejelzéseit is bevontuk.

Az adatok a 2003-2024 közötti évekre országos átlagban, illetve összegben álltak rendelkezésre, mely 22 évet két részre, egy tanuló és egy teszt időszakra osztottunk föl. A 2025-ös évben a szezon során öt,


illetve nyolc naponta frissítettük a modellt az aktuális adatokkal, a szezon hátralévő részére pedig az előző öt év átlagát használtuk előrejelzésül. Őszi búza, kukorica és napraforgó kultúrára állítottunk föl modelleket. Növénykultúránként megvizsgáltuk azt is, hogy a tenyészidőszaknak mely része az, amely alapján a legjobb termésbecslést lehet készíteni.

Őszi búza termésbecslés


Az őszi búza termésbecslésére a március-június közötti időszak mutatkozott a leginformatívabbnak. A 2019–2024-es tesztidőszakon az ensemble modell adta a legpontosabb becslést (átlagos abszolút hiba: 183,1 kg/ha), jelentősen fölülmúlva a bázis-előrejelzéseket (2. ábra). Így a továbbiakban az ensemble modell eredményeit fogjuk vizsgálni.

A tesztidőszakra vonatkozó becslések alapján a 2021-es kilógó évet nem számítva a modell relatív hibája 3% alatti (3. ábra). 2021-ben jelentős az alábecslés (-13,4%), melynek több oka is lehet. Abban az évben a tél végén és a tavasz elején jelentős volt a belvízzel elöntött területek nagysága, a tartós vízborítás hatására a vetés sok táblában nagy foltokban kipusztult.


A 2025-ös folyamatosan frissülő ensemble modell becslése március elején az öt éves átlag szintjéről indul, a bő márciusi csapadék és az átlagosnál melegebb idő hatására május közepéig emelkedik (4. ábra), majd a kibontakozó aszály miatt június végéig folyamatosan csökken. Június végén, az aratás kezdetekor az ensemble modell által becslött országos termésátlag 72 kg/ha (1,3%) mértékben haladta meg



2. ábra. Búza termésátlag előrejelzések hibái (RMSE: Root Mean Squared Error – a négyzetes hiba átlagának négyzetgyöke, MAE: Mean Absolute Error – átlagos abszolút hiba, R2: determinációs együttható).




3. ábra. A búza országos termésátlagának különböző modellekkel előrejelzett értékei a tesztidőszak során és a tényleges hozamok.



4. ábra. A búza országos termésátlagának előrejelzése folyamatos frissítéssel a 2025-ös szezonban.

a tényleges hozamot. A legjobb becslést az öt éves átlag adta, míg a többi modell, köztük a JRC előrejelzése is lényegesen gyengébben teljesített.

A számszerű becslésekkel összevetettük a HungaroMet agrometeorológiai elemzéseiben operatívan megjelenő őszi búzára vonatkozó éves NDVI menet grafikonokat (5. ábra). Kvalitatívan ezek a grafikonok is egy átlaghoz közeli termést sejtetnek.



5. ábra. Az NDVI index éves menete 8 véletlenszerűen kiválasztott őszi búza táblára a Dunántúl délkeleti felén a 2024-25-ös tenyészidőszak során egy kifejezetten jó és egy kifejezetten gyenge évjáráthoz viszonyítva.


Kukorica termésbecslés

A kukorica termésbecslésénél a három nyári hónap adataival dolgoztunk. A 2020–2024-es tesztidőszakon a búzához hasonlóan itt is az ensemble modell adta a legpontosabb becslést (átlagos abszolút


hiba: 424 kg/ha), jelentősen fölülmúlva a bázis-előrejelzéseket (6. ábra). Ennél a kultúránál is az ensemble modellt használtuk a gyakorlatban.

A tesztidőszak alatt a modell relatív hibája 7% alatti, csak a 2022-es rekord aszályos évben magasabb ennél (7. ábra). A rekord alacsony terméshozamot az ensemble modell becslése közelítette meg legjobban annak ellenére, hogy a tanuló időszak során ilyen alacsony hozammal nem találkozott.

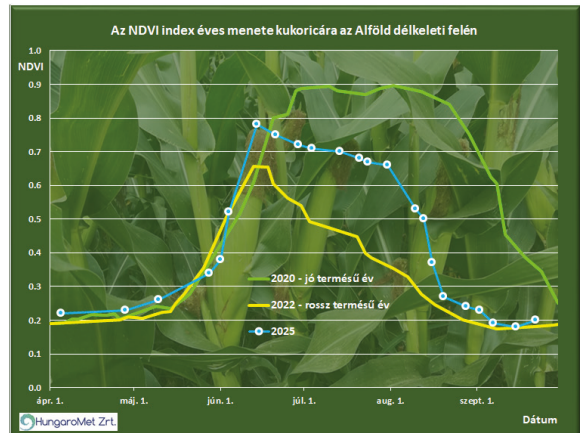
A 2025-ös öt naponta folyamatosan frissülő becslés június elején az ötéves átlag szintjéről indul, majd gyakorlatilag a szezon végéig folyamatosan csökken a már júniusban kialakuló és a nyár végéig kitartó aszály hatására (8. ábra). Mivel a cikk írásakor még mindig nincs hivatalos országos kukorica termésátlag, a modell teljesítményét csak sejtteni lehet. A médiában




6. ábra. Kukorica termésátlag előrejelzések hibái (RMSE: Root Mean Squared Error - a négyzetes hiba átlagának gyöke, MAE: Mean Absolute Error - átlagos abszolút hiba, R^2 : determinációs együttható).



7. ábra. A kukorica országos termésátlagának különböző modellekkel előrejelzett értékei a tesztidőszak során és a tényleges hozamok.




9. ábra. Az NDVI index éves menete 8 véletlenszerűen kiválasztott kukoricatáblára az Alföld délkeleti felén a 2024-25-ös tenyészidőszak során egy kifejezetten jó és egy kifejezetten gyenge évjáráthoz viszonyítva.



8. ábra. A kukorica országos termésátlagának előrejelzése folyamatos frissítéssel a 2025-ös szezonban.

csapadék öntözte volna az országot. A termésbecslés ebben a fiktív esetben már július közepétől meghaladja a valóságnak megfelelő értékeket, majd a szezon végére kissé csökken (10. ábra). Végül a modell szerint mintegy 1 t/ha plusz hozamot jelentett volna egy július eleji plusz 50 mm csapadék, mely országos szinten több tízmilliárd forintnak felel meg.



10. ábra. A kukorica országos termésátlagának előrejelzése folyamatos frissítéssel és július elején plusz 50 mm fiktív országos csapadékkal (ML +50 mm) a 2025-ös szezonban.


megjelenő információk szerint a 2025-ös tényleges termésátlag valahol 3900 és 5200 kg/ha között lehet (4500 kg/ha körül), a becslő eljárások közül egyedül az ensemble modell várta ebbe a sávba a termésátlagot, a JRC becslése ezt jóval meghaladta.

A számszerű becslésekkel a kukoricára vonatkozó éves NDVI menet grafikonokat is összevethetjük (9. ábra). Az Alföld délkeleti részét jellemző görbe kvalitatívan nagyon gyenge, de a 2022-es évinél jobb termést sejtet az ensemble modell eredményével összhangban.

A kukorica akkor fejlődne optimálisan, ha júliusban és augusztusban is 100-100 mm csapadékot kapna (Nagy, 2021). Mivel a 2025-ös év is súlyosan aszályos volt, végeztünk egy modellkísérletet. Megvizsgáltuk, hogyan alakult volna a terméshozam, ha július elején a valóságon felül átlagosan plusz 50 mm

Napraforgó termésbecslés

A napraforgó termésbecslésénél is a három nyári hónap adataival dolgoztunk. A 2020–2024-es tesztidőszakon a másik két kultúrához hasonlóan az ensemble modell adta a legpontosabb becslést




11. ábra. A napraforgó országos termésátlagának különböző modellekkel előrejelzett értékei a tesztidőszak során és a tényleges hozamok.

(átlagos abszolút hiba: 180 kg/ha), így napraforgónál is ezt használtuk a gyakorlatban.

A tesztidőszak alatt a modell relatív hibája 8% alatti, kivéve a 2022-es rekord aszályos évben, amikor 13,5% (11. ábra). A rekord alacsony termésátlagot itt is az ensemble modell becslése közelítette meg legjobban.

A 2025-ös ötnaponta folyamatosan frissülő becslés június elején az ötéves átlag szintjéről indul, de júniusban rohamosan, majd júliustól lassuló ütemben csökken az aszály hatására (12. ábra). A cikk írásakor még hivatalos országos napraforgó termésátlag sincs, a médiában megjelenő információk szerint a 2025-ös tényleges termésátlag valahol 2000 és 2500 kg/ha között lehet. Az ensemble modell a sáv alsó, míg a JRC becslés a sáv felső széléhez várja a termésátlagot.

A napraforgóra vonatkozó éves NDVI menetek egy átlagosnál valamivel gyengébb termést sejtettek.



12. ábra. A napraforgó országos termésátlagának előrejelzése folyamatos frissítéssel a 2025-ös szezonban.

Összefoglalás

A termésátlagok évről évre történő jelentős ingadozása miatt a termésbecslés nemcsak szakmai, hanem gazdasági és döntéstámogatási szempontból is indokolt feladat. Ennek megfelelően egy olyan operatív termésbecslési eljárást dolgoztunk ki, amely a vegetációs időszak során folyamatosan frissülő meteorológiai és távérzékelési információkra támaszkodik, és gépi tanulási modellekkel ad előrejelzést több szántóföldi növénykultúrára. Eredményeink azt mutatják, hogy a gépi tanulásra épülő becslések a vizsgált években érdemben felülmúlják a legalapvetőbb klimatológiai-statisztikai bázisokat (például perzisztencia, gördülőátlag, lineáris trend). A szezon közben folyamatosan frissülő modell pedig a ténylegesidőszak során is olyan pontosságot ad, amely operatív felhasználás szempontjából ígéretes. Mindez megerősíti, hogy a meteorológiai és távérzékelési adatokra épülő, szezon közben frissülő operatív termésbecslés reális és hasznos döntéstámogató eszközzé fejleszthető.

A továbblépés legfontosabb iránya az adatbázis bővítése és finomítása lehet: a jelenlegi országos idősorok mellett a vármegyei adatok bevonása javíthatja a térbeli részletességet, a bemeneti változók célzott bővítése pedig segíthet abban, hogy a modell azokban az években is javuljon, melyekben most gyengébben teljesít. Kiemelt feladat a bizonytalanságbecslés beépítése, hogy az előrejelzések ne csak egyetlen hozamértéket, hanem a döntésekhez közvetlenül használható megbízhatósági információt is adjanak. Az operatív működtetéshez szükséges a szezon közbeni, automatikusan frissülő futtatási lánc kialakítása. A meteorológiai előrejelzések beépítésével pedig a rendszer a megfigyelt múltbeli állapotot túl az időjárás várható alakulását is explicit módon figyelembe veheti.

Irodalomjegyzék

- Ajtay Á., Boncz J. és Takács F., 1984: Összefüggés a vetőburgonya termésátlaga és a meteorológiai tényezők között, *Időjárás*, 88, 238-246.
- Anda, A., Simon-Gáspár, B., Simon, S., Soós, G., and Menyhárt, L., 2024: Modeling Risk in Fusarium Head Blight and Yield Analysis in Five Winter Wheat Production Regions of Hungary, *Agriculture*, 14(7). 1093. <https://doi.org/10.3390/agriculture14071093>.
- Berényi D., 1931: Az időjárás elemek és a mezőgazdasági növények terméseredménye közötti összefüggést kutató módszerek. *Debreceni Szemle* 44, 4.
- Berényi D., 1945: A kukorica termelése és összefüggése az időjárással, Alföldi Magvető Kiadó, Debrecen.

- Bognár P., Kern A., Pásztor Sz., Lichtenberger J., Koronczay D. és Ferencz Cs., 2017: Yield estimation and forecasting for winter wheat in Hungary using time series of MODIS data, *International Journal of Remote Sensing*, 38(11), 3394–3414.
<https://doi.org/10.1080/01431161.2017.1295482>
- Bussay A., 1992: A meteorológiai tényezők hatása a burgonya terméshozamára, Beszámolók az 1988-ban végzett tudományos kutatásokról, Országos Meteorológiai Szolgálat, Budapest, 243–248.
- Dunay S., 1974: Rizs, Agroklímatalógia és Növénytermesztés, Országos Meteorológiai Szolgálat, Budapest, 41–53.
- Dunkel Z. és Zárbok Zs., 1980: Agrometeorológiai modellek alkalmazása a növény fejlődésének előrejelzésében, *Időjárás*, 84, 239–245.
- Erdős L. és Lambert K., 1987: Modellek a fűszerpaprika festéktartalmának és termésátlagának előrejelzésére, *Időjárás*, 91, 187–196.
- Han, J., Zhang, Z., Cao, J., Luo, Y., Zhang, L., Li, Z., and Zhang, J., 2020: Prediction of Winter Wheat Yield Based on Multi-Source Data and Machine Learning in China, *Remote Sensing*, 12(2), 236. <https://doi.org/10.3390/rs12020236>
- Harris, C.R., Millman, K.J., van der Walt, S.J. et al., 2020: Array programming with NumPy, *Nature*, 585, 357–362.
<https://doi.org/10.1038/s41586-020-2649-2>
- Jordan, M. I. and Mitchell T. M., 2015: Machine learning: Trends, perspectives, and prospects, *Science*, 349, 255–260. <https://doi.org/10.1126/science.aaa8415>
- Kern A., Bognár P., Pásztor Sz., Timár G., Lichtenberger J., Ferencz Cs., Steinbach P. és Ferencz O., 2014: Közvetlen vételű MODIS adatok alkalmazásai Magyarország térségére, *Távérzékelési Technológiák és Térinformatika – Remote Sensing Technologies & GIS*, 1, 5–13.
- Kmetyó K., 1984: A kukorica területi termésátlagának előrejelzése meteorológiai paraméterek segítségével, *Időjárás*, 88, 232–237.
- Lecerf, R., Ceglar, A., López-Lozano, R., Van Der Velde, M. and Baruth, B., 2019: Assessing the information in crop model and meteorological indicators to forecast crop yield over Europe, *Agricultural Systems* 168, 191–202.
<https://doi.org/10.1016/j.agsy.2018.03.002>
- Nagy J., 2021: Kukorica. Szaktudás Kiadó, Budapest.
- Nguyen, G., Dlugolinsky, S., Bobák, M., Tran V., García A., L., Heredia, I., Malík, P. and Hluchý, L., 2019: Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*, 52, 77–124.
<https://doi.org/10.1007/s10462-018-09679-z>
- Paudel, D., Boogaard, H., de Wit, A., Janssen, S., Osinga, S., Pylianidis, C. and Athanasiadis, I.N., 2021: Machine learning for large-scale crop yield forecasting, *Agricultural Systems*, 187 Article 103016.
<https://doi.org/10.1016/j.agsy.2020.103016>
- Paudel, D., Boogaard, H., de Wit, A., Janssen, S., Osinga, S., Pylianidis, C. and Athanasiadis, I.N., 2022: Machine learning for regional crop yield forecasting, *Field Crops Research*, 276 Article 108377.
<https://doi.org/10.1016/j.fcr.2021.108377>
- Schmidhuber, J., 2015: Deep learning in neural networks: An overview, *Neural Networks*, 61, 85–117.
<https://doi.org/10.1016/j.neunet.2014.09.003>
- Simon B., 1974: A termésbecslés módszerei, Mezőgazdasági Kiadó, Budapest.
- Sun, Y., Zhang, S., Tao, F., Aboelenein, R., and Amer, A., 2022: Improving Winter Wheat Yield Forecasting Based on Multi-Source Data and Machine Learning, *Agriculture*, 12(5), 571. <https://doi.org/10.3390/agriculture12050571>
- Szalay M. G., 1981: A kukorica termésátlagának becslése megyénként, három független változós másodfokú polinom segítségével, Beszámolók az 1981-ben végzett tudományos kutatásokról, Országos Meteorológiai Szolgálat, Budapest, 84–94.
- Szász G., 1961: A rizs termesztésének időjárási feltételei a fő termőterületeken, *Növénytermelés*, 10, 193–206.
- Szász G., 1988: Agrometeorológia általános és speciális. Mezőgazdasági Kiadó, Budapest, 410.
- Virtanen, P., Gommers, R., Oliphant, T.E. et al., 2020: SciPy 1.0: fundamental algorithms for scientific computing in Python. *Nature Methods*, 17, 261–272.
- Wu, B., Zhang, M., Zeng, H., Tian, F., Potgieter, A., Qin, X., Yan, N., Chang, S., Zhao, Y., Dong, Q., Boken, V., Plotnikov, D., Guo, H., Wu, F., Zhao, H., Deronde, B., Tits, L., and Loupian, E., 2023: Challenges and opportunities in remote sensing-based crop monitoring: a review, *National Science Review*. 10. <https://doi.org/10.1093/nsr/nwac290>