

Gépi látás és mesterséges intelligencia alkalmazása a precíziós növénytermesztésben

1. Bevezetés

A mesterséges intelligencia alkalmazása új lehetőségeket teremt a precíziós növénytermesztésben, különösen a nagy felbontású képi adatok időben követett feldolgozásán keresztül. A képfeldolgozó rendszerek lehetővé teszik a növényállomány egyedszintű monitorozását, amely alapot ad a fejlődési folyamatok mélyebb megértéséhez és a beavatkozások optimalizálásához.

A paradicsomnövények esetében egy többlépcsős, human-in-the-loop alapú képi desztillációs eljárást alkalmaztunk, amely strukturált tanítóadatbázist hozott létre különböző növényi jellemzők automatikus kinyeréséhez. Az így betanított modellek alkalmasak voltak levél-, virág- és termésjellemzők meghatározására, valamint időbeli trendek és korrelációk vizsgálatára, támogatva a növényfejlődés és stresszállapotok elemzését.

Ezzel párhuzamosan a gyomnövények, pontosabban az acat detektálása drónfelvételek alapján történt, ahol mélytanulási objektumdetektáló módszereket alkalmaztunk. A GPS-alapú térbeli leképezés lehetővé tette célzott kijuttatási térképek előállítását, azonban a precíziós permetezés megvalósítása során a pozicionálási pontosság és a felhasznált permetező gép további technikai kihívásokat vetett fel.

2. Anyag és Módszer

2.1. Paradicsom képszegmensek adatbázis desztillálás lépései

A vizsgálat során paradicsomnövényekhez kapcsolódó képi adatbázis építésére fókuszáltunk, amelynek célja egy osztályozó neurális hálózat betanításához szükséges, nagy mennyiségű tanító adathalmaz létrehozása volt. A mezőgazdasági képadatok annotálása jelentős időigénnyel és bizonytalansággal jár, különösen a természetes környezet komplexitása és az objektumok nehéz lehatárolhatósága miatt (J. Song et al., 2025). Ennek csökkentésére egy félautomata desztillációs eljárást dolgoztunk ki (1. ábra), amely során SAM-alapú szegmentációval több mint 50 000 képi szegmenst állítottunk elő. A szegmensekhez hagyományos és mélytanulásalapú jellemzőket


¹ Wittmann Antal Növény-, Állat- és Élelmiszer- tudományi Multidiszciplináris Doktori Iskola;

² Axiál Kft.;

Témavezető: Dr. Nyéki Anikó Éva egyetemi docens, Albert Kázmér Mosonmagyaróvári Kar Biológiai Rendszerek és Precíziós Technológiai Tanszék;

Vállalati szakértő: Dr. Mesterházi Péter Ákos, Axiál Kft. precíziós gazdálkodási csoportvezető;

rendeltünk, majd klaszterezési és felügyelt tanulási módszerekkel (RF, SVM, GBM) tisztítottuk és egységesítettük az annotációkat.



1. ábra: Adat desztilláció folyamata

A folyamat végén, minimális manuális korrekció mellett, elegendő mennyiségű és minőségű tanítóadat állt rendelkezésre egy YOLO-alapú detektáló modell betanításához. A SAM alkalmazása megszüntette a pixel-szintű annotáció szükségességét, miközben megőrizte a szegmentáció pontosságát, amely fontos a változatos morfológiájú mezőgazdasági objektumok esetében (Kirillov et al., 2023). Az eredmények igazolták, hogy a fél-automata desztillációs megközelítés hatékonyan csökkenti a manuális munkaigényt, miközben megfelelő minőségű adatokat biztosít a további detektálási feladatokhoz.

2.2. Paradicsom adatainak elemzése

A betanított YOLO-alapú detektáló modellt egy teljes tenyészidőszakot lefedő képi adathalmazon alkalmaztuk annak érdekében, hogy strukturált, térben és időben is értelmezhető kvantitatív adatokat állítsunk elő. Az adatgyűjtés során 12 paradicsomsort vizsgáltunk, soronként jellemzően 13 növényvel, növényenként 4 felvétellel, összesen 8 időpontban rögzítve a vegetációs periódus alatt. A detektálási eredményeket növény, sor és táblaszinten aggregáltuk, így csökkentve a képszintű zajt és stabil növény szintű jellemzőket képezve. Az elemzés során kizárólag 95% feletti megbízhatóságú detektálásokat vettünk figyelembe, valamint kiszűrtük a nem releváns osztályokat, így egy $12 \times 13 \times 8$ dimenziójú tér-idő adatstruktúrát hoztunk létre.

Az aggregált adatbázis lehetővé tette a növényfejlődés dinamikájának részletes vizsgálatát, beleértve a termésképződés, levélállapot és virágzás időbeli alakulását, valamint az egyedek és sorok közötti különbségeket. Az elemzések során összevont mutatókat (pl. teljes termésterhelés) is alkalmaztunk, továbbá hisztogramokkal és hőtérképekkel vizsgáltuk az eloszlásokat és térbeli mintázatokat. A módszert kiegészítettük korrelációs és késleltetett korrelációs vizsgálatokkal, amelyek feltárták a korai növekedési jellemzők és a későbbi hozam közötti összefüggéseket. Az ilyen jellegű, időben strukturált képi adatok feldolgozása különösen fontos a mezőgazdasági környezet változékonysága és komplexitása miatt, amely jelentősen befolyásolja a modellek általánosíthatóságát és az eredmények értelmezhetőségét (X. Song et al., 2025).

2.3. Acat detektálása YOLOv11 algoritmussal.

Az acat felismerése drónnal készített felvételek alapján történt, két különböző adatgyűjtési időpontban és eltérő repülési magasságokon (12 m, illetve 12 és 25 m). Ez lehetőséget adott a térbeli felbontás hatásának vizsgálatára a detektálási teljesítmény szempontjából. A nyers képeket egységes méretű csempékre bontottuk, majd mintegy 800 képet manuálisan annotáltunk, kizárólag az acat növények pontos jelölésére fókuszálva. A precíz annotáció kulcsfontosságú volt a megbízható modelltanítás érdekében, különösen korlátozott méretű adatbázis esetén (Moldvai et al., 2024).

Az annotált tanítóadatokat YOLO-alapú detektáló modellt tanítottunk, amelyet ezt követően a teljes drónos képadathalmazon alkalmaztunk. A detektálás a csempézett képeken történt, majd az eredményeket visszavetítettük az eredeti képekre. Ez biztosította a detektált egyedek pontos térbeli lokalizációját, és megalapozta a további térinformatikai feldolgozásokat, valamint a kijuttatási térképek előállítását. Az így kialakított feldolgozási lánc stabil és jól alkalmazható megoldást nyújt a drónalapú, automatizált gyomfelismeréshez.

2.4. Kijuttatási térkép generálása

A detektált acatállomány térbeli eloszlása alapján kijuttatási térképeket készítettünk a helyspecifikus permetezés támogatására. A GPS-koordinátákból shape formátumú állományokat hoztunk létre, amelyekben a detektálási és pozicionálási bizonytalanságok kezelésére pufferezónákat alkalmaztunk, biztosítva a gyomnövények megfelelő lefedését. Az ilyen helyspecifikus gyomszabályozás kulcsfontosságú a vegyszerfelhasználás csökkentésében és a környezeti terhelés mérséklésében (Zhang et al., 2021).

A kezdeti térkép több mint 7000 elkülönülő zónát tartalmazott, azonban a permetezőgép nem tudta azt közvetlenül végrehajtani, mivel a rendszer egy folytonos geometriai vonalat igényelt. Ennek megfelelően a zónákat gráfelméleti módszerekkel alakítottuk át: feszítőfákat és összekötő hidakat alkalmazva egyetlen folytonos vonalláncná formáltuk a kezelendő területeket. Az így létrehozott struktúra már kompatibilis volt a gép vezérlésével, lehetővé téve a gyakorlati alkalmazást.

2.5. Precíziós permetezés

A kijuttatási térképek gyakorlati implementációja során jelentős technikai kihívást jelentett a shape fájlok permetezőgép vezérlőrendszerébe történő integrálása. Bár az előállított állományok formailag megfelelőek voltak, a kezdeti próbák során a gép nem hajtotta végre a kijuttatási utasításokat. A probléma hátterében a vezérlőrendszer specifikus elvárásai álltak, amelyek nemcsak a fájlformátumra, hanem a geometriai reprezentáció szerkezetére és értelmezhetőségére is kiterjedtek.

A módszertani fejlesztés ezért kiterjedt a shape állományok iteratív finomhangolására és a permetezőgép működési logikájához való illesztésére. Több tesztelési ciklus és gyártói konzultáció eredményeként sikerült olyan térképi struktúrát kialakítani, amelyet a rendszer már helyesen értelmezett és végrehajtott. Ez a lépés kulcsfontosságúnak bizonyult a digitális feldolgozási lánc és a valós kijuttatási művelet közötti kapcsolat megteremtésében.

3. Eredmények

3.1. Paradicsom képszegmensek adatbázis desztillálás eredményei

A szegmentációs eljárás teljes tesztadatbázison történő alkalmazása során összesen 56 937 képi szegmenst detektáltunk, amelyek közül méret szerinti szűrést követően 50 591 bizonyult további feldolgozásra alkalmasnak. A túl kisméretű (3 715 db) szegmensek jellemzően zajból vagy fragmentált képi elemekből adódtak, míg a túl nagyméretű (2 631 db) régiók elsősorban háttérelemeket – például talajt, eget vagy környező növényállományt – reprezentáltak, ezért kizárásra kerültek. A YOLO-alapú osztályozó modell teljesítményét a manuálisan annotált tesztalmanazon értékeltük, ahol 97,4%-os Top-1 pontosságot és 98,62%-os összesített fitness értéket ért el, ami kiegyensúlyozott és megbízható működést jelez az egyes osztályok között. Az eredményeket színekódolt határoló dobozokkal jelenítettük meg a 2. ábrán (pl. virág – sárga,

egészséges levél – zöld, érett termés – piros), amely lehetővé tette a detektálások gyors vizuális ellenőrzését és a térbeli eloszlások kvalitatív értékelését.



2. ábra: Detektált célobjektumok eltérő színnel jelezve.

3.2. Paradicsom adatainak elemzése

A kialakított osztályozó keretrendszer és a betanított YOLO-modell alkalmazása lehetővé tette a növényállomány fejlődésének térbeli és időbeli dinamikájának részletes vizsgálatát. Az aggregált, időben rendezett adatok jól követték a fenológiai folyamatokat: a levélfejlődés, virágzás és termés beérésének mintázatai összhangban voltak a várható biológiai folyamatokkal. Kimutatható volt, hogy a korai növekedési jellemzők – például a levélszám és a virágok mennyisége – közepes vagy erős korrelációt mutattak a későbbi terméshozammal, így alkalmas indikátorként szolgálhatnak a hozambecsléshez. A sor- és növény szintű elemzések rámutattak az állományon belüli különbségekre is: az eltérő fejlődésű vagy stresszhatásnak kitett egyedek jól azonosíthatók voltak hisztogramok és hőtérképek segítségével, míg a korrelációs vizsgálatok feltárták az egyes fejlődési fázisok közötti összefüggéseket. Az eredmények igazolják, hogy a módszer nemcsak pontos detektálásra alkalmas, hanem strukturált, tér-idő alapú fenotipizálási adatok előállítására is, amelyek hatékonyan támogathatják a precíziós növénytermesztési döntéshozatalt.

3.3. Acat detektálása YOLOv11 algoritmussal

Az acat detektálásának eredményeit a 3. ábra szemlélteti, ahol jól látható, hogy a modell képes volt különböző fejlettségi állapotú – világosabb, sötétebb, fiatalabb és idősebb – egyedek


megbízható felismerésére, miközben a környező gyomnövényeket nem azonosította tévesen. A drónfelvételeken alapuló, YOLO-alapú egyosztályos detektáló modell légi képadatbázison került betanításra, és stabil teljesítményt nyújtott változó méretarányok, nézőpontok és háttérviszonyok mellett is. A modell mAP@0.5 értéke 78,97%, míg az mAP@0.5–0.95 értéke 56,38% volt, az F1-mutató pedig 77,2%-nak adódott (precízió: 80,2%, visszahívás: 74,5%), ami megbízható detektálási képességet jelez valós mezőgazdasági környezetben.



3. ábra: Acat detektálásának eredménye

3.4. Kijuttatási térkép generálása


A precíziós permetezési technológia során a detektált objektumok képi koordinátáinak marker-alapú geometriai vetítésével sikerült azokat valós térbeli koordinátákhoz rendelni, így kezelési zónák alakíthatók ki meghatározható pozicionálási bizonytalanság mellett. Az így kapott pozicionálási bizonytalanság alapján definiált pufferzónák biztosították, hogy a gyomok ténylegesen lefedésre kerüljenek a kijuttatás során. Emellett egy egyedi topológiai korrekciós eljárást is kidolgoztunk, amely lehetővé tette, hogy a shape állományok megfeleljenek a permetezőgép specifikus követelményeinek, elkerülve a nem kívánt kijuttatást az összekötő vonalak mentén. A területre készült kijuttatási térképek három állapota a 4. ábrán látható.



4. ábra: Shape fájlok. a) levetített keretek, b) pufferzóna alkalmazása, c) feszítőfa és hidak alkalmazása után.

3.5. Precíziós permetezés

A permetező gép adatai alapján a teljes terület mindössze 32,43%-án történt vegyszerkijuttatás, ami 67,57%-os megtakarítást jelentett a teljes felületű kezeléshez képest, ezzel igazolva a drónalapú, helyspecifikus gyomszabályozás hatékonyságát. Az 5. ábrán zölddel a tervezett kijuttatási zónák, míg sárgával a permetezőgép tényleges kijuttatási adatai láthatóak. A két térkép jól illeszkedik egymáshoz.



5. ábra: Zölddel a tervezett kijuttatási zónák, míg sárgával a permetezőgép tényleges kijuttatási adatai láthatóak

4. Összegzés

A paradicsom detektálásával kapcsolatos vizsgálatok során egy komplex képalapú adatfeldolgozási és elemzési láncot alakítottunk ki, amely a fél-automata adatbázis-építéstől a mélytanulás-alapú detektáláson át a tér-időbeli fenotipizálásig terjed. A human-in-the-loop desztillációs eljárás jelentősen csökkentette a manuális annotációs igényt, miközben nagy pontosságú tanítóadatokat biztosított. Az így betanított YOLO-modell stabilan detektálta a növényi

szerveket, és lehetővé tette időben követett, strukturált adatok előállítását, amelyekből kirajzolódtak a fejlődési mintázatok és a hozammal kapcsolatos korrelációk.

Az acat detektálására és a precíziós permetezésre kidolgozott módszer igazolta a drónalapú gyomszabályozás gyakorlati alkalmazhatóságát. A YOLO-modell megbízhatóan azonosította az acatot különböző fejlettségi állapotokban. Ebből GPS-alapú kijuttatási térképek készültek. A rendszer integrálása során megoldottuk a fedélzeti rendszerrel való kompatibilitást, az ehhez szükséges korrekciókat, így a helyspecifikus kijuttatás jelentős vegyszermegtakarítást eredményezett, miközben hatékony gyomszabályozást tett lehetővé.

Felhasznált irodalom

- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A. C., Lo, W.-Y., Dollár, P., & Girshick, R. (2023). Segment Anything (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2304.02643>
 - Moldvai, L., Mesterházi, P. Á., Teschner, G., & Nyéki, A. (2024). Weed Detection and Classification with Computer Vision Using a Limited Image Dataset. *Applied Sciences*, 14(11), 4839. <https://doi.org/10.3390/app14114839>
 - Song, J., Kim, D., Jeong, E., & Park, J. (2025). Determination of Optimal Dataset Characteristics for Improving YOLO Performance in Agricultural Object Detection. *Agriculture*, 15(7), 731. <https://doi.org/10.3390/agriculture15070731>
 - Song, X., Yan, L., Liu, S., Gao, T., Han, L., Jiang, X., Jin, H., & Zhu, Y. (2025). Agricultural Image Processing: Challenges, Advances, and Future Trends. *Applied Sciences*, 15(16), 9206. <https://doi.org/10.3390/app15169206>
 - Zhang, J., Maleski, J., Jespersen, D., Waltz, F. C., Rains, G., & Schwartz, B. (2021). Unmanned Aerial System-Based Weed Mapping in Sod Production Using a Convolutional Neural Network. *Frontiers in Plant Science*, 12, 702626. <https://doi.org/10.3389/fpls.2021.702626>
-