



PARADICSOM HOZAMELŐREJELZÉS TECHNOLÓGIAI LÉPÉSEI GÉPI LÁTÁS SEGÍTSÉGÉVEL

MOLDVAI LÁSZLÓ, AMBRUS BÁLINT, TESCHNER GERGELY, NYÉKI ANIKÓ*

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

ORCID: <https://orcid.org/0009-0003-2426-852X>

ORCID: <https://orcid.org/0000-0002-8591-4041>

ORCID: <https://orcid.org/0000-0002-7268-8700>

nyeki.aniko@sze.hu, ORCID: <https://orcid.org/0000-0002-5388-2241>

*Levelező szerző/Corresponding author

Érkezett/Received: 2024.04.08. Átdolgozva/Revised: 2024.05.29. Elfogadva/Accepted: 2024.06.03.

ÖSSZEFOGLALÓ

A precíziós növénytermesztésben egyre több adatot mérünk, egyre több adatot gyűjtünk. Az adatgyűjtés végső célja, hogy valamilyen precíziós beavatkozást el tudjunk végezni. Tudjunk szabályozni bizonyos környezeti paramétereket adott szempontrendszer szerint optimálisan.

A gyakorlatban is felhasználható eredményekhez szükségünk van a várható hozam minőségi és mennyiségi paramétereire, a betakarítás várható időpontjára. A monitoring során képződött adatokból bizonyos betegségek előrejelzését is tudjuk pontosítani, illetve a stresszhatásokat is felismerhetjük. Emellett olyan kérdésekre is igyekszünk választ adni, hogy szabályozható-e bizonyos minőségben a környezet és tudjuk-e optimalizálni a beavatkozási technológiákat?

Jelen munkánknak az volt a célja, hogy meghatározzuk, milyen adatokat tudunk előállítani gépi látás segítségével képfeldolgozás útján. Igyekeztünk meghatározni, hogy a precíziós növénytermesztésben milyen adatok állhatnak rendelkezésünkre, mire alkalmazhatjuk a képfeldolgozási megoldásokat és a gépi látást. Vannak olyan szenzorok, amelyek direkt adatokkal szolgáltatnak és vannak olyanok, amelyek adataiból indexeket vagy konkrét transzformációk útján nyerünk feldolgozható információkat. Célkitűzésünk ezen technológiák áttekintése, hogy a gépi látás témakörében elmélyedve konkrét adatokat és információkat nyerjünk ki, amelyek már a precíziós beavatkozást lehetővé teszik.

Kulcsszavak: hozam-előrejelzés, precíziós növénytermesztés, big data, gépi tanulás, paradicsom detektálás.



BEVEZETÉS

A jelen tanulmányban áttekintjük a korszerű technológiákat és szenzorokat, amelyeket a precíziós mezőgazdasági beavatkozások elvégzésére használnak, különösen üvegházi környezetben. Elemzésünk során vizsgáltuk azokat az informatikai, statisztikai, valamint neurális hálózatokon alapuló megoldásokat, amelyek célja a növényi hozamok becslése és előrejelzése, elsősorban közvetlen adatokból származó információk felhasználásával.

Kiemeltük, hogy számos jelenleg alkalmazott módszer nem képes a növények teljes életciklusának kezelésére a növények fejlődési fázisai miatt. Jelenleg ezek a módszerek széles körben használatosak, annak ellenére, hogy hatékonyságuk korlátozott lehet a növények változó életfázisai során, és hogy jobb alternatívák híján alkalmazzák őket.

Köztudott, hogy a gépi látás, mint alkalmazható eszköz és a detektálásnak egy megoldása már számos területen használható a precíziós gazdálkodásban. Az egyik legfontosabb előnye, hogy képes detektálni a növények életciklusainak változásait. Ennek segítségével a teljes növényi életciklust kisebb, kezelhetőbb szakaszokra bonthatjuk. Ezekre a szakaszokra hatékonyabban alkalmazhatók a statisztikai és regressziós módszerek, valamint a neurális hálózatok, mivel minden rendszer csak az adott szakaszra kell, hogy fókuszáljon.

A gépi látás továbbá magában is képes értékes információk kinyerésére bizonyos életciklus-szakaszokban. Ilyenek például a kelés utáni gyomosodás megfigyelése, a növények fejlődése, a levelek és száruk állapota, a stressz állapota, korai betegség-megállapítás, valamint a virágzás és termésfejlődés folyamata, továbbá érettségi, minőségi és mennyiségi becslések.

IRODALMI ÁTTEKINTÉS

A mesterséges intelligencia (AI) fontossága jelentősen megnőtt a huszonegyedik században szinte minden területen, ideértve a mérnöki, tudományos, orvosi, oktatási, üzleti, számviteli, pénzügyi, marketing, közigazdasági, tőzsdei és jogi területet is (Halal, 2003).

A mesterséges neurális hálózatokat széles körben alkalmazták már számos kutatási területen a hagyományos módszerekkel szembeni előnyeik miatt. Fő előnyük, hogy képesek előrejelzéseket tenni, figyelembe véve az információk kölcsönhatását. Mivel a gépek automatikusan tanulják meg a problémák megoldásának lehetőségeit az adatok alapján, a gépi tanulás (ML) fejlesztése különbözik a hagyományos szoftverfejlesztéstől (Amershi, Begel, Bird, és Zimmermann, 2019).

Az elmúlt időszak egyik ígéretes technológiája a képfeldolgozás területén a mély tanulás (DL), amely alkalmazható képazonosításra, osztályozásra, eltérések kimutatására, stb. (Teke, Devenci, Haliloğlu, Gürbüz, és Sakarya, 2013; Ishimwe, Abutaleb, és Ahmed, 2014).

A képelemzés fontos kutatási téma az agráriumban is. Az élőlények természetes vizuális érzékelési mechanizmusából eredeztethető egy jól ismert mély tanulási technika, a Konvolúciós Neurális Hálózat (CNN) (Gu et al, 2015). A kutatások jelentős része az osztályozással és azonosítással foglalkozik, beleértve az akadályok észlelését (Steen, Christiansen, Karstoft, és Jørgensen, 2016; Christiansen, Nielsen, Steen, Jørgensen, és Karstoft, 2016) és a hozamkalkulációt (Sa et al, 2016).

A paradicsom (*Solanum lycopersicum* L.) a burgonyafélék családjába tartozik, és Dél- és Közép-Amerikában őshonos. A növény és annak bogyótermése, melyet Magyarországon főként



zöldségként fogyasztunk, azonos címmel említhető. A világ paradicsomtermelése évente 124 millió tonnáról több mint 177 millió tonnára nőtt 2003 és 2017 között, miközben a fogyasztás ugyanebben az időszakban körülbelül 2,5%-kal emelkedett (Nemeskéri, Neményi, Böcs, Pék, és Helyes, 2019).

Számos tanulmány mutatja be, hogy mennyire hatékonyak a számítógépes látáson alapuló, termést mechanikailag nem roncsoló vizsgálatok a gyümölcsök és zöldségek osztályozásában a precíziós mezőgazdaságban és az élelmiszeriparban egyaránt. A paradicsom színét gyakran használják az érettség megbízható mutatójaként, mely összefügg az ízzel, a savassággal és a cukortartalommal (Li, Shi, Webster, és Triantafilis, 2008). Ezért a színi jellemzőket gyakran alkalmazzák a gyümölcs minőségének értékelésére. Ebben az esetben minden képpont színét a piros, zöld és kék komponensei határozzák meg.

A mesterséges intelligencia a gépi tanulás egy részhalmaza. Azonban számos tényező, mint például az egyes kitarakások és a megvilágítási körülmények befolyásolhatják a színszegmentálást. Az ilyen problémák enyhítése érdekében alternatív színtereket használnak, például az HSV (Hue, Saturation, Value), HIS (Hue, Intensity, Saturation), YIQ (perceived luminance, color/luminance information) és YCbCr (luminance component, blue-difference chroma, red-difference chroma) színtereket a megszokott RGB (piros, zöld, kék) színtér helyett, hogy kivonják a színinformációt a detektálandó objektumból, ebben az esetben a gyümölcsből. A megérett paradicsomok azonosítására és a gyümölcsök elhelyezkedésének meghatározására Qingchun, Wang, Wang, és Li (2015) kifejlesztett egy üvegházi környezetben működő paradicsom betakarító robotot, mely az RGB színtér HIS színmodelljével dolgozik a detektált képekkel.

Arefi, Motlagh, Mollazade, és Teimourlou (2011) bemutatott egy algoritmust az érett paradicsom felismerésére, amely színtereket kombinál morfológiai információkkal RGB, HSI és YIQ színterek alapján. Malik, Zhang, Zhang, Shabbir, és Saeed (2018) HSV színtér alapú algoritmusokat használt érett paradicsomok észlelésére, valamint a Watershed szegmentációs módszert a csoportos gyümölcsök elkülönítésére.

Huang, Yang, és He (2012) az érett paradicsomokat egy üvegházban a $L^*a^*b^*$ színtér felhasználásával szegmentálta és lokalizálta, és fuzzy logikát alkalmazott a gyümölcsök elkülönítésére a háttértől. Jhawar (2016) egy olyan megközelítést mutatott be, amely az érettség becslésére szolgál RGB fényképek segítségével, lineáris regressziót alkalmaz a mintafelismerésre. A bogyó minőségének értékelésére Khodabakhshian, Emadi, Khojastehpour, és Golzarian (2017) multispektrális képeket használtak. A paradicsom középponti koordinátáinak meghatározásához Mohamadi, Alimardani, és Omid (2011) a paradicsomok RGB képeit HSV képekké alakították át, majd egy küszöbérték alapján szegmentálták az érett paradicsom régióját. Ebben a módszerben az érett paradicsomok azonosításának fő technikája, a háttér eltávolítása. Azonban, mivel az éretlen zöld paradicsom színe hasonló a levelekhez, a detektálási hibaarány viszonylag magas. Zhang, Cui, és Ding (2021) háromdimenziós pozicionálást hajtott végre a vizuális képfejlesztésnek megfelelően, és illesztési görbe segítségével választotta el a paradicsomokat a háttértől. Wang, Wang, Li, és Du (2016) a minimális kritikuss téglalap módszerrel helyreállította az érett paradicsomokat, és küszöbszegmentációt végzett a Niblack algoritmus segítségével.

A paradicsom gyümölcsének képpontjait kinyerve, Yamamoto, Guo, Yoshioka, és Ninomiya (2014) kivonta a háttér színét, szerkezetét és leveleit. Ezek a technikák főként osztályozókat használnak a detektáláshoz és az azonosításhoz annak érdekében, hogy kinyerjék a képből az adott



tulajdonságokat (szín, forma és textúra) a paradicsomokra vonatkozóan. Azonban nem nyújtanak megoldást a kitakarási és átfedési problémákra.

A paradicsomok osztályozására szín, méret és súly alapján módszert mutatott be Clement, Novas, Parra, és Manzano-Agugliaro (2012). Ezeket az osztályozási technikákat nagymértékben befolyásolják a termés minőségi hibái. A paradicsomhiba-észlelés javítása érdekében Arakeri és Lakshmana (2016) javasolta a nagy felbontású képek és képtextúra alkalmazását. Azonban a nagy felbontású képek alkalmazása, például a hiperspektrális és multispektrális képalkotó rendszereké (Polder és Heijden, 2010), költséges és sok feldolgozási időt igényel.

Gong, Yu, Jiang, Cutsuridis, és Pearson (2021) tanulmányában áttekintették a hozambecslés 2 fő megközelítési módját. Az egyik esetben biofizikai modellt próbálnak fejleszteni, amely a környezeti paraméterek, hőmérséklet, víz, tápanyag, szén-dioxid, besugárzás, páratartalom segítségével biokémiai és biofizikai hatásmechanizmusok által szimulálja adott növény fejlődését, ami alapján becslik a hozamot. Paradicsom esetében a TOMGRO és TOMSIM modellt említi meg. Első lépésben a nyers bemeneti adatokat normalizálja és létrehoz egy adat vektor sorozatot. Második lépésben egy LSTM-RNN visszacsatolt neurális hálózatot használ. A normalizált időbeli adat sorozatot egy rekurrens neurális hálózatba táplálja. Ezzel a lépéssel az adatokban lévő időbeli függőséget és a szekvencia legrepresentatívabb jellemzőit ragadja meg. Maga az RNN hálózat több LSTM memória elemmel rendelkezik a múltbeli adatok tárolására. Harmadik lépésben egy időbeli konvolúciós hálózatba (TCN) tápláljuk az RNN hálózat kimeneti adatait további feldolgozáshoz. A TCN kimenetét ellaposítjuk és egy teljesen összekapcsolt rétegre vezetjük. Ez a réteg kimenete adja a hozambecslést. A fenti RNN-TCN hálózat 3 adatsoron tesztelve jobb hozambecslést végzett, mint az előzőekben megvizsgált klasszikus neurális hálózatok vagy akár a mély tanulós hálózatok.

Ezzel szemben Fitz-Rodriguez és Giacomelli (2009) tanulmánya fuzzy logikát használ paradicsom hozamának becslésére. Környezeti paraméterek helyett a növényzet fizikai paramétereit méri, mint a méret, a levelek hossza, a szár növekedése, a növény magassága, a termés súlya, a termések száma (mindezt négyzetméterre vetítve is), illetve a múltbeli hozamokat használja. Az adatok többségét manuálisan gyűjtötték több területen, például Arizona és Texas üvegházaiban. Mivel ez humánerőforrás-igényes feladat, így heti adatokkal dolgoztak, és heti előrejelzést adtak. A becsléshez Dinamikus Neurális Hálózatot (DNN) és Fuzzy Logikát (FL) használtak. A szerzők megemlítik, hogy a szabályozott klímájú üvegházban termesztett paradicsom 15-ször nagyobb hozamot ér el a szántóföldihez viszonyítva, mindezt úgy, hogy az üvegházi paradicsom 90%-a piacképes termést ad, míg a szántóföldinél ez az arány 40-60% közötti, időjárástól függően. Megemlítik, hogy a paradicsomtermesztők a hozamot jól meg tudják becsülni a növények morfológiai jellemzői alapján. A tanulmány a TOMGRO és TOMSIM modell mellett bemutatja a TOMPOUSSE és HIPPO szimulációs modelleket is. A szerzők két módszert kombináltak. Használtak egy Fuzzy logikát, ahol a morfológia változásokból a növény növekedési módjának jellemzőjét (vegetatív, kiegyensúlyozott vagy reprodukív) határozták meg. Majd ezen információval és a múltbeli hozam adatokkal egy Dinamikus Neurális Hálózattal végeztek hozambecslést.

Szabadföldi paradicsomot vizsgáltak (Johansen et al, 2020) egyrészt egészséges környezetben, illetve egy másik populációt sóstressz hatása alatt (600-600 tő) drónos távérzékeléssel készített RGB és multispektrális képekkel. A kutatás idősoros, vagyis hetente gyűjt adatokat, és a növények fejlődését is figyeli. Az így nyert adatokat gépi tanulással elemzi, Random Forest algoritmussal. Az RGB képeket 1,2,4,6,7,8 héttel a betakarítás előtt készítették, míg a multispektrális képeket 1 és 2



héttel a betakarítás előtt. A képeken kiemelték a paradicsom növényeket. Ezekon különböző indexeket számoltak például NDVI (Normalized Difference Vegetation Index), NDRE (Normalized Difference RegEdge), RENDVI (RegEdge Normalized Difference Vegetation Index), illetve képfeldolgozással lombkorona átmérőt, alak tényezőt, homogenitást, illeszkedő ellipszist és társaikat számoltak.

Több gépi tanulási algoritmus segítségével megjósolták a friss paradicsomhajtások tömegét, a paradicsomok tömegét és a paradicsomok számát (Tatsumi, Igarashi, és Mengxue, 2021). A szerzők RGB és multispektrális képeket gyűjtöttek drónnal két időpontban, 3 hónappal és 3 nappal a betakarítás előtt. A képekből 3 indexet, mégpedig az NDVI, GNDVI és WdVI indexeket állítottak elő. Ezekből a képekből első- és másodrendű statisztikákat vontak ki minden egyes növényre vonatkozóan. A képfeldolgozásban használt GLCM (Gray Level Co-Occurrence) mátrixból 13 paramétert számítottak ki és ezeket nevezte másodrendű statisztikai vektoroknak. Ezeket a vektorokat 5 különböző algoritmussal elemezte. A hajtástömeg, a terméstömeg és a termések számának előrejelzési pontossága az összes változóból összeállított modellekkel (RMSE = 8,8-28,1%) jobb volt, mint az elsőrendű statisztikákból (RMSE = 10,0-50,1%). Vagyis a képfeldolgozás során előállított adatok pontosították a paradicsomhozam-becslését.

Paradicsomhozam detektálásának lehetőségét vizsgálták (Lillo-Saavedra et al, 2022) úgy, hogy a paradicsom parcellákról drónfelvételeket készítettek 7 alkalommal. Az első 12 héttel a betakarítás előtt, míg az utolsó 2 héttel a betakarítás előtt került elkészítésre. A felvételeket multispektrális kamerával végezték és a csatornákból előállított NDVI és NDRE indexeket készítettek. Az NDVI és NDRE indexből előállítottak egy bináris képet, ahol fekete a háttér, vagyis talajt vagy adott méretnél kisebb növényeket tartalmaz, illetve a fehér a paradicsom növényeket jelezte. A parcellák közepén 1-1 sort használtak fel és abból is csak 2 métert mintavételre. Meghatározták a terület méretét, a területen belüli paradicsomnövény területét és ennek a területnek a kerületét. Majd borítottságot, méretet és sűrűséget. Másik oldalról a betakarítást kézzel végezték, a 3 cm-nél kisebb paradicsomokat nem számolták, és mérték a paradicsomok számát, tömegét. A fenti adattér 70%-át használták tanításra és 30%-át tesztelésre. A hozambecslést 6 héttel korábbi, 4 héttel korábbi és 2 héttel korábbi adatokon is elvégezték. A 6 héttel korábbi adatokkal végzett becslést 9,28%-os hibával tudták megoldani.

Ehret, Hill, Helmer, és Edwards (2011) üvegházban termesztett paradicsomhozam növekedés és víz felhasználását modellezte neurális hálózattal. Az adatokat kereskedelmi üvegházakból és kutatási célú üvegházakból is gyűjtötték. A vizsgálatban a CropAssist meteorológiai állomást használták, amely az alábbi adatokat mérte: hőmérséklet, a besugárzás, a relatív páratartalom és a CO₂-koncentráció. Az adatokat a CropAssist percenként rögzítette, és ennek a napi, illetve heti átlagait használták. A CropAssist 12 növényre volt rákötve és ezen adatokat terjesztették ki az 55 ezer m² növényeire. Így a teljes növényzet 0,006%-ából következtettek a teljes állományra, ennek ellenére a becslések nagyon jól megközelítették a valóságot. Az eltérés heti szinten kevesebb, mint 2% volt.

A tanulmány a paradicsom levélbetegségeinek osztályozását célozta meg egy, pusztán a levelekről készült RGB képek alapján (Saeed et al, 2023). Adatforrásnak a PlantVillage adatbázist és terepen rögzített képeket használtak. Egy automatikus, a leveleket folyamatosan vagy naponta lefotózó rendszer a levelek feldolgozásához CNN neurális hálózatot tanított be osztályozásra. A fejlesztés felgyorsítása érdekében két előre betanított CNN hálózatot használt, mégpedig az Inception V3 és



Inception ResNet V2-t. A CNN hálózatot eltérő beállításokkal betanítva a teszt képeken 97,8–99,2% pontosságot ért el. Az viszont igaz, hogy csak kétféle levélbetegséget és egy egészséges levélosztályt használt a tanulmány.

Jelen tanulmány célja, hogy bemutassa a képfeldolgozási módszerek technológiai lépéseit a paradicsomnövény vonatkozásában, szemléltesse a képfeldolgozás kihívásait és néhány megoldási lehetőséget a pontosabb előrejelzésekhez gépi tanulási modellek tesztelésével.

ANYAG ÉS MÓDSZER

Az esettanulmányhoz a paradicsom kultúrában alkalmazható gépi látás technológiákat használtuk fel. Esetünkben egy paradicsomnövényen szeretnénk automatikusan kiemelni az érett paradicsomokat. Ez lehet az alapja egy hozambecslésnek vagy a betakarítás időzítésének meghatározására.

A képfeldolgozáshoz és programozáshoz Python nyelvet (<https://www.python.org/>) és az OpenCV függvény (<https://docs.opencv.org/3.4/annotated.html>) gyűjteményt használtuk, mely a színek szerinti szétválasztással, távolságadatok és a paradicsomtermés előzetes paramétereinek felhasználásával állapítja meg a termésszámot és a hozammennyiségét. Első lépésként az eredeti három alapszínből álló (RGB) felvételeket átalakítottuk HSV paraméterekkel leírható formába a szegmentálni kívánt szín/színek pontos kijelölése céljából. A képekből a megfelelő algoritmussal színszegmentált maszkot készítettünk, amely maszk segítségével kontúrokkal kijelöltük az érett paradicsomokat az egyes felvételeken. Mivel az így kijelölt kontúrok a termések gyakori átfedése, egymásra lapolódása miatt gyakran nem különültek el, ezért a „Watershed” algoritmust (https://docs.opencv.org/4.x/d3/db4/tutorial_py_watershed.html) alkalmaztuk a megfelelő szintű szétválasztásra. Az így létrejövő kontúrokkal körbehatárolt felületelemek felhasználásával az egyes paradicsombogyókra a legkisebb köré írható kört illesztettük. A körök illesztésénél nagy figyelmet fordítottunk az algoritmus paramétereinek pontos beállítására, miszerint mekkora minimum és maximum sugár mellett illeszse a köröket a felületelemekre, így elkerülve a pontatlan illesztéseket. A képfeldolgozás során 54 képet használtunk, amelyek több száz érett paradicsomot tartalmaznak. Ezekben a képeken többféle piros objektum zavarja a paradicsomok detektálását. Ezen zavaró tényezőket a képek hisztogramjai alapján különböző osztályozó algoritmusok betanításával és tesztelésével oldottuk meg. Az adatok kiértékelése után az optimális megoldást építettük be a paradicsom detektálási folyamatba. Az alkalmazott gépi tanulási megoldások közül 6 módszert használtunk fel. A Support Vector Machine (SVM) egy felügyelt tanulási algoritmus, amely a különböző osztályokat elválasztó optimális hipersík megtalálására törekszik. Gyakran használják osztályozási és regressziós feladatokhoz. A Random Forest (RF) egy összetett tanulási módszer, amely több döntési fa modell kombinációján alapul. Az algoritmus különböző mintákon tanulva növeli a predikciós pontosságot és csökkenti a túlilleszkedés kockázatát. A k-Nearest Neighbors (KNN) egy egyszerű, nem paraméteres felügyelt tanulási algoritmus, amely a bemeneti minta legközelebbi k szomszédjának osztályozási eredménye alapján dönt. Technikailag nem tanul, csak a tanító vektorokat tárolja el. Az Artificial Neural Network (ANN) egy olyan gépi tanulási modell, amely neuronok rétegeiből áll, és a biológiai agy működését utánozza. Alkalmas komplex mintázatok felismerésére. A Naïve Bayes (NB) egy egyszerű, de hatékony valószínűségi osztályozó, amely a Bayes-tételen alapul. Feltételezi, hogy az egyes jellemzők függetlenek egymástól. A Gradient

Boosting Machine (GBM) egy összetett tanulási technika, amely iteratívan épít fel döntési fákat. Az egyes fák javítják az előzők hibáit, ami nagyon pontos predikciókat eredményez. A gépi tanulás tesztelés mérőszámának a pontosság (Precision) és a visszahívás (Recall) paramétereit használtuk. A pontosság, azt méri, hogy az osztályozó által pozitívnak jelölt példák közül mennyi valóban pozitív. A visszahívás, azt mutatja be, hogy az összes valóban pozitív példából mennyit talált meg az osztályozó.

EREDMÉNYEK

Paradicsomok detektálása képalkotással

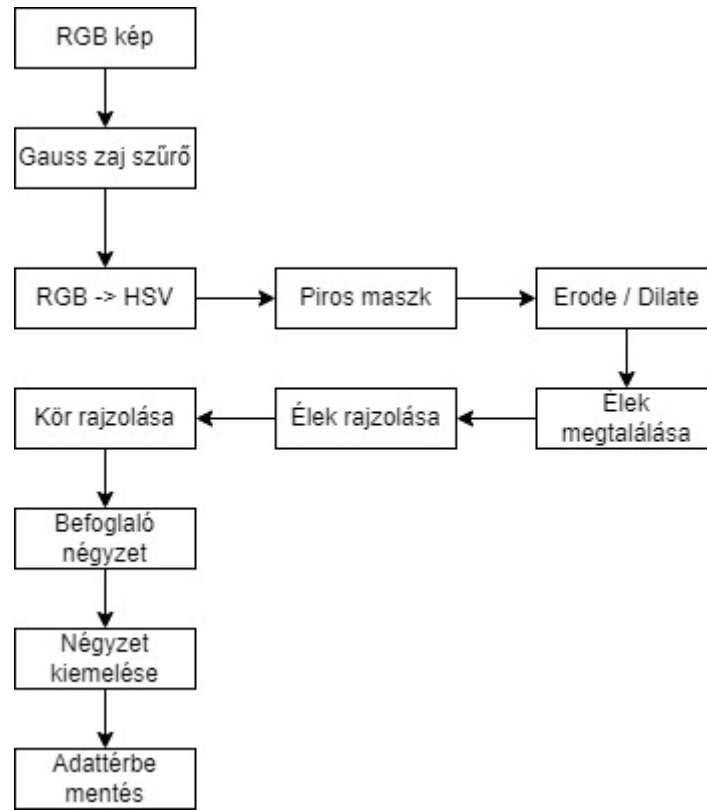
A gépi látás fontos információkat tud kinyerni a növény méretéről, szárának vastagságáról, leveleiről, levélbetegségekről, virágzásról, termés méretéről, minőségéről, érési állapotáról, sőt a rajtuk megjelenő rovarokról, csigákról is tud információt kinyerni. A képfeldolgozás első eredményeként azok a fotók kerültek kiválasztásra, melyeken a paradicsomtermést felismerte, detektálta a program, ezt példaként szemlélteti az *1. ábra*, ahol az RGB képosztályozás történt.



1. ábra Három érett paradicsomot tartalmazó RGB kép
Figure 1 Tree mature tomatoes RGB image

Forrás: https://hobbikert.hu/images/image_intro/55a8d075978a3tz_portfolio_1437126773.jpg


A *2. ábra* szemlélteti a képfeldolgozás alapfolyamatát. A későbbiekben ez lesz kibővítvé. A folyamat főbb lépéseit képekkel illusztrálva a következő bekezdések tartalmazzák.



2. ábra Alap folyamatábra

Figure 2 Basic flowchart

A feldolgozás első lépéseként szükséges a zajmentesítés, második lépésben az RGB színtérből átkonvertáltuk HSV színtérbe. Az eredmény a 3. ábrán látható.




3. ábra HSV színtérbe konvertált kép

Figure 3 Image converted to HSV color space


A HSV színtérben lévő képen kiemeltük a piros színű részeket és bináris képet készítettünk belőle. A lépések segítségével látható, hogy a három paradicsomon kívül rengeteg kisebb piros részt talált az algoritmus. Megnézve az eredeti képet, ezek a részek a leveleken lévő vörösesbarna foltok, illetve bizonyos tükröződések. Szerencsére a számunkra szükséges paradicsomok és a barna foltok között jelentős méretbeli különbség van, amit a későbbiekben ki fogunk használni.

A tükröződéssel kapcsolatban fontos kiemelni, hogy a tárgyakról, növényekről, a termésről visszaverődő színek, azok nem a nap spektrumából tükröznek vissza, illetve nyelnek el komponenseket. Ugyanúgy a környezetükben lévő tárgyak színét és fényét is tükrözik. Számunkra ez azért fontos, mert a környezet színei eltorzíthatják azon színeket, amiket elvárnánk. Ezért célszerű olyan színű (fehér, szürke fekete, stb.) eszközöket és tárgyakat (kamera, ruha, stb.) használni, amelyek a képünk minőségét nem befolyásolják nagymértékben.



4. ábra Bináris maszk a piros színekre
Figure 4 Binary mask for red colours

A bináris képen (*4. ábra*) a fehér színt első körben erodáljuk. Ez azt jelenti, hogy a fekete-fehér átmenetekenél néhány pixel mélységig a fehér színt feketére állítjuk. Így kisebbek lesznek a paradicsomok körvonalai, de ami fontosabb, hogy a képen található kisméretű fehér foltok teljesen el is fogynak. Ezzel el is tűnnek a kisméretű, számunkra zajnak tekinthető részek. Amint említettük, ez a paradicsomokat is kissé erodálta. Ezért a következő lépésben dilatáljuk a fehér részeket. Ez az előző művelet fordítottja. A fehér részekhez hozzáövesztünk pixeleket, vagyis az átmenetekenél a fekete pixelekből fehéret csinálunk. Így mindegy megnöveljük a paradicsomokat az eredeti méretre, és közben a belógó fekete vágásokat, fekete zajokat is sikerül eltüntetni.



5. ábra Erodt és dilatált maszk
Figure 5 Eroded and dilated mask

Az így megtisztított maszkon (5. ábra) élkiemelünk, és a kapott éleket az eredeti képre helyezve megkapjuk a paradicsomok kontúrját (6. ábra). Láthatjuk, hogy pontosan megtaláltuk a paradicsomokat, de elég zajosak a kontúrjaink.



6. ábra Piros paradicsomokra kontúr rárajzolása
Figure 6 Drawing contours on red tomatoes

A kontúrok adatai alapján már tudunk egy kört illeszteni a paradicsomunkra (7. ábra). Esetünkben szerencsénk van, mert a paradicsom fajtája alapján egészen körszerű. Más paradicsomfajták más alakú termésekkel rendelkeznek. Egy részükre ellipszist tudunk illeszteni, de a többire még azt sem. Attól függően, hogy mire van szükségünk sok esetben nem is szükséges ez a lépés.



7. ábra Paradicsomra kör illesztése a kontúrok alapján
Figure 7 Fitting a circle on tomato based on contours

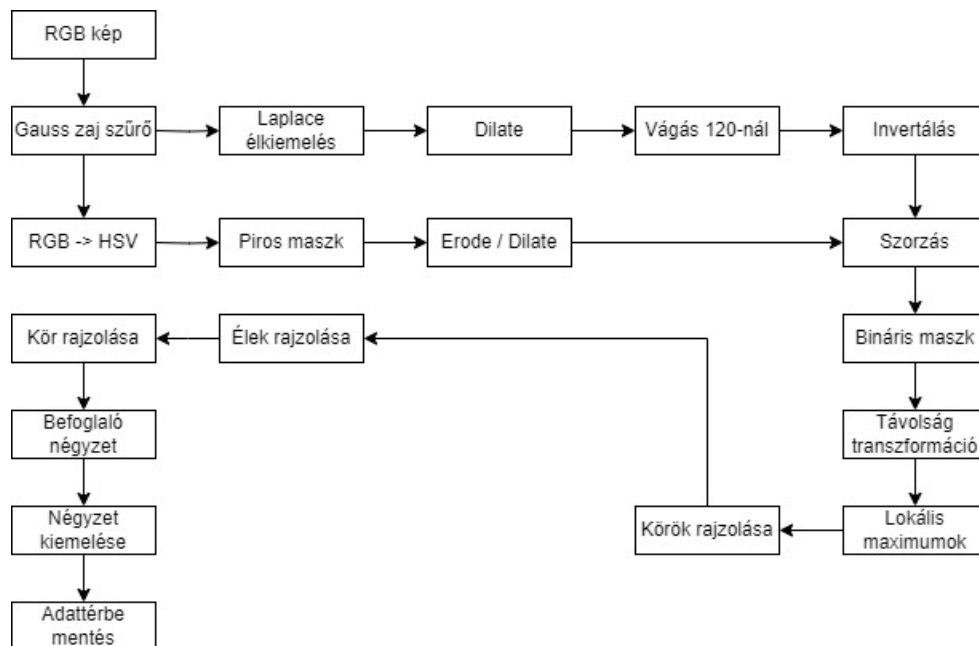
Fejlesztés közben általában 1-2 képpel dolgozunk, de amint sikerült elvégezni a feladatot, jöhet a rendszer robusztusságának tesztelése. Mennyire képes más képeken is jó eredményt elérni? Mi a helyzet más fényviszonyokon készült képeken? Mi történik, ha árnyékban vagy direkt napsütésben készülnek a képek? Általában elmondható, hogy adott rendszert egyben kell kezelni és tekinteni. Olyan kamerával és olyan környezetben készüljenek a képek, ami majd a napi gyakorlatban is használva lesz, és csak ilyen képekre érdemes algoritmust fejleszteni.

Másik teszt képen alkalmazva az algoritmust (8. ábra) már látszik néhány problémásabb eset. Itt a paradicsomok nem elkülönülten találhatóak, hanem egymás mellett összeérve, illetve egymást részben kitakarva. Ennek az az eredménye, hogy egy piros maszk készítésénél a 3 egymást részben kitakaró paradicsom nem különül el és nagyobb összefüggő területet kapunk.



8. ábra Egymást elfedő és részben kitakart paradicsomok
Figure 8 Overlapping and partially uncovered tomatoes

A 9. ábra mutatja a képfeldolgozási folyamat kibővített lépéseit. Ezen lépéseket is részletesen tárgyaljuk a következőkben.




9. ábra Kibővített képfeldolgozási folyamat lépései
Figure 9 Extended image processing process steps

A képfeldolgozás során alkalmazható az úgynevezett élkiemelés. Ekkor egy filterrel végighaladunk a képen és megkapjuk a képeken található hirtelen változatokat. Így a paradicsomok sima felületeinél fekete a kép, de a paradicsom széleinél jól látható kontúr rajzolódik ki (10. ábra). Ezt az élkiemelt képet tudjuk kicsit dilatálni, vagyis az éleket kicsit megvastagítjuk.



10. ábra Él kiemelt kép
Figure 10 Edge highlighted image

A következő lépésben a piros maszkot – ahol 3 paradicsom egyben szerepel még – és a dilatált élkiemelt képet összerakva az élekkel el tudom vágni az egybefüggő részeket. Az eredmény a lenti képen látható, ahol már minden paradicsomunk külön-külön látszik (11. ábra).




11. ábra Piros maszk és élkiemelt kép metszete
Figure 11 Red mask and edge highlighted image inset

A fenti maszkon elvégzünk egy úgynevezett távolság transzformációt. Ez azt jelenti, hogy a fekete részek, feketék maradnak, és a fehér maszknál az értékeket kicseréljük az alapján, hogy milyen messze található a legközelebbi fekete terület. Vagyis a maszk szélénél 1 a felvett érték, de 1 pixellel beljebb már 2 a felvett érték és így tovább.



12. ábra Távolságtranszformált kép
Figure 12 Distance transformed image

A távolságtranszformált kép (12. ábra) alkalmas kiszűrni a kisebb objektumokat. Az esetünkben nem ilyen tiszta a kép, de a távolságtranszformált képen megkereshetjük a lokális maximumokat.



13. ábra Lokális maximumok berajzolása a távolságtranszformált képre
Figure 13 Plot local maximas on the distance transformed image

A lokális maximumok koordinátáinál berajzolt körök a fenti képen láthatóak (13. ábra). A körök sugarát a lokális maximum értéke adja. Ez alapján 6 paradicsomot tudunk megtalálni a képen. Mégpedig egy olyan képen, ahol a paradicsomok összeérnek és részben kitakarják egymást.



14. ábra Paradicsomokra rajzolt kontúrok
Figure 14 Contours drawn on tomatoes

Ezen centrumok alapján megkeressük a centrumhoz tartozó kontúrokat (14. ábra). A képre berajzolva láthatóan elég zajosak. Az algoritmusunk ezek után a legjobban illeszkedő köröket is berajzolja.



15. ábra Körök illesztése a paradicsomokra a kontúrok alapján
Figure 15 Fitting circles on tomatoes based on contours


A végeredmény a képen látható (15. ábra), az algoritmus precízen megtalálta az érett paradicsomokat, kizárólag az illesztésnél van pár pixeles eltérés. A zöld, éretlen paradicsomokat nem találja meg a rendszer, ennek ellenére elmondható, hogy jól működik az algoritmus. Főleg annak fényében, hogy a 2 legfelső paradicsom összeér. Fentről a harmadik részben ki van takarva egy másik paradicsom által, és a paradicsom szára is kitakar egy részt belőle. A legalsó paradicsomot kitakarja egy szár, míg a bal oldalon látható paradicsomot egy levél takar ki nagyságrendileg 30-40%-ban.

A következőkben egy statisztikai célú tesztelést végzünk „big data” adatkészleten, ahol 54 nagyfelbontású képen keresünk érett paradicsomokat. A képfeldolgozási folyamatot nehezíti, hogy a mintatéren (16. ábra), vagyis a képeken több más objektum is fellelhető (pl. talaj, rögzítő elemek, lehullott növényi részek...).



16. ábra Nagyfelbontású képek
Figure 16 High resolution images

A talaj is több helyen piros árnyalatú, ami szintén okoz kihívásokat. Az eddigi rendszerünk megtalálja a paradicsomokat, de az említett piros objektumokat is felismeri, és ezek a képrészletek is bekerülnek az első körben a paradicsomokat tartalmazó képadat-halmazba (17. ábra).



17. ábra A képekből kiemelt piros színt tartalmazó területek
Figure 17 Areas with red highlighted in the images

A képfeldolgozás következő lépésében kiszűrjük a valóban paradicsomokat tartalmazó képeket. Ehhez az RGB képek mindhárom csatornájából készítünk egy-egy 32 elemű hisztogramot. Az RGB képeket átkonvertáljuk HSV tartományba is, és a HSV kép három csatornájából szintén készítünk hisztogramokat. Így összesen hat darab 32 elemű hisztogramot kaptunk, amelyeket egy 192 elemű vektorként kezelhetünk. A vektorok előállításának és a vektor osztályozó rendszer betanításának folyamata a 18. ábrán látható.



tesztadatbázissal elemzésre kerültek a modellek pontosságai. Az osztályozási eredmények a 1. táblázatban láthatók, amely a kilenc vektor eredményeit mutatja be.

1. táblázat Gépi tanulás pontosság és visszahívás eredményei
Table 1 Machine learning's precision and recall results

	*	R	G	B	H	S	V	RGB	HSV	RGBHSV
SVM	P	57.00	60.31	52.40	91.97	62.91	57.52	56.36	84.32	79.97
	V	55.60	62.33	52.28	88.27	63.94	53.82	57.24	88.34	84.98
RF	P	57.08	62.98	55.13	84.60	76.62	57.13	60.56	82.05	80.53
	V	57.67	64.20	56.32	85.84	77.11	58.35	62.73	80.58	80.91
KNN	P	50.45	53.27	51.01	85.08	64.33	51.56	57.90	80.08	73.06
	V	50.53	53.99	51.22	87.50	67.14	51.86	59.36	81.33	76.76
ANN	P	58.35	63.45	57.17	84.83	70.80	55.79	55.15	77.76	78.78
	V	60.24	66.45	58.63	86.67	71.78	57.12	56.33	77.41	78.95
NB	P	55.03	63.14	57.92	70.49	73.41	58.18	62.25	72.01	70.58
	V	54.35	66.00	59.08	74.85	73.41	55.43	64.88	73.64	71.89
GBM	P	57.02	64.08	58.51	87.56	75.76	55.95	62.93	86.72	86.10
	V	58.43	65.97	60.15	89.55	78.06	57.27	65.50	82.10	84.69

*' P: pontosság százalékos értéke. V: visszahívás százalékos értéke

Az adatok elemzése alapján megállapítható, hogy a 6 alap csatorna közül 5 nagyon gyengén teljesít, viszont a H csatorna kiemelkedően a legjobb eredményeket hozza. A H csatorna tartalmazza a szín információt spektrális jelleggel, ezért az érett paradicsom piros maszkját a HSV színtér H csatornájának a vágásával oldjuk meg. Az RGB vektortér közepesen teljesít. A következő, már 80% körüli pontosságot elérő vektorterünk az összes csatornát tartalmazó RGBHSV volt. Ennél is jobb eredményt érhetünk el, ha kihagyjuk az RGB adatait, és csak a HSV színtér adatokkal dolgozunk. Viszont az abszolút nyerő a H hisztogram volt.

A másik irány az osztályozók teljesítményének elemzése. Érdekes csak a H csatornán lévő teljesítményre összpontosítani. Az NB osztályozó adta a leggyengébb eredményt, míg a legjobb eredményt az SVM osztályozó érte el, közel 92%-os pontossággal. A többi osztályozó körülbelül 85%-os pontosságot ért el.

Összefoglalva, a feladatra elegendő csak a H csatornát felhasználni SVM osztályozóval.

A H csatorna hisztogramja alapján az SVM osztályozó adta a legjobb eredményt. Ennek a kombinációnak a Confusion Mátixa a 21. ábrán látható. A mátrixból is látszik, hogy nem kiegyensúlyozott adatokkal teszteltünk, mivel jóval több paradicsom volt a mintatérben, mint más piros színezetű kép.

	Nem Paradicsom	Paradicsom	
Nem Paradicsom	77 22.45%	20 5.83%	97 79.38% 20.62%
Paradicsom	7 2.04%	239 69.68%	246 97.15% 2.85%
	84 91.67% 8.33%	259 92.28% 7.72%	316 / 343 92.13% 7.87%

21. ábra Confusion mátrix
Figure 21 Confusion matrix

A fentiek alapján érdemes lehet a folyamatábrát kiegészíteni a pontosabb eredmények eléréséhez a következő elemekkel (22. ábra).



22. ábra Képfeldolgozás folyamatát kiegészítő lépések
Figure 22 Additional steps in the image processing process

Miután kiemeltük a piros ROI-kat, mindegyiket leosztályozzuk a most már betanított SVM osztályozóval, majd eldönthetjük, hogy melyik ROI-k tartalmaznak paradicsomot. Csak ezeket mentjük el és használjuk fel akár hozambecslésre, akár a szüret következő időpontjának meghatározásához.



KÖVETKEZTETÉSEK

A tanulmány célja a paradicsom hozamának előrejelzésére alkalmas gépi látás és képfeldolgozási módszerek fejlesztése és alkalmazása volt. A kutatás során számos fontos konklúziót tudunk levonni az eddigi eredményeink alapján is. A gépi látás technológiája lehetővé teszi a növények életciklusának részletes monitorozását a tesztnövényünk esetében is, a paradicsom termesztésében. A gépi látás segítségével a növények fejlődésének különböző fázisait lehet nyomon követni, így pontosabb adatokat lehet gyűjteni a hozam becsléséhez. A kutatás során alkalmazott képfeldolgozási módszerek, mint az RGB és HSV színtér konverzió, valamint a „Watershed” algoritmus hatékonyan segítettek a paradicsomok detektálásában és elkülönítésében a képeken. A gépi látás alapú módszerekkel pontosan meghatározható volt a termések száma és érettségi állapota. A különböző gépi tanulási algoritmusok, mint a Support Vector Machine (SVM), Random Forest (RF) és Artificial Neural Network (ANN) jelentős mértékben javították a detektálás és osztályozás pontosságát. Az SVM osztályozó 92%-os pontosságot ért el a paradicsomok felismerésében, ami kiemelkedően magas eredménynek számít. A multispektrális kamerákkal és drónokkal végzett idősoros adatgyűjtés lehetővé tenné a továbbiakban, hogy a növények állapotát és fejlődését folyamatosan monitorozzuk. Az ilyen típusú adatgyűjtés segíthet a növények stresszhatásainak és betegségeinek korai felismerésében, hiszen sokkal több csatorna áll rendelkezésünkre, mely előnyre tehet szert a képalkotásban és a feldolgozásban egyaránt. A vizsgálat eredményei bizonyítják, hogy a gépi látás és a képfeldolgozási módszerek jól alkalmazhatóak a paradicsomok különböző állapotainak detektálására. A képfeldolgozási folyamatok optimalizálása és a gépi tanulási modellek integrálása hozzájárulhat a mezőgazdasági termelés hatékonyságának növeléséhez.

Összességében a tanulmány eredményei azt mutatják, hogy a gépi látás és a gépi tanulási módszerek alkalmazása a precíziós mezőgazdaságban jelentős előrelépést jelenthet a hozamok pontos előrejelzése és a termesztési folyamatok optimalizálása terén.



MACHINE VISION-BASED APPROACHES FOR PREDICTING TOMATO YIELDS

SUMMARY

In this study, we delve into advanced technologies and sensors utilized for precision agriculture, especially in greenhouse environments. Our investigation encompasses information technology, statistical models, and neural network-based approaches for predicting and estimating crop yields, primarily through direct data analysis.

We highlight a significant limitation of current methods: they often do not cover the entire lifecycle of plants, which is critical due to the varying stages of plant development. Although these methods are widely used, their effectiveness can be constrained during the dynamic growth phases of plants, and they are adopted in the absence of better alternatives.

At this point, we introduce machine vision as a versatile tool with applications across numerous fields. Its key advantage lies in its ability to detect changes throughout the plant lifecycle, allowing us to segment the lifecycle into more manageable phases. This segmentation enables the targeted application of statistical, regression, and neural network techniques, with each system focusing on a specific developmental stage.

Machine vision is adept at extracting crucial information at different stages of a plant's life. It can be used for various purposes, such as weed monitoring, tracking plant growth, assessing leaf and stem health, detecting stress and early signs of disease, and evaluating flowering, crop progression, as well as determining maturity, quality, and yield.

To demonstrate the effectiveness of machine vision, we developed a Python application that identifies ripe tomatoes ready for harvest in RGB images. This tool aids in accurately estimating harvest volumes by counting the number of mature tomatoes.

Furthermore, we suggest the implementation of a multi-camera system employing machine vision to identify precise agricultural interventions needed at various stages of crop development.

Keywords: yield prediction, big data, machine learning, tomato detection, imaging

KÖSZÖNETNYILVÁNÍTÁS

A kutatómunkát a „Precíziós Bio-Műszaki Kutatócsoport” végezte, amelyet a "Széchenyi István Egyetemért Alapítvány Kuratóriuma" támogatott.



IRODALOM

- Amershi, S., Begel, A., Bird, C., DeLine, R., Gall, H., Kamar, E., Nagappan, N., Nushi, B., & Zimmermann, T. (2019). Software Engineering for Machine Learning: A Case Study. ICSE-SEIP '10 Proceedings of the 41st International Conference on Software Engineering: Software Engineering in Practice, Montreal, Quebec, Canada, May 27, 2019, pp. 291-300.
- Arakeri, M.P. & Lakshmana (2016). Computer Vision Based Fruit Grading System for Quality Evaluation of Tomato in Agriculture industry. *Procedia Computer Science*, 79, 426-433. <https://doi.org/10.1016/j.procs.2016.03.055>
- Arefi, A., Motlagh, A., Mollazade, K., & Teimourlou, R. (2011). Recognition and localization of ripen tomato based on machine vision. *Aust. J. Crop Sci.*, 5, 1144-1149.
- Christiansen, P., Nielsen, L. N., Steen, K. A., Jørgensen, R. N., & Karstoft, H. (2016). DeepAnomaly: Combining background subtraction and deep learning for detecting obstacles and anomalies in an agricultural field. *Sensors*, 16(11), 1904.
- Clement, J., Novas, N., Parra, J.A.G., & Manzano-Agugliaro, F. (2012). High speed intelligent classifier of tomatoes by colour, size and weight. *AGRICULTURAL RESEARCH*, 10(2), 314. <https://doi.org/10.5424/sjar/2012102-368-11>
- Ehret, D.L., Hill, B.D., Helmer, T., & Edwards, D.R. (2011). Neural network modeling of greenhouse tomato yield, growth and water use from automated crop monitoring data. *Computers and electronics in agriculture*, 79(1), 82-89. <https://doi.org/10.1016/j.compag.2011.07.013>
- Fitz-Rodriguez, E. & Giacomelli, G. A. (2009). Yield Prediction and Growth Mode Characterization of Greenhouse Tomatoes with Neural Networks and Fuzzy Logic. *American Society of Agricultural and Biological Engineers*, (01): 15, <https://doi.org/10.13031/2013.29200>
- Gong, L., Yu, M., Jiang, S., Cutsuridis, V., & Pearson, S. (2021). Deep Learning Based Prediction on Greenhouse Crop Yield Combined TCN and RNN. *Sensors*, 21(13), 4537. <https://doi.org/10.3390/s21134537>
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, L., Wang, G., Cai, J., & Chen, T. (2015). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354-377. <https://doi.org/10.1016/j.patcog.2017.10.013>
- Halal, W.E. (2003). Artificial intelligence is almost here, On the Horizon - *The Strategic Planning Resource for Education Professionals*, Vol. 11, No. 2
- Huang, L., Yang, S., & He, D. (2012). Abscission Point Extraction for Ripe Tomato Harvesting Robots. *Intelligent Automation & Soft Computing*, 18, 751-763.
- Ishimwe, R., Abutaleb, K., & Ahmed, F., (2014). Applications of thermal imaging in agriculture – a review. *Advances in Remote Sensing*, (3). <https://doi.org/10.4236/ars.2014.33011>
- Jhawar, J. (2016). Orange Sorting by Applying Pattern Recognition on Colour Image. (n.d.). *Procedia Computer Science*, 78, 691-697. <https://doi.org/10.1016/j.procs.2016.02.118>



- Johansen, K., Mitchell, J.L.M., Yoann, M., Bruno A., Samer, A.M., Matteo, G.Z., Yoseline, A., Gabriele, F., Sónia, N., Magdi, A.A.M., Mark, A.T., & Matthew, F.M. (2020). Predicting Biomass and Yield in a Tomato Phenotyping Experiment Using UAV Imagery and Random Forest. *Frontiers in Artificial Intelligence*, 3 (May) 28. <https://doi.org/10.3389/frai.2020.00028>
- Khodabakhshian, R., Emadi, B., Khojastehpour, & Golzarian, M.R. (2017). Determining quality and maturity of pomegranates using multispectral imaging. (n.d.). *Journal of the Saudi Society of Agricultural Sciences*, 16(4), 322-331. <https://doi.org/10.1016/j.jssas.2015.10.004>
- Li, H.Y., Shi, Z., Webster, R., & Triantafilis, J. (2008). Mapping the three-dimensional variation of soil salinity in a rice-paddy soil. *Geoderma*, 195, pp. 31-41. <https://doi.org/10.1016/j.geoderma.2012.11.005>
- Lillo-Saavedra, M., Espinoza-Salgado, A., García-Pedrero, A., Souto, C., Holzapfel, E., Gonzalo-Martín, C., Somos-Valenzuela, M., & Rivera, D. (2022). Early Estimation of Tomato Yield by Decision Tree Ensembles. *Agriculture*, 12(10), 1655. <https://doi.org/10.3390/agriculture12101655>
- Malik, M.H., Zhang, T., Li, H., Zhang, M., Shabbir, S., & Saeed, I. (2018). Mature Tomato Fruit Detection Algorithm Based on improved HSV and Watershed Algorithm. *IFAC-PapersOnLine*, 51, 431-436. <https://doi.org/10.1016/j.ifacol.2018.08.183>
- Mohamadi, H., Alimardani, R., & Omid, M. (2011). Detection of red ripe tomatoes on stem using Image Processing Techniques. *Journal of American Science*, 7(7), 376-379.
- Nemeskéri E., Neményi A., Bócs A., Pék Z., & Helyes L. (2019). Physiological Factors and their Relationship with the Productivity of Processing Tomato under Different Water Supplies. *Water*, 11, 586. <https://doi.org/10.3390/w11030586>
- Polder, G. & Heijden, G. van der (2010). Measuring Ripening of Tomatoes Using Imaging Spectrometry. *Hyperspectral Imaging for Food Quality Analysis and Control*, pp. 369-402. <https://doi.org/10.1016/B978-0-12-374753-2.10012-7>
- Qingchun, F., Wang X., Wang G., & Li Z. (2015). Design and test of tomatoes harvesting robot. In Proceedings of the 2015 IEEE International Conference on Information and Automation, Lijiang, China, pp. 949-952. <https://doi.org/10.1109/ICInfA.2015.7279423>
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., & McCool, C. (2016). Deepfruits: A fruit detection system using deep neural networks. *Sensors*, 16(8), 1222. <https://doi.org/10.3390/s16081222>
- Saeed, A., Abdel-Aziz, A.A., Mossad, A., Abdelhamid, M.A., Alfadhl, Y.A., & Muhammad, M. (2023). Smart detection of tomato leaf diseases using transfer learning-based convolutional neural networks. *Agriculture*, 13(1), 139. <https://doi.org/10.3390/agriculture13010139>
- Steen, K.A., Christiansen, P., Karstoft, H., & Jørgensen, R.N. (2016) Using deep learning to challenge safety standard for highly autonomous machines in agriculture. *Journal of Imaging*, 2(1), 6. <https://doi.org/10.3390/jimaging2010006>
- Tatsumi, K., Igarashi, N., & Mengxue, X. (2021). Prediction of plant-level tomato biomass and yield using machine learning with unmanned aerial vehicle imagery. *Plant Methods*, 17(1), 77. <https://doi.org/10.1186/s13007-021-00761-2>



Teke, M., Deveci, H.S., Haliloğlu, O., Gürbüz, S.Z., & Sakarya, U. (2013). A short survey of hyperspectral remote sensing applications in agriculture. In Ilarslan M, Ince F, Kaynak O and Basturk S (eds), 6th International Conference on Recent Advances in Space Technologies (RAST), IEEE. Piscataway, NJ, USA: IEEE, pp. 171-176. <https://doi.org/10.1109/RAST.2013.6581194>

Wang, J., Wang, G., Li, M., & Du, W. (2016). Hand vein recognition based on PCET. *Optik - International Journal for Light and Electron Optics*, 127(19), <https://doi.org/10.1016/j.ijleo.2016.05.119>

Yamamoto, K., Guo, W., Yoshioka, Y., & Ninomiya, S. (2014). On plant detection of intact tomato fruits using image analysis and machine learning methods. *Sensors*, 14(7), pp. 12191- 12206. <https://doi.org/10.3390/s140712191>

Zhang, S., Cui, S., & Ding, Z. (2021). Hypergraph spectral analysis and processing in 3d 955 point cloud, *IEEE Transactions on Image Processing*, 30, 1193-1206. <https://doi.org/10.48550/arXiv.2001.02384>