

DOKTORI (PhD) ÉRTEKEZÉS

AMBRUS BÁLINT

MOSONMAGYARÓVÁR
2023

**SZÉCHENYI ISTVÁN EGYETEM
ALBERT KÁZMÉR MOSONMAGYARÓVÁRI KAR
BIOLÓGIAI RENDSZEREK ÉS PRECÍZIÓS TECHNOLÓGIAI
TANSZÉK**

**WITTMANN ANTAL NÖVÉNY-, ÁLLAT- ÉS ÉLELMISZER-
TUDOMÁNYI MULTIDISZCIPLINÁRIS
DOKTORI ISKOLA**

**HABERLANDT GOTTLIEB NÖVÉNYTUDOMÁNYI DOKTORI
PROGRAM**

**DOKTORI ISKOLAVEZETŐ:
PROF. DR. VARGA LÁSZLÓ DSC
EGYETEMI TANÁR**

**PROGRAMVEZETŐ:
PROF. DR. PINKE GYULA DSC
EGYETEMI TANÁR**

**TÉMAVEZETŐK:
DR. NYÉKI ANIKÓ PHD
EGYETEMI DOCENS,**

**DR. TESCHNER GERGELY PHD
EGYETEMI ADJUNKTUS**

**ADATGYŰJTÉSI TECHNOLÓGIÁK FEJLESZTÉSE A
PRECÍZIÓS NÖVÉNYTERMESZTÉSNEEL, KÜLÖNÖS
TEKINTETTEL A MAGAJÁRÓ BERENDEZÉSEKRE**

**KÉSZÍTETTE:
AMBRUS BÁLINT**

**MOSONMAGYARÓVÁR
2023**

ADATGYŰJTÉSI TECHNOLÓGIÁK FEJLESZTÉSE A PRECÍZIÓS NÖVÉNYTERMESZTÉSNEÉL, KÜLÖNÖS TEKINTETTEL A MAGAJÁRÓ BERENDEZÉSEKRE

Írta:
Ambrus Bálint

Készült a Széchenyi István Egyetem Albert Kázmér Mosonmagyaróvári Kar
Wittmann Antal Növény-, Állat- és Élelmiszer- tudományi Multidiszciplináris
Doktori Iskola
Haberlandt Gottlieb Növénytudományi Doktori Programja keretében

Témavezető: Dr. Nyéki Anikó (PhD), Dr. Teschner Gergely (PhD)

Elfogadásra javaslom (igen / nem)

(aláírás)

Elfogadásra javaslom (igen / nem)

(aláírás)

A jelölt a doktori szigorlaton.....%-ot ért el,

Mosonmagyaróvár,

.....
a Szigorlati Bizottság Elnöke

Az értekezést bírálóként elfogadásra javaslom (igen/nem)

Első bíráló (Dr.) igen/nem

(aláírás)

Második bíráló (Dr.) igen/nem

(aláírás)

Esetleg harmadik bíráló (Dr.) igen/nem

(aláírás)

A jelölt az értekezés nyilvános vitáján%-ot ért el.

Mosonmagyaróvár,

A Bírálóbizottság elnöke

Doktori (PhD) oklevél minősítése.....

Az EDT elnöke

TARTALOMJEGYZÉK

KIVONAT	3
ABSTRACT	4
1. BEVEZETÉS	5
2. IRODALMI ÁTTEKINTÉS	8
2.1. Kutatási előzmények	8
2.2. Robotok a mezőgazdaságban	9
2.2.1. Robotok általános jellemzői	9
2.2.2. Robotok a precíziós gazdálkodásban	11
2.2.3. Mezőgazdasági robotok érzékelő és adatgyűjtő rendszerei	20
2.2.3.1. Környezeti, atmoszférikus szenzorok	24
2.2.3.2. Talajszenzorok	25
2.2.3.3. Képkalkotó szenzorok	28
2.2.3.4. Navigációs szenzorok	31
2.3. A mesterséges intelligencia, gépi tanulás alkalmazása	35
2.3.1. Mesterséges intelligencia jellemzői, alkalmazása	35
2.3.2. Mesterséges látás, képfeldolgozás	39
2.3.3. Paradicsom termés detektálása gépi látás alkalmazásával	45
2.4. Képfeldolgozáshoz szükséges korrekciók	51
2.5. Paradicsom termés 3D modelljének előállítás 3D scanneléssel	55
3. ANYAG ÉS MÓDSZER	60
3.1. Alap robotrendszer bemutatása	60
3.2. Robotfejlesztés (A gép és a vezérlőrendszer újratervezése)	61
3.2.1. Vázszerkezet, meghajtás	61
3.2.2. Tápellátás	63
3.2.3. Mikroszámítógép és programozás	64

3.2.4. Távvezérlő rendszer	64
3.2.5. Telepített érzékelők	65
3.3. Kísérleti helyszínek bemutatása.....	70
3.3.1. Szabadföldi kísérlet.....	70
3.3.2. Növényházas kísérlet.....	72
3.4. Adatgyűjtés és a feldolgozás módszerei.....	73
3.4.1. Képi-adatgyűjtés RGB DSLR kamerával	73
3.4.2. Képi-adatgyűjtés a saját fejlesztésű robottal	76
3.4.3. Képfeldolgozási módszerek.....	77
3.4.4. Regresszió elemzés.....	83
3.5. Képfeldolgozáshoz szükséges korrekciós módszerek.....	83
3.5.1. Lencsekorrekció	83
3.5.2. Távolságkalibráció	86
3.5.3. Szín és fénykorrekció.....	87
3.6. Paradicsom termés 3D modellezésének módszere	88
4. EREDMÉNYEK.....	93
4.1. Robotfejlesztés eredményei	93
4.1.1. Szerkezeti elemek	93
4.1.2. Navigáció.....	94
4.1.3. Alkalmazott érzékelők	98
4.1.4. Adatgyűjtési és továbbítási módszerek.....	103
4.1.5. Levélmintavevő működtető.....	106
4.1.6. Távirányítás	107
4.2. Paradicsom termés 3D modellezésének eredményei.....	109
4.3. Optikai korrekciós eredmények.....	112
4.3.1. Lencsekorrekciós eredmények	112

4.3.2. Fénykorrekciós és színi vizsgálatok eredményei.....	114
4.3.3. Távolságkalibráció eredményei.....	117
4.4. Képfeldolgozás eredményei	120
4.4.1. Paradicsom termés detektáló módszerének eredményei.....	120
4.4.2. Paradicsom-levélelváltozás detektálásának eredményei	124
4.4.3. A hozambecslési módszer eredményei	126
4.4.4. Paradicsombogyók tömegének meghatározásának eredményei szabadföldi kísérletben és növényházban	127
4.4.4.1. DSLR fényképezőgép képeinek eredményei.....	128
4.4.4.2. A robot képeinek eredményei.....	134
4.4.5. Paradicsom bogyószám meghatározásának eredményei szabadföldi kísérletben és növényházban.....	142
4.4.5.1. DSLR fényképezőgép képeinek eredményei.....	143
4.4.5.2. Robot képeinek eredményei	147
4.4.6. Regressziós elemzés eredményei.....	155
5. KÖVETKEZTETÉSEK, JAVASLATOK.....	158
5.1. Robot fejlesztés.....	158
5.2. Paradicsom termés 3D modellezése	159
5.3. Kalibrációs módszerek.....	160
5.4. Machine learning alapú paradicsom detektáció.....	161
5.5. Paradicsom termésszámlálás és becslés	162
6. ÖSSZEFOGLALÁS.....	167
7. TÉZISEK	170
8. KÖSZÖNETNYILVÁNÍTÁS	173
9. IRODALOMJEGYZÉK.....	174
10. JELMAGYARÁZAT.....	217
11. MELLÉKLETEK	218
12. ÁBRAJEGYZÉK	252

KIVONAT

A dolgozat egy autonóm kisméretű intelligens adatgyűjtő és elemző robotot mutat be, amely képes környezeti paraméterek érzékelésére és vizuális adatok (RGB) feldolgozására gépi tanulási módszerekkel. A szerző egy nyílt forráskódú és interfészekkel rendelkező kis robot módosítását mutatja be adatgyűjtőként és beavatkozási eszközként. Az alapfunkciók megtartása mellett az érzékelési, adatfeldolgozó, adatátviteli és beavatkozási rendszer kibővült. Célja egy alacsony költségű és többfunkciós mobil szántóföldi robot megalkotása volt, amelyet precíziós mezőgazdasági alkalmazásra lett kifejlesztve

Emellett a dolgozat másik célja a szántóföldi paradicsom terméshozamának becslése volt a saját fejlesztésű hardver és szoftver rendszerrel, melynek része a saját fejlesztésű robot és egy digitális tükörreflexes (DSLR) kamera. A dolgozatban egy új megközelítés lett javasolva a paradicsom hozamának előrejelzésére, amely a szántóföldön készült képeken, valamint 3D szkennelésen és korrekciós modellen alapul. Szabadföldi és növényházban készült képek lettek felhasználva a paradicsom szegmentálásához és a termés mennyiség meghatározása érdekében. A paradicsombogyó szegmentálására egy konvolúciós neurális hálózat (CNN) modell lett kidolgozva a TensorFlow programkönyvtár használva. A termésbecslés gépi látás alkalmazásával OpenCV függvénykönyvtár felhasználásával történt meg.

ABSTRACT

The dissertation presents an autonomous small intelligent data collection and analysis robot capable of sensing environmental parameters and processing visual data (RGB) using machine learning methods. The author presents the modification of a small robot with open source code and interfaces as a data collector and intervention tool. In addition to keeping the basic functions, the detection, data processing, data transmission and intervention system has been expanded. Its goal was to create a low-cost and multifunctional mobile field robot developed for precision agricultural applications.

In addition, another goal of the thesis was to estimate the yield of field tomatoes with the self-developed hardware and software system, which includes the self-developed robot and a digital single-lens reflex (DSLR) camera. In this paper, a new approach for tomato yield prediction based on field images, 3D scanning and modeling is proposed. Images taken in the open field and in the greenhouse were used to segment the tomatoes and determine the yield. A convolutional neural network (CNN) model was developed for tomato segmentation using the TensorFlow program library. The yield estimation was done using machine vision using the OpenCV function library.

1. BEVEZETÉS

„A tudomány két lábon halad előre, e kettő: a kísérlet és az elmélet”

MILLIKAN, 1924

Napjainkban számos tanulmány felhívta a figyelmet a paradigmaváltás szükségességére. LONGCHAMPS (2018), a mezőgazdaság bioszférára gyakorolt káros hatásait elsősorban a szokásos kísérleteken alapuló kutatások eredményei nem tudják csökkenteni (HUSTI, 2018). A kollektív élelmezési ellátás nagyfokú veszélyeztettségnek van kitéve, úgy, mint a lélekszám gyarapodása, az étkezési szokások változása és a globális felmelegedés problémaköre (NYÉKI et al., 2022). Ezen kívül a növekvő toleranciák (kártévő, betegség, gyom) növekvő nyomást gyakorolnak a hagyományos, és precíziós technológiákra egyaránt (NYÉKI et al., 2021). A hatékonyság növelésével és az ártalmas kihatások redukálása mellett idő és térbeli differenciát mutató a növények szükségleteinek az optimális tápanyag-kijuttatást kell realizálni (TILMAN, 1998). A precíziós technológia az ökológiai szempontokat vizsgálva sem váltotta be maradéktalanul a felé támasztott elvárásokat. Valamint a precíziós technológia az elmúlt negyed évszázados korszerűsítése során a gyakorlati alkalmazások is megerősítik, hogy a korábbinál jóval nagyobb adatbázisokra van szükség (LONGCHAMPS 2018).

A mezőgazdaság jövőjében a robotok nagyszámban fognak elterjedni a növénytermesztésben, átvéve az ember szerepét, ellentétben napjaink kiegészítő, segítő munkákat ellátó robotjai mellett. Az

elterjedés vertikumának kiszélesedése is be fog következni a jelenleg alkalmazott egy célú alkalmazást mutató robotokkal szemben, mint például növényvédelmi robotokkal. Jelenleg is zajlik az egyedi gépek fejlesztése mellett a robotok kooperációban működő munkavégzésének kialakítása. Az iparban alkalmazott robotok jelentős innovációs lehetőséggel rendelkeznek, viszont ezen tapasztalatok a természetes környezethez való adaptálása komoly kihívásokat jelent (BLACKMORE, 2017).

E kihívások terheinek enyhítése érdekében lehetőséget ad a gazdálkodási folyamat bizonyos aspektusainak automatizálására és robotizálására. A beágyazott alkalmazások intelligensebbé, gyorsabbá és energiahatékonyabbá válhatnak azáltal, hogy közvetlenül a forrásnál elemzik az érzékelőadatokat, ahelyett, hogy az adatokat egy feldolgozó egység számára küldenék és válaszra várnának.

Fontos megjegyezni, hogy napjaink robot tervezésénél sok esetben nem a teljes tervezési és kivitelezési ciklust járják végig, hanem felhasználják korábbi fejlesztések eredményeit. Ahogy WANG et al. (2019) is rámutattak tanulmányukban, ahol a „játékból eszköz” (From Toy to Tool) megfontolás alapján alakítottak ki egy robot rendszert.

Kutatási célkitűzéseink:

Elsődleges kutatási célkitűzések között szerepelt a Tanszék precíziós gazdálkodási technológia-fejlesztéséhez való csatlakozás, a fejlesztési munkák továbbvitele. Kutatásaink célja olyan a precíziós és digitalizációs technológiába beilleszthető rendszer kifejlesztése, amely monitoring és beavatkozó célokat is el tud látni. Ezen munka során egy mobil (robot) mérőállomás kifejlesztése volt a cél, melynek a hardveres és szoftveres háttere is saját fejlesztés. A kialakított adatgyűjtő mérőrendszer szántóföldi és növényházas körülmények között is üzemképes, tehát a precíziós gazdálkodás és a digitális agrárium egyik meghatározó fejlesztési irányához, az autonóm mobil robotokhoz is kapcsolható. Célul tűztük ki az IoT teschnológiakba történő integrációját is a kifejlesztett rendszernek a digitalizáció mai trendjeinek figyelembe vételével. A könnyebb kezelhetőség miatt egy vezeték nélküli applikációt is kifejlesztettünk a robot távirányítása céljából. Alkalmazhatósága kiterjed az adatgyűjtés mellett azok elemzésére is, úgymint képi infomációk feldolgozása saját kialakítású mesterséges intelligencia alkalmazásával. Vizsgálatainkat két helyszínen is elvégeztük, amely során a termesztett paradicsom növény részeinek (levélzet elváltozás és érett termés) felismerése volt a célunk.

Vizsgálataink kiterjednek a robot által gyűjtött adatok utóelemzésére is, amelyre gépi látást alkalmaztunk a paradicsom termésbecslése (termésszám és terméstömeg) céljából. Az eljárást kibővítettük 3D szkennelési eljárással a paradicsom termés morfológiai tulajdonságainak figyelembe vételével, amelynek célja a pontosabb eredmények elérése

2. IRODALMI ÁTTEKINTÉS

2.1. Kutatási előzmények

A Széchenyi István Egyetem, Albert Kázmér Mosonmagyaróvári Karának, Biológiai Rendszerek és Precíziós Technológiai Tanszéke által a precíziós mezőgazdaság területén szerzett bő két évtizedre kiterjedő elméleti és gyakorlati tapasztalatai nagyszámú hazai és külföldi szakfolyóiratban és konferencián megjelent nivós tanulmányai, valamint a tangazdaság művelése alatt lévő tábláján beállított precíziós kísérletek termékeny táptalajt nyújtottak a kutatómunka elindításához.

A Tanszék jelentős mennyiségű szak- és diplomadolgozat, valamint doktori disszertáció létrejöttében játszott szerepet már a helyspecifikus, precíziós növénytermesztési technológiák témekörében. MESTERHÁZI (2004) a kísérleti táblát homogén kezelési egységekre osztottva vizsgálta a talajellenállás és a hozam kapcsolatát. MIKE-HEGEDŰS (2006) az optimális management zónák méretét fuzzy logika és neurális statisztikai módszerekkel vizsgálta. MILICS (2008) bemutatta a térinformatika és a távérzékelés alkalmazásainak lehetőségeit. A precíziós növénytermesztési technológiák mérési módszereinek fejlesztésével CSIBA (2010) foglalkozott. NYÉKI (2016) napjaink legnagyobb problémakörét a fenntarthatóságot vizsgálta a precíziós növénytermesztés tükrében, majd később NYÉKI et al. (2021) a kukorica hozam térbeli-időbeli változékonyságát mesterséges intelligenciával dolgozta fel.

Ezek a tanulmányok és vizsgálatok kellő alapot biztosítottak kutatásaink hipotéziseinek felállításához.

2.2. Robotok a mezőgazdaságban

2.2.1. Robotok általános jellemzői

Bár a robotika egy viszonylag új fogalom, az első önállóan működtetett gépek Kr.e. 400-ra tehetőek, amikor Tarentumi Arkhüasz gőzhajtású, önjáró berendezést fejlesztett ki (PATEL, 2007). Maga a robot kifejezés minden olyan automata gépre utal, amely az emberi erőfeszítést, munkát helyettesíti, függetlenül attól, hogy embernek néz-e ki, vagy emberszerűen hajt végre a feladatokat (VERL et al., 2019). A "robot" szó a cseh „robot” szóból származik, ami szolgát jelent (MAVRIDIS, 2015). Maga a robot szó, napjainkban sem rendelkezik tökéletesen konzekvens definícióval (AMOBI, 2019). Automatának tekintünk egy olyan gépet, amely egy program utasításait önműködően végre tudja hajtani, viszont robot meghatározás szerint minden olyan önműködő entitást, amely képes érzékelni a körülötte folyamatosan változó környezet paramétereit, ezeket feldolgozva a működését ehhez is igazítva látja el a feladatát (BÁRTFAI et al., 2018).

A robotikai kutatás és fejlesztés fő korszaka a 20. század közepe volt, elsősorban ipari környezetben, ahol az ismétlődő mozgások és a nehéz tárgyak emelése vonzóvá tették a gépek használatát az emberrel szemben. Joseph F. Engelberger és George Devol 1961-ben fejlesztette ki az első ipari célú robotot, az Unimate-t. Ez egy hidraulikus hajtású, programozható, 2 tonnás robotkar volt, amelyet automatizált présöntéshez alkalmaztak (DHARIA és FALCONE, 2005).

A robotikában nagy jelentőséggel rendelkezik Isaac Asimov amerikai sci-fi író és biokémikus által 1942-ben papírra vetetett a robotika 3 alapvető törvénye, amely a következőket fogalmazza meg:

- „1. A robotnak nem szabad kárt okoznia emberi lényben, vagy tétlenül tűrnie, hogy emberi lény bármilyen kárt szenvedjen.
2. A robot engedelmeskedni tartozik az emberi lények utasításainak, kivéve, ha ezek az utasítások az első törvény utasításaiba ütköznenek.
3. A robot tartozik saját védelméről gondoskodni, amennyiben ez nem ütközik az első vagy második törvény bármelyikének előírásaiba”
(RUTKIN, 2014).

Asimov írásaiban jelenleg még nagyrészt futurisztikus, valamint technológiailag és etikailag is meglehetősen optimista és ideális képet rajzol a robotokról (DOMINIC, 2000).

Az etikai, jogi problémák mellett számos műszaki probléma is jelen van a gyakorlati alkalmazás során, amelyek megoldásra várnak. A mezőgazdasági robotok fejlesztése a konstrukciós megoldásokon felül és azok megfelelőségén túl számos, tágabb, rendszerszinten megjelenő problémát is generálnak (GRIMSTAD és FROM, 2017). Ezek magukba foglalják az élet- és vagyonbiztonsági feladatokat, az ember szerepét, felelősségét, kompetenciáját, a robotok együttműködését, az ehhez szükséges infrastruktúrát, a robotok mozgását és a közutakon való közlekedését, a költséges gépek idényjellegű használatát és mindezeknek az anyagi vonzatát (BOAD, et al., 2021).

A robottechnika fejlesztésekor a fenntarthatóság felelőssége is nagy nyomást gyakorol a fejlesztőkre. „A fenntartható fejlődés olyan fejlődés, amely kielégíti a jelen generációk szükségleteit anélkül, hogy veszélyeztetné a jövő generációit abban, hogy ők is kielégíthessék szükségleteiket” (LÁNG, 2001). Az ilyen módú fejlesztéseknek az ökológiai, környezetbarát elvárásoknak is meg kell felelni, így az agrár

biodiverzitás növeléséhez, a klímaváltozás csökkentéséhez is hozzá kell járulni (NEMÉNYI, 2020). A robotizáció tükrében a fenntartható növénytermesztés általános követelményeit NEMÉNYI (2017) foglalta össze: a talajra gyakorolt kedvezőtlen hatások csökkentése (szikesedés, savanyodás, tömörödés), és a környezetszennyezés csökkentése.

A robotoknak, mint automatizálási rendszernek úgyszintén nagy jeletősséggel bír a kommunikáció- és kooperációképessége. A helyes információ ellátottság egy ilyen rendszer megfelelő működésének alapköve, helytelen információk esetében, hibás döntéseket és helytelen intézkedések fog kialakítani.

2.2.2. Robotok a precíziós gazdálkodásban

A precíziós gazdálkodás az ISPA (Nemzetközi Precíziós Mezőgazdasági Társaság) meghatározása szerint a következő: „A precíziós mezőgazdaság olyan irányítási stratégia, amely összegyűjti, feldolgozza és elemzi az időbeli, térbeli és egyedi adatokat, és kombinálja azokat más információkkal, hogy a becsült változatosságnak megfelelően támogassa a gazdálkodói döntéseket a mezőgazdasági termelés hatékonyabb erőforrás-felhasználásának, termelékenységének, minőségének és jövedelmezőségének és fenntarthatóságának javítása érdekében” (LOWENBERG-DEBOER és ERICKSON, 2019).

MCBRATNEY et al. (2005) szerint a precíziós mezőgazdaság kifejezés úgy definiálható, mint „az a fajta mezőgazdaság, amely növeli a terület-, és időegységekre vetített helyes döntések számát, ami a nettó haszonnal korrelál”.

Az elmúlt két évtizedben, az információs korszak beköszöntével a mezőgazdasági termelési módszerek is drámaian megváltoztak (ZHANG et al., 2021). Az élelmiszerek mennyiségi kereslete, a gyorsan növekvő népesség, a termőföldek termékenységének csökkenése mind indokolja az új innovatív megoldások, például a robotok szükségességét (AZMI et al., 2021; MOYSIADIS et al., 2020). Így elterjedt a robotok alkalmazása a precíziós mezőgazdaságban, hiszen ezzel növelhetjük annak hatékonyságát. A robotika elterjedésének fő alapja a munkaterhelés csökkentése a mezőgazdasági tevékenységek automatizálásával (MAHMUD et al., 2020). A zöld gazdaság robotizálása segíthet a minőségjavulás, a környezetvédelem nyomon követésében és a fenntarthatóság megőrzésében (OBAIDEEN et al., 2022). Az információkhoz való hozzáférés révén a gazdálkodók magas hozamot és alacsony működési költségeket biztosíthatnak a mezőgazdasági termelés sikerének érdekében (DUCKETT et al., 2018; ANGIN et al., 2020; KHADATKAR et al., 2021).

A mezőgazdasági robotok olyan intelligens robotok, amelyek szenzoros fűziót, automatikus vezérlést, szabályozást, beavatkozó aktuátorokat, fejlett adattovábbító rendszereket és egyéb technológiákat használhatnak a mezőgazdasági munkafolyamatok autonóm végrehajtásához (FENG et al., 2021; TALAVIYA et al., 2020). A modern precíziós mezőgazdaság három alapvető technológiai területre támaszkodik: robotika, mesterséges intelligencia (AI) és az Internet of Things (IoT) (OLIVEIRA et al., 2021).

A mezőgazdaság a monitoring és beavatkozó igények megfelelése végett kétféle robottechnikai platform is kialakult, úgy, mint a pilóta nélküli légi járművek (Unmanned Aerial Vehicle = UAV); és mobil

robotok (Unmanned ground vehicle = UGV). THOMPSON et al. (1991) a mezőgazdasági robotokat hardveresen és szoftveresen is három alapvető részre osztotta fel 1. információgyűjtés, 2. feldolgozás és döntéshozatal, 3. feladat végrehajtása (1. ábra).



1. ábra – Egy mezőgazdasági robot általános részei (UTSTUMOA, 2018).

A mezőgazdasági robotok részeit hardveres és szoftveres tekintettel is több kategóriába lehet sorolni: működtető elemek (hajtásrendszerek, vezérlők, robot-kar, aktuátorok, stb.), környezetérzékelő rendszerek (radar, kamera, stb.) egyéb segédkomponensek (PIERZCHALA et al., 2018). A hajtásrendszer, mint a robot fő alkotóeleme elektromos, hidraulikus és pneumatikus típusú is lehet, az alkalmazási terület alapján (LI et al., 2021). A speciális érzékelők alkalmazásának, beleértve a gépi látást, lézer alapú eszközöket, inerciális eszközöket és aktuátorokat (hidraulikus munkahengerek, lineáris és forgómotorok, stb.) nélkülözhetetlen szerepük van abban, hogy a mezőgazdasági robotok különböző feladatokat tudjanak végrehajtani elektronikus eszközök (beágyazott számítógépek, ipari számítógépek és programozható logikai vezérlő) segítségével (GAI et al., 2021; SEBASTIAN et al., 2018). Számos területen alkalmazhatók ezek a berendezések úgy, mint talajművelés, ültetés, metszés, gyomlálás, betakarítás, vetés, permetezés, műtrágyázás, adatgyűjtés, növényvédelem, növényápolás, betakarítás, légi képalkotás és az állattenyésztés

(fejőrobotok, etetőrobotok, állományok egészségi állapotát figyelő robotok) területén is (BECHAR és VIGNEAULT, 2017; MAO et al., 2020).

Napjainkban olyan önjáró mintavevő és mintaértékelő robotokat fejlesztenek amelyek képesek a növényi részek elváltozásainak és a talaj jellemző paramétereinek meghatározására (CAO et al., 2003; BOTTA et al., 2022).

Egy robot táblán belüli elhelyezkedésének pontos meghatározása több aspektusból is mérvadó a precíziós mezőgazdaság számára. A legismertebb erre alkalmas rendszer a globális helymeghatározó rendszer (Global Position System = GPS). A Föld körüli pályán keringő 24 műhold alkotta rendszer segítségével minimum 4 műhold láthatósága esetén a műholdakon elhelyezett atomórák időmérése valamint a felszíni pont és a műhold távolsága alapján a vevőeszköz pontos helyzete meghatározható háromszögeléssel (BECVARIK és DEVETSIKIOTIS, 2016).

A mezőgazdasági robot működéséhez valós idejű korrekciós jelek szükségesek, hiszen a berendezés koordinátáit a lehető legpontosabban lehetőség szerint azonnal pontról pontra kell meghatározni (GOMES et. al., 2018). A valósidejű differenciális korrekcióval (Real-time Kinematic = RTK) jelentősen javítható a GPS koordináták pontossága (TAMÁS, 2001), így akár centiméteres pontosság is elérhető (XU, 2012; ROVIRA-MÁS et al., 2015). SLAUGHTER et al. (2012) ilyen módszerrel rögzítette a vetés során az elvetett mag helyzetét, ezáltal a táblára való visszatéréskor a későbbi munkafolyamatok során már rendelkezésre állt a növények helyzete. Ez alapján a munkagép automatikus irányítása lehetővé válik, a sorokon történő automatikus vezetés és a sorvégi fordulás kivitelezésére is képes, ezáltal precízebb munkavégzés érhető el.

A robotok esetében a terepi beavatkozó munkák elvégzéséhez beavatkozó berendezésekkel (aktuátorokkal, effektorokkal) ellátott robotokat is kifejlesztettek. Ilyen munkák lehetnek a talaj vagy növényminták gyűjtése, ill. gyümölcs betakarítási munkák végzése stb. A mezőgazdasági felhasználásra kifejlesztett robotok a változó környezeti feltételek mellett kihívásokkal is szembesülnek az alapanyagokkal való munka során (OLIVEIRA et al., 2021). Gyümölcs és zöldségbetakarítás esetében a robot érzékelőrendszerei határozzák meg a termés megfelelő érési állapotát, tehát a betakaríthatóságát (EIZICOVITS et al., 2016). Éppen ezért fontos feladat a termés, termés kezelésének precizitása az emberi karokhoz és ujjakhoz hasonlóan (FURUKAWA et al., 2019). Sokféle aktuátort fejlesztettek ki, ujjakkal, tűkkel, fűvókákkal, ollókkal, és robotkarokkal a termés megfogására, vágására, rögzítésére vagy leválasztására (GORJIAN et al., 2021). Ez magában foglalja a mesterséges intelligencia és a gépi tanulás lehetőségeit is. (MOHANTA et al., 2020; WIDIANTO et al., 2022).

A legtöbb mezőgazdasági robot esetében az alkalmazott gépi tanulási módszerek komplex feladatok végrehajtására is alkalmassá teszik a gépeket (MESHRAM et al., 2021). A teljesen automata, autonóm robotok mellett jelentős számú olyan eszköz van, amely egy olyan kezelőhöz csatlakozik, aki befolyásolni tudja a robotot, így létrehozva egy "ember - robot-interakciót" (Human-Robot - Interakció = HRI) (HURTADO et al., 2019). A géptől-gépig (Machine-to-Machine = M2M) egy másik olyan képesség, amely emberi beavatkozás nélkül teszi lehetővé az adatok áramlását a gépek között (RAJAGOPAL et al., 2022). Ezek a rendszerek csökkenthetik a kockázatot és egyben időt takaríthatnak meg.

A fejlesztés jelenlegi szakasza a „dolgok internete” (Internet of Things = IoT), amely hálózatba kapcsolt specifikus azonosítóval ellátott eszközöket jelent. Az ilyen rendszer felépítése három összetevőre bomlik: az érzékelő rétegre, az adatátviteli rétegre és az alkalmazási rétegre (TZOUNIS et al., 2017). Az IoT alkalmazása a mezőgazdaságban elsősorban a növénytermesztésben jelentős (XU et al., 2022). Speciális esetekben a "dolgok", amelyekről információt gyűjtünk, élő, intelligens rendszerek, amelyek nem csak a programozott feltételekhez alkalmazkodnak. Emellett a szenzoroknak hozzá kell járulniuk a folyamatos adatszolgáltatáshoz terepi körülmények között is hosszú távon.

Az IoT-rendszerek nagy adatbázisokat használnak, ugyanakkor az információs bázis több nagyságrenddel javítható az on-the-go mérési lehetőségekkel (OMRAN, 2012). Maga az információáramlás kezdete egy olyan eszközzel (robottal) kezdődik, amely a szántóföldön gyűjt adatokat, előrejelzéseket készít, és ezeket az adatokat továbbítani tudja a központba, vagy akár egy munkagép fedélzeti számítógépére (FOUNTAS et al., 2020; CHAITANYA et al., 2020). Ezen adatok továbbítására rádiófrekvenciás azonosítást (RFID), Bluetooth-t, ultraszéles sávot (Ultra-wideband = UWB) stb. alkalmaznak, amelyek a kis hatótávolságú vezeték nélküli kommunikációs rendszerek közé tartoznak. A Wi-Fi és a ZigBee a leggyakrabban használt közepes hatótávolságú vezeték nélküli kommunikációs technológiák. A jól ismert mobilhálózatok (GPRS-4G/5G) mellett a Low-Power Wide-Area network (LPWA) egy új típusú technológia, amelyet a nagy hatótávolságú vezeték nélküli kommunikációs technológiák közé sorolunk. Az elmúlt néhány évben




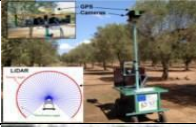


számos LPWA technológia jelent meg, mint például a LoRa, az NB-IoT és a Sigfox (THAKUR et al., 2019; FENG et al., 2019).

A mezőgazdasági termelésben fontos szerepet tölt be a monitoring, amely a precíziós mezőgazdaság megvalósításának alapja (SONG et al., 2022). Ennek a feladatnak ez ellátásához fejlesztették ki a távérzékelési alkalmazásokat. A mezőgazdasági termelés alatt álló terület és az adatgyűjtő műholdak közötti távolság átlagosan 700 km körül van, viszont több információt kapunk, ha a szenzorok kis távolságra vannak a célterülettől (LAMESKI et al., 2018). Ha az adatgyűjtő platformok a talajról működnek, az érzékelők és a célnövény közötti távolság 2 m alá csökken (SAIZ-RUBIO et al., 2020; JAFARBIGLU et al., 2022). Mivel ezek a járművek a termés közelében mozognak, a kapott adatok pontosabbak, és méterenként egy vagy több mintavételezés is lehetséges.

Számos munkafolyamat elvégezhető a kisebb méretű robotokkal úgy, mint a permetezés, mikroadatgyűjtés (SØGAARD et al., 2006), öntözés, multispektrális adatgyűjtés és szelektív betakarítás is (BLACKMORE, 2013). XAUD et al. (2018) kifejlesztett egy négykerék-meghajtású robotot, amely képes mérni a környezeti paramétereket, valamint a kártevők jelenlétét infravörös kamerák és lézerszkennerek segítségével. SANTOS et al. (2015) kutatásaikkal olyan robotot hoztak létre, amely autonóm módon, vagy távirányítva, költséghatékonyan tudja ellátni a termésfelügyelet feladatát. AHMADI et al. (2020) kifejlesztett egy kétkamerás módszert, amely felhasználja a vetésterület sorszerkezetét, hogy a robotot a sor mentén irányítsa anélkül, hogy explicit lokalizációs rendszerre, GNSS-re vagy a környezet térképére lenne szükség. MILELLA et al. (2018) épített egy moduláris többszenzoros rendszert, amely vizuális, termikus,


hiperspektrális és inerciális érzékelőket tartalmaz a strukturálatlan talajtérképezéshez. Ennek célja, a talaj jellemzőinek pontos ismerete. CUBERO et al. (2020) kifejlesztett egy terepi robotot, amely multispektrális szenzorokkal van felszerelve, és szabályozott megvilágítás mellett képes követni a kertészeti növények sorait távérzékelési technikák segítségével 1 és 2,5 *mm/pixel* felbontással, RTK korrekciós adatrögzítéssel. CUBERO et al. (2020) kifejlesztett egy távirányítású ültetőrobotot, a palánták folyamatos üzemű ültetéséhez, amelynek vetőmechanizmusa a forgattyús-csúszka koncepción alapul. A vizsgálat eredménye alapján a robot 5 perc alatt 138 palántát tud elültetni. Az 1. táblázat a fent felsorolt robotfejlesztéseket szemlélteti.

1. táblázat – Különböző kisméretű monitoring, és beavatkozó robotok

FELADAT	NAVIGÁCIÓ	SZENZOROK	KÉP	FORRÁSOK
Termés- és környezetfigyelés	Teleoperáció	IR kamera, laser scanner, környezeti szenzorok		XAUD et al. (2018)
Termésfigyelés	Lézer scanners, IMU, GNSS	RGB és IR kamerák		SANTOS et al. (2015)
Növényállomány figyelés	Első és hátsó kamerák	--		AHMADI et al. (2020)
Talajvizsgálatok	--	2 RGB kamera, VIS-NIR szenzor, hőkamera, IMU		MILELLA et al. (2018)
Kártevők és betegségek	Távirányítású	Multispektrális kamera, DSLR kamera, hiperspektrálképalkotó rendszer, hőkamera		CUBERO et al. (2020)
Vetés	Távirányítású	--		CUBERO et al. (2020)

Mezőgazdasági robotok közé sorolhatóak a mezőgazdasági célokra kifejlesztett pilóta nélküli légi járművek (UAV) is. Az UAV-k egyik leggyakoribb alkalmazási módja a művelés alatt lévő területről spektrális információk gyűjtése, tehát különböző hullámhossztartományokba és sávzélességekben a talajra merőleges légifelvételek készítése (YAO et al., 2019). Emelett alkalmazásuk kiterjed az anyagkijuttatásra is elsősorban foltpermetezési alkalmazásokra (HANIF et al., 2022). A monitorozás kézenfekvő lehetősége mellett ezen eszközök által végzett adatgyűjtési és mérési technológia nem alkalmazható a lombkoronába való vizsgálódásra (ZANG et al., 2023), annak zártsága miatt.

Jelenleg is fejlesztés alatt vannak a mikrobotok (2. ábra), mint miniatűr autonóm robotok amelyek a mezőgazdaságban is alkalmazhatóak precízebb monitoring munkára a lombkorona belsejében, vagy akár mesterséges beporzásra is (ELAMVAZHUTHI és BERMAN, 2015).



2. ábra – *Biológia inspirálta mikrorobot* (URL¹)

AHMAD et al. (2021) tanulmányukban olyan adatgyűjtő platformot mutatnak be, amely technológiák fúziója (például robotok, műholdak és légi megfigyelő rendszerek). A szerzők arra a következtetésre jutottak,

hogy az adatfúzió fő korlátja a különböző típusú érzékelőktől származó adatok multimodalitása. PIEKUTOWSKA et al. (2021) egy nem lineáris modellt hoztak létre a többszörös lineáris regressziós elemzés alapján, és mesterséges neurális hálózatok (Artificial Neural Network = ANN) alkalmazásával burgonyatermés meghatározásához fitofenológiai és meteorológiai adatok felhasználásával. A neurális modell magas, több mint 7%-os átlagos abszolút százalékos hiba értéke igazolta a predikciós minőségét.

SZULC et al. (2021) kutatásának célja a különböző mélységere kijuttatott nitrogén foszfor műtrágya kukoricára gyakorolt hatásának felmérése volt. Az egységnyi területre jutó kelés az NP-műtrágya kihelyezési mélységének növekedésével együtt csökkent minden vizsgált évben.

A terméshozamok előrejelzése az egyik legnagyobb kihívást jelentő feladat a mezőgazdaságban. Lényeges szerepet játszik a döntéshozatalban globális, regionális és területi szinten. A talaj, meteorológiai, környezeti, a termésparamétereket pedig termés hozam előrejelzésére használják. A termés hozam-szimulációk segítenek megérteni a víz- és tápanyaghiány, a kártevők, a betegségek egymással összefüggő, a termés hozamra gyakorolt hatását a tenészedőszak során (NEMÉNYI és NYÉKI, 2022).

2.2.3. Mezőgazdasági robotok érzékelő és adatgyűjtő rendszerei

A precíziós gazdálkodás fontos részét képezik a szenzorok, amelyek folyamatosan mérik a különböző talaj, környezeti, klimatikus és időjárási jellemzőket, valamint a mezőgazdasági műveletekhez kapcsolódó egyéb paramétereket (ZHANG, 1996; MONTEIRO et al., 2021).

Maguk a szenzorok átalakítják a meghatározni kívánt valós fizikai (nem elektromos) jeleket azok elektromos (digitális) megfelelőjévé (BURD és DOREY, 1984). Az általános célú érzékelők, mint például hőmérsékletérzékelő, fényintenzitásérzékelő, gyorsulásmérők, talajnedvességérzékelők, stb., megfelelően integrálhatók az IoT rendszerekbe (WHITE, 1987). A mezőgazdaságban alkalmazott szenzorok esetében az alacsony energiafogyasztás, kompatibilitás az adatátvitelben az irányító egység és az érzékelő között, a pontosság, az ismételhetség, az érzékenység és a robusztusság tartoznak a legfontosabb szempontok közé (CHAMARA et al., 2022).

Jelenleg háromféle érzékelő típust alkalmaznak széles körben a mezőgazdaságban: fizikai tulajdonságok érzékelői, bioszenzorok, ill elektromechanikus érzékelők (YOU és TANG, 2013). A fizikai jellemzőket mérő érzékelők jelátalakítást valósítanak meg a szenzorban végbemenő fizikai változtatások alapján. A bioszenzorok biológiailag érzékeny komponenseket alkalmaznak az információtovábbításra. Az elektromechanikus érzékelők új technológia termékek, alacsony energiafogyasztás és magas megbízhatóság jellemzi őket (LI et al., 2015). A precíziós mezőgazdaság legfontosabb eszközei közé sorolhatóak a különböző vezeték nélküli szenzorhálózatok (SHAFI et al., 2019). Az adatgyűjtő szenzorok megfelelő működése és az általuk összegyűjtött adatok effektív feldolgozása lehetővé teszi a beavatkozást úgymint permetezés, öntözés, műtrágyázás, stb. (OBAIDEEN et al., 2022).

A robotikában számos szenzor és szenzorrendszer létezik, amelyek elsősorban a kölcsönhatásra összpontosítanak robot és környezete között, valamint olyan érzékelőkkel is el vannak látva, amelyek információt adnak

a robot belső állapotáról (DUMBS és HESSE, 1983). Ezek alapján a robotikában a szenzorok az alapján osztályozhatók, hogy kapcsolatba lépnek-e a környezetükkel, illetve ennek a mértéke alapján. Így két fő osztályozás lehetséges:

- A proprioceptív érzékelők az egység belső változóit mérik, mint pl.: a kerék fordulatszáma, az akkumulátor töltöttségi állapota, a belső hőmérséklet, stb.
- Az exteroceptív érzékelők a környezetet vizsgálják, pl.: RGB kamerák és ultrahangos érzékelők, fényérzékelő és távolság mérő érzékelők, stb. Ezek az érzékelők információkat szolgáltatnak a növényekről és a mezőgazdasági területről (KELLY és SUKHATME, 2014; SOTER et al., 2018; MARTINELLI et al., 2005).

A szenzorok környezettel való kölcsönhatása szerint szintén kétféle módon osztályozhatóak:

- Az aktív érzékelők kölcsönhatásba lépnek a környezettel az energiacsereén keresztül. Ez azt jelenti, hogy az érzékelő a saját áramforrását használja arra, hogy energiát bocsát ki a környezetbe és rögzíti a visszatérő energiát, pl.: ultrahangos érzékelők, lézeres távolságmérők.
- A passzív érzékelők rögzítik a környezet által kibocsájtott, vagy visszavert energiát, saját energiát nem bocsájtanak ki. Az RGB kamerák passzív érzékelők; rögzítik a fényt a természetes ill. mesterséges forrásokból, amelyeket a környező tárgyak tükröznek vissza (ESCOLÀ, et al., 2021; ELSAYED et al., 2015).

A különböző érzékelők azonban eltérő technológiai elvekkel rendelkeznek, és különböző adatokat szolgáltatnak. A felhasználóknak figyelembe kell venniük a különböző működési módokat az egyes érzékelők képességeit, és korlátait (JAVOID et al., 2021a).

Egy vezeték nélküli szenzorrendszer (Wireless Sensor Network = WSN) négy komponensre tagolódik: tartalmaz tápegységet, adatgyűjtő szenzort, adatfeldolgozó egységet és a kommunikációs csatornát biztosító adóvevőt (FAROOQ et al., 2020). A különböző adatok gyűjtésére különböző szenzorok, illetve az adatfeldolgozó egységek állnak rendelkezésre (SHAFI et al., 2019). Sok esetben az adattárolás és feldolgozás (döntéshozatal) nem helyben, hanem egy távoli szerverben (felhőben) történik. A beavatkozás szabályozásáért és monitoringjáért szintén szenzorok felelősek.

A Sensor Fusion a különböző érzékelők adatainak kombinálása olyan adatokká, amelyeknél a kapott információ bizonyos értelemben jobb, mint, ha ezeket a forrásokat külön-külön használnák fel (STEINMETZ és BELLON, 1995). Különböző lehetőségek léteznek az érzékelőadatok fúziójára. ELMENREICH (2002) nyomán az érzékelő adatok fúziós folyamatát három szintre lehet felosztani:

- alacsony szint - több nyers adatforrást összekapcsol új adatok előállításához;
- közbülső szint - nyers adatok helyett jellemzőket vagy változókat kombinál;
- magas szint vagy döntési szint - amely a már feldolgozott adatokat döntésekké egyesíti.

Az érzékelő adatok fúziójában különféle módszereket már elterjedten alkalmaznak (CASTANEDO, 2013), beleértve az olyan statisztikai módszereket, mint a többváltozós lineáris regresszió (Multiple Linear Regression = MLR), a legkisebb négyzetek módszere (Partial Least Squares = PLSR) és főkomponens-analízis (Principal Component Regression = PCR) (VEUM et al., 2017; DE BENEDETTO et al., 2013).

Az érzékelők képezik az IoT-hálózatok gerincét olyan fizikai rétegben, amely olyan területeket foglal magában, mint a szántóföldi növénytermesztés, hidroponika, melegházak, állattenyésztés, intelligens öntözés, szállítás, légi járművek, stb.

Az IoT használatával az érzékelők által gyűjtött adatok vezeték nélkül eljutnak a szerverhez, amely bárholnan elérhető egy internetképes eszköz segítségével (KOUR et al., 2022).

2.2.3.1. Környezeti, atmoszférikus szenzorok

A precíziós mezőgazdaság feltételeire alapozott növénytermesztés folyamán elengedhetetlen a környezet állapotának nyomon követése, a lokális környezeti paraméterek meghatározása.

A leggyakrabban alkalmazott érzékelők a környezet fizikai paramétereinek meghatározására a talajnedvességérzékelők (IVANOVA et al., 2016), utánuk a páratartalom-érzékelők (HURST et al., 2021) majd a levegőhőmérséklet-érzékelők következnek (HAQUE et al., 2021). A növény föld feletti részeinek jellemzőinek mérése, a növény magassága, növény sűrűsége, levél helyzete, levélfelület index (Leaf Area Index=LAI), növényi szervek száma (levél, termés, virág), biomassa, a

klorofilkoncentráció, a nedvzárlás és a sztóma vezetőképessége hasznos biológiai paraméterek a termésfigyelésben.

BAR-ON et al. (2019) egy olyan rendszert mutatnak be, ami különböző környezeti mennyiségek - levegő hőmérséklet, relatív páratartalom, megvilágítás, és a talaj vízpotenciál - mérésére fejlesztettek ki. XING et al. (2017) egy olyan rendszert alakított ki monitorozás céljából, amely ZigBee protokoll segítségével továbbítja a mért információkat egy távoli szerverhez. COSMAN et al. (2019) és TAHA et al. (2018) alacsony költségvetésű mérőrendszert mutat be, amelyet együtt használnak a monitoring mellett egy üvegházi automatikus vezérlőrendszer megvalósítására (szellőztetés és öntözés).

Ultrahangos szélesség és az irányérzékelő fontos meteorológiai érzékelő, amelyeket az evapotranspiráció becsléséhez használnak fel (KAMEOKA et al., 2017). A mechanikus szélmérőhöz képest egy ultrahangos szélmérő kevesebb karbantartást igényel a kevesebb mechanikai alkatrész miatt. Ezenkívül egy ultrahangos anemométer nagyon pontosan képes rögzíteni a szél sebességének és irányának hirtelen változásait (széllökés) is. A lombkorona ultrahang-érzékelővel történő magasságmérése a biológiai paraméterek mérésének közvetett fajtája (YUAN et al., 2018). DAOSAWANG et al. (2020) bebizonyították, hogy a görögdinnyén áthaladó 130 – 170 Hz-es ultrahanghullámokkal az érettség kimutatható.

2.2.3.2. *Talajszenzorok*

A környezeti adatokkal együtt egy másik fontos, általában megfigyelt paraméter a talajnedvesség. A talaj alapvető eleme a

növénytermesztésnek, mivel döntő fontosságú szerepet játszik a kultúrnövények fejlődésben, a termés hozamában és a minőségében is (CHAMARA et al., 2022). A talaj tulajdonságait két fő kategóriába lehet besorolni: az egyik a fizikai jellemzők, míg a mások csoportja a kémiai jellemzők. Ezért különféle proximális talajérzékelőket fejlesztettek ki a különböző mechanikai, fizikai és kémiai tulajdonságai mérésére, elektromos és elektromágneses, optikai és radiometriai, mechanikai, akusztikus, pneumatikus és elektrokémiai mérési módszerekkel (ADAMCHUK et al., 2004). Az elektromos és elektromágneses érzékelők az elektromos vezetőképesség, kapacitás vagy induktivitás mértékét mérik. Ezekkel az érzékelőkkel megcélzott legfontosabb talajtulajdonságok a talaj textúra (agyag-, homok- és vályogtartalom), talaj szervesanyag-tartalma, nedvesség, sótartalom (LI et al., 2009), pH, ioncserélő kapacitás (Cation exchange capacity = CEC) és a talajszerkezet mélység szerinti változékonysága (MUELLER et al., 2003). Optikai és radiometrikus érzékelőket használnak a talaj szervesanyag-tartalmának, széntartalmának (VISCARRA et al., 2006; SHI et al., 2015;), nehézfém szennyeződésének (KALNICKY et al., 2001), agyagtartalmának (BOUSBIH et al., 2019), homoktartalmának (STEVENSON et al., 2023), pH (JI et al., 2014), és nitrát- vagy nitrogéntartalmának (KUANG és MOUAZEN, 2011) mérésére.

Mechanikus érzékelők mérik a talajba hatoláshoz szükséges erőt és ezen keresztül a talajjellenállást (HEMMAT és ADAMCHUK, 2008). Az elektrokémiai érzékelők ion-szelektív membránokat használnak, az ionok (H^+ , K^+ , NO_3^- , Na^+ , stb.) aktivitásának meghatározására (SETHURAMASAMYRAJA et al., 2007). A méréshez gyakran szükség van kiegészítő érzékelők alkalmazására a talajtulajdonságok

változékonyságának egyidejű vizsgálata és azok térbeli számszerűsítése érdekében (GRUNWALD et al., 2015).

A kémiai érzékelők két fő típusra oszthatók: fotokémiai és elektrokémiai. A fotokémiai érzékelők a vegyi anyagokat az egyedi spektrális tulajdonságaik alapján mérik, az elektrokémiai szenzorok viszont a kémiai reakciókból adódó elektromos tulajdonságokat határozzák meg (ANGKAWINITWONG és WILLIAMS, 2021). A leggyakrabban mért paraméterek közé tartozik a talaj pH, sótartalma, tápanyagai, oxigén (O₂), szén-dioxid (CO₂), metán (CH₄), valamint a fotoszintézis bizonyos jellemzői. A talaj tápanyagtartalmának valós idejű mérése, különösen a nitrogén (N), a foszfor (P) és a kálium (K) nélkülözhetetlen a megfelelő mennyiségű műtrágya kijuttatásához. Ezeknek az érzékelőknek az alkalmazási köre még kezdetleges stádiumban van (BURTON et al., 2018).

A CO₂ és az NH₄ gázok jelentős szerepet töltenek be az üvegházhatás kutatásában is. Kétféle gázérezékelőt alkalmaznak: fénoxid gázérezékelők (érezékelő elektromos ellenállása nő, ha bizonyos típusú gázokkal érintkezik) és optikai gázérezékelők (abszorpciós spektrum meghatározásával állapítják meg az adott gázt) (DHALL et al., 2021).

A talajvízpotenciál-érezékelők iránti kisebb érdeklődés a következőknek tudható be: a talaj vízpotenciálja és a hozam közötti kapcsolat még nem teljesen megértett, az olcsó talajvízpotenciál-érezékelők még nem állnak rendelkezésre és a rendelkezésre álló talajvízpotenciál összekapcsolásának nehézségei az IoT rendszerekkel.

BAR-ON et al. (2019) egy lehetséges megvalósítást mutattak be egy mikroszámítógép alapú kereskedelmi érezékelővel (URL²). Az alkalmazott

talajszonda a talaj ellenállását határozza meg, amelyből a talajnedvesség kiszámítható.

GMUR et al. (2012) spektroradiométert használtak a talaj hiperspektrális elemzéshez a nitrogén, szén és szerves anyag tartalom meghatározásához. A talaj vezetőképességének meghatározásán keresztül WILCZEK et al., (2012) refraktormétert használt a sótartalom meghatározásához. SKIERUCHA et al. (2012) az elektromos vezetőképesség folyamatosan üzemben történő mérésére alapozva végzett kutatást a talajnedvesség és hőmérséklet meghatározásához. A kiépített rendszer két részre osztható, egy nyolccsatornás TDR/MUX típusú mérőegységre (a talajtulajdoságok mérésére) és egy GPRS modemre az internetes szerver eléréséhez.

SCUDIERO et al. (2012) a talaj víztartalmát és sótartalmát egy alacsony költségű kapacitív elven működő szenzorral határozza meg $\pm 10\%$ -os pontossággal. Számos esetben a talajt a mezőgazdasági gépek tranzitja tömöríti, ami a terméshozam érezhető csökkenését okozza. VALERA et al. (2013) egy elektromos penetrométerrel felszerelt eszközt fejlesztett, amely a talajok ellenállását méri a munkagép előtt és után meghatározva a talajtömörödöttséget.

2.2.3.3. *Képalkotó szenzorok*

A képérzékelő vagy képalkotó egy olyan érzékelő, amely észleli és továbbítja a kép létrehozásához használt információkat. Ezt úgy teszi, hogy a fényhullámok változó csillapítását (ahogy áthaladnak vagy visszaverődnek a tárgyakon) jelekké, kis áramlökésekké alakítja, amelyek továbbítják az információt (RIBA, 2022). A hullámok lehetnek látható fény vagy más elektromágneses sugárzások. A képérzékelőket mind analóg,

mind digitális típusú elektronikus képalkotó eszközökben használják, beleértve a digitális fényképezőgépeket, kameramodulokat, kamerás telefonokat, optikai egereket, orvosi képalkotó berendezéseket, éjjellátó berendezéseket, például hőkamerákat (OMIA et al., 2023).

A kamera a 3D környezetet képezi le a 2D képre. A kamerák működésének leírásához a lyukkamera modellt alkalmazzak (ZATSERKOVNYY és NURMINSKI, 2022). A lyukkamera-modell matematikai összefüggést ír le a háromdimenziós térben egy pont koordinátái és egy ideális lyukkamera képsíkjára vetítés között, ahol a kamera rekesznyílását pontként írják le, és nem használnak lencsét a fény fókuszálására (JAHNE, 2004). A térbeli pontok 3D-s koordinátáiból a 2D-s képkoordinátákba történő leképezés homogén koordinátákkal szokták gyakran ábrázolni (1. egyenlet).

$$\vec{y} \sim \bar{\bar{C}}\vec{x} \quad (1.)$$

ahol, \vec{x} a homogén koordináták 4 dimenziós vektora, $\bar{\bar{C}}$ a 3×4 kamera mátrix és y a kép 3 dimenziós pontjai (SANGWINE, 2013).

A kamera olyan eszköz, amely egy fénytől elzárt kamrából áll, amelynek rekesznyílásán keresztül lencsék segítségével egy tárgy képét egy felületre vetíti rögzítés céljából (fényérzékeny filmre vagy elektronikus érzékelőre), vagy elektromos impulzusokká alakítják át (ASSIRELLI et al., 2015). Az elektromos elveken alapuló képalkotó rendszerek ugrásszerű fejlődésével a digitális fényképezőgépek az elmúlt években kiszorították a piacról a hagyományos filmes fotózást.

Az elektronikus érzékelőknek több típusa is létezik: töltéscsatolt eszköz (CCD), elektron-sokszorozó töltéscsatolt eszköz (EMCCD), komplementer fém-oxid-félvezető (CMOS), hátulról megvilágított CMOS (BERNACKI, 2019).

Az emberi szem számára látható fénytartományban érzékeny RGB-kamera alacsony költségű megoldás számos mezőgazdasági alkalmazáshoz, terményfelismeréshez és osztályozáshoz, lokalizációhoz és térképezéshez, navigációhoz és gyomérzékeléshez egyaránt. (TILLET et al., 2002; CHEEIN et al., 2011; BOSSU et al., 2009; BERGE et al., 2012). Azonban az RGB jelek által generált digitális képek eszközfüggőek, azaz különböző digitális kamerák különböző RGB válaszokat hoznak létre ugyanahhoz az egy objektumhoz (HONG et al., 2001). Az RGB kamerákat sikeresen használják mezőgazdasági alkalmazásokban gyomfelderítéshez, osztályozáshoz (termések), de mindig szabályozott fényviszonyok mellett (CHO et al. 2002).

Az RGB kamerák viszont közvetlenül nem képesek mélységinformációt adni, kivéve, ha sztereólátást vagy más több kamerát alkalmazó rendszert használunk (ZHAI et al. 2016; BIETRESATO et al., 2016).

Az RGB kamerák által elérhető információk csak a három színcsatornára (piros, zöld és kék) korlátozódnak (WANG et al, 2018). Nagyságrendekkel több információ nyerhető ki a növényállományból, ha nem csak RGB színtartományban vizsgálódunk. Ennek a problémának a leküzdésére úgynevezett multispektrális képalkotó rendszereket alkottak meg, amelyek képesek rögzíteni egyidejűleg más, az emberi szem számára nem látható spektrális tartományokat is, és nagy mennyiségű spektrális

információt gyűjteni viszonylag rövid idő alatt (HAGEN és KUDENOV, 2013; SUZUKI et al., 2018). A multispektrális képalkotás az elektromágneses spektrum meghatározott hullámhossz-tartományán belül rögzíti a képadatokat. A hullámhosszokat szűrőkkel lehet elválasztani, vagy bizonyos hullámhosszokra érzékeny műszerekkel lehet detektálni, beleértve a látható fénytartományon túli frekvenciákból származó fényt is, azaz az infravörös és az ultraibolya sugárzást. Lehetővé teszi olyan további információk kinyerését, amelyeket az emberi szem nem képes felfogni a vörös, zöld és kék színeket látó receptoraival. (RAMIREZ et al., 2022).

Hiperspektrális távérzékelésről akkor beszélhetünk, ha a spektrális felbontás nagy, akár több száz sávban felvételező érzékelőket alkalmazunk (KWAN, 2018).

Minden élő anyagnak egyedi, közeli infravörös (NIR) abszorpciós mintája van, amely felhasználható karakterizáció és kvalitatív vagy kvantitatív elemzésre (LOPEZ et al., 2016).

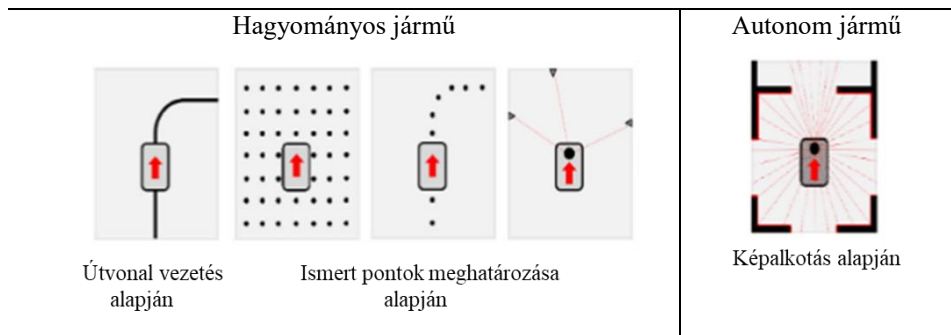
A kamerák nagyon érzékenyek a fényviszonyokra; ezért többféle kalibrálásra is szükség van úgy mint a fókuszpont, a lencse deformációjának kompenzációja, hogy megfelelően működjenek.

2.2.3.4. *Navigációs szenzorok*

Az elmúlt években drámai emelkedés tapasztalható az autonóm mobil robotok alkalmazásában (WANG és WANG, 2021). Hasonlóan az emberhez, egy autonóm mobil robot is képes önálló döntéshozatalra és korrekciós intézkedések megtételére. Egy teljesen autonóm robot képes megfigyelni környezetét, ami alapján ítélni tud, majd végrehajtani egy cselekvést vagy beavatkozást (FRAGAPANE, 2021). Az útvonaltervezés

kulcsfontosságú feladat az autonóm mobil robotok navigációs rendszerében, amely alapján a robotnak meg kell találnia az optimális utat (pl.: a legrövidebb út, a legrövidebb idő alatti út) a kívánt teljesítmény elérése érdekében (SOARES, 2016). Egy robot útvonalának megtervezését két nagy kategóriába lehet besorolni: a globális úttervezés (a terep teljes ismeretére alapul statikus környezetet feltételezve) és lokális úttervezés viszont hiányos ismeretet feltételez a környezetről, és általában online alakul ki a fedélzeti érzékelők adatai alapján a dinamikus környezetben történő navigációhoz.

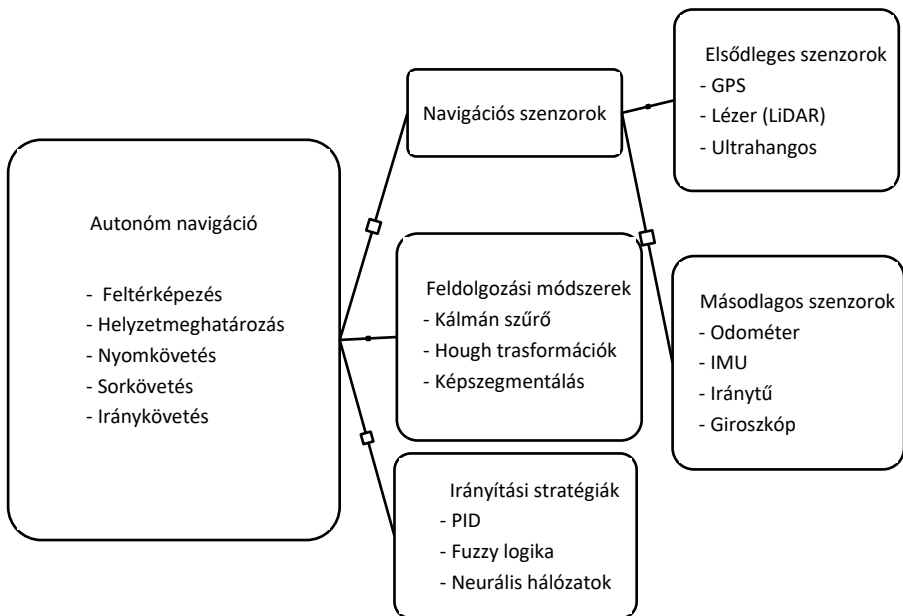
A hagyományos irányított jármű csak rögzített utat képes követni (trajektória), és csak előre meghatározott pontokon tud végighaladni. Az autonóm mobil robotok bármely elérhető pont körül mozoghatnak adott területen belül, elkerülve az ütközéseket (3. ábra).



3. ábra – Robotirányítási módszerek (FRAGAPANE, 2021)

Az autonóm mobil robotok legmeghatározóbb tulajdonsága, hogy képes navigálni megszakítás nélkül új helyi útvonal létrehozásával, amikor korábban előre nem látott akadályt észlel (LOGANATHAN és AHMAD, 2023).

A GNSS-alapú gépirányítás a mezőgazdasági robotok legszélesebb körben alkalmazott navigációs stratégiája (SANTOS et al., 2019). A GNSS jelek nyomon követik a mezőgazdasági robotok helyzetét és a járművek a globális GNSS koordináta-rendszerhez képest eltérését. Amikor a mezőgazdasági robotok nyílt környezetben működnek, a GNSS hatékonyan javíthatja a rendelkezésre álló erőforrások felhasználásának hatékonyságát és a valós idejű információszerezést (ROVIRA-MÁS et al., 2015). HIREMATH et al. (2014) rámutatott, hogy a globális navigációs műholdrendszer (GNSS) bizonyos feladatokhoz nem elég pontos, és a navigáció meghiúsulhat, ha a jel megszakad (ESPOSITO et al., 2021; MÜLLER, 2017). Éppen ezért gyakorta proximális szenzorokat használnak a robot táblán belüli helyzetének meghatározásához. A 4. ábra a robotok autonóm irányítási lehetőségeit és módszereit foglalja össze.



4. ábra – Mezőgazdasági mobil robotok autonóm navigációs rendszerének alapelemei (Forrás: SHALAL et al., 2013)

Az ultrahangos tartományérzékelők az egyik leggyakrabban használt érzékelők a robotikában. Az ultrahangos érzékelőket a robotikában akadályészlelésre és navigációra használják (GUTIERREZ–OSUNA et al., 1998). Az alkalmazástól függetlenül különös gondossággal kell eljárni figyelembe kell venni az érzékelők beépítési helyzetét, az ultrahang kúpszögét, ezen kívül, ha több érzékelő működik ugyanazon a területen, interferencia léphet fel. Az interferencia csökkentésére szolgáló megelőző intézkedés a távolság növelése lehet. Az érzékelő működése a Time-of-Flight (ToF) elvén alapul. Kültéri alkalmazásuk azonban korlátozott, mivel ezek megkövetelik, hogy a tárgyak merőlegesek legyenek az érzékelőre, hogy az ultrahang visszhangok megfelelően visszaverődjenek. TODA et al. (1999) egy szonáron alapuló vetéssor-térképezési technikát mutatott be a kukorica azonosítására a robot navigálásához. HARPER és MCKERROW (2001) ultrahangos érzékelőket használt a növények felismeréshez navigációs feladatok ellátására. IIDA és BURKS (2002) munkájukban ultrahangos érzékelők használatát mutatták be a munkagép és a fák relatív helyzetének mérésére a gyümölcsösben való navigációhoz.

Az elmúlt években a lézer alapú távérzékelést (Light Detection and Ranging = LiDAR) egyre gyakrabban használják a robotnavigációra (SUN et al., 2023). Előnyei a nagy mérési pontosság és a nagy mennyiségű távolsági információ magas frekvenciájú szolgáltatásának képessége miatt, így ezeket a szenzorokat széles körben használják az erdőszetben és a polgári területeken mérnöki vagy építészeti alkalmazásoknál már hosszú ideje (MUKUPA et al., 2017), míg a mezőgazdaságban való felhasználásuk csak körülbelül 20 évre nyúlik vissza. A legtöbb LiDAR érzékelő két részből tevődik össze: áll egy lézersugarat kibocsátó fényforrásból és egy

vevő fotodetektorból. A kibocsátott lézersugár a céltárgy egy körülhatárolt területét érint, a visszaverődött fény egy részét a fotodetektor rögzíti és átalakítja feszültségjelre. A 2-D LiDAR szenzor a környezetet egy sík forgótükörrel ellátott lézersugár segítségével pásztázza, így kialakítva egy két-dimenziós pontfelhőt. A 3-D LiDAR érzékelők a harmadik dimenziót is képesek letapogatni a 2-D LiDAR-hoz képest egy harmadik tengely menti leképezéssel. Ezt a megoldást széles körben alkalmazzák az autonóm járművek kutatásában. A LiDAR érzékelők képesek meghatározni a cél távolságát a lézer fény kibocsátása és visszatérése között eltelt idő mérésével. Általában az eltelt idő mérése két különböző technikával történik, Time-of-flight-tal és fáziseltolással. Egy harmadik mérés elve (háromszögelés) a trigonometrikus szögviszonyok alkalmazásán alapul (BERALDIN et al., 2010).

A mezőgazdasági robotok üzemeltetése során a LiDAR-t elsősorban akadályelkerülésre használják (SKOCZEŃ et al., 2021). Kezdetben LiDAR érzékelőket az önjáró permetezőgépek által kijutatott növényvédőszer áramlási sebességének valós idejű szabályozásához alkalmazták (ESCOLÀ et al. 2013; WEI és SALYANI, 2004).

2.3. A mesterséges intelligencia, gépi tanulás alkalmazása

2.3.1. Mesterséges intelligencia jellemzői, alkalmazása

A 21. században a mesterséges intelligencia (Artificial Intelligence = AI) szinte minden területen fontos kutatási területté vált: mérnöki, tudomány, oktatás, orvostudomány, üzlet, számvitel, pénzügy, marketing, közgazdaságtan, tőzsde és jog, stb. (HALAL, 2003). Ugyanakkor egyre nagyobb érdeklődést váltanak ki a környezetvédelem és fenntarthatóság

kutatási területein, valamint a klímakutatásban is (RASP et al., 2018; REICHSTEI et al., 2019). A mesterséges intelligencia alkalmazásához elengedhetetlen, hogy a robotok képesek legyenek önállóan dolgozni és elkerülni a munkájuk során felmerülő problémákat. Számos tanulmány kimutatta, hogy a robotika és az önálló tanulás jelenlegi fejlődési szakaszában a technológiai innováció legerősebb kombinációja. Lehetőségünk van különböző típusú mesterséges intelligenciákat használni attól függően, hogy a robotnak milyen felhasználási területet és milyen feladatot kell végrehajtania.

- Gyenge mesterséges intelligencia:

Ennek a mesterséges intelligenciának köszönhetően a programozott robot csak azt a munkát tudja majd elvégezni, amelyet előre definiáltunk számára. Nem lesz képes önállóan dönteni, nem fog másképp reagálni a dolgokra, mint ahogyan azt előre elhatározták.

- Erős mesterséges intelligencia:

Az ezzel az intelligenciával ellátott robotok már képesek autonóm döntéshozatalra és autonóm munkára. Bizonyos esetekben elemezhetik az összegyűjtött adatokat és továbbíthatják azokat.

- Speciális mesterséges intelligencia:

Ezt a fajta intelligenciát főleg csak akkor használják, ha a robotnak bizonyos meghatározott feladatokat kell végrehajtania. A mezőgazdaság számára ez az a rendszer, amely a legjobb megoldást kínálja számunkra. Megfelelő képesséssel különböző betegségeket képes felismerni, amelyeket különböző kategóriákba sorol. Ebbe a kategóriába tartoznak a szántóföldi robotok, amelyek a termés állapotát figyelik (BRYSON, 2013).

Manapság megannyi lehetőség létezik a nagy adathalmazok (Big data) információtartalmának megfelelő feldolgozására, amelyek a gépi tanulás nyújtotta lehetőségek előretörő fejlődésének köszönhetőek. Olyan módszerek állnak rendelkezésre, mint a fuzzy logika, a mesterséges neurális hálózatok (Artificial Neural Network = ANN), vagy a neuro fuzzy logika, amelyek megkönnyítik a probléma megoldását (JHA et al., 2019).

A hagyományos módszerekkel szemben támasztott előnyeik miatt a mezőgazdaság különböző területein már gyakorta alkalmazzák a mesterséges neurális hálózatokat. Fő előnyük, hogy előrejelzést képesek adni úgy, hogy figyelembe veszik az egyes információk egymásra gyakorolt hatását. A gyomnövények és a kultúrnövények megkülönböztetésére GLIEVER és SLAUGHTER (2001) ilyen neurális hálózatokat alkalmazott. A növények vízszükségletének előrejelzését MAIER és DANDY (2000) szintén neurális hálózatokkal oldotta meg.

A mezőgazdasági robotfejlesztőknek a változó környezet mellett úgyszintén nagy kihívást jelent, hogy a berendezéseknek gyakorta sérülékeny, élő anyagokkal kell dolgozni. Az interferencia tényezők inkonzisztens környezeti struktúrákból származhatnak, változó formájú és színű kultúrnövényeket, egyenetlen terepfelületeket, ill. ingadozó fényt, stb. (AGHI et al., 2020; HIREMATH et al., 2014) foglalhatnak magukba.

A gépi tanulás (Machine Learning = ML) fejlesztési gyakorlata különbözik a hagyományos szoftverfejlesztéstől, mert a gépek automatikusan megtanulják a problémamegoldó készségeket az adatok alapján (AMERSHI et al., 2019). A hagyományos szoftverfejlesztésben a programozó kódot fejleszt algoritmusok alapján. A gépi tanulás során a

modellek problémamegoldó készségeket tanulnak, és nincs ember által olvasható kód bennük (JANARDHANAN et al., 2020). A mesterséges neurális hálózatok a gépi tanulás és mesterséges intelligencia egyik legfontosabb eleme. Az emberi agy szerkezete ihlette őket, és úgy működnek, mintha összekapcsolt csomópontok lennének, amelyekben egyszerű feldolgozási műveletek zajlanak. A neurális hálózatok alkalmazása nagyon széleskörű és a mezőgazdaságot is magában foglalja. Ezen területek közé tartozik a mezőgazdasági termelési hatékonyság előrejelzése több változó alapján (ADISA et al., 2019), betegségek és kártevők ellenőrzése (RAHMAN et al., 2020; FERENTINOS, 2018), intelligens gyomirtás (SUBEESH et al., 2022) és a betakarított termények minőségének osztályozása (NIKIFOROV et al., 2020).

Mesterséges intelligencia módszerek támogatják a döntéshozatali rendszereket a mezőgazdaságban, segítik a tárolási és szállítási folyamatok optimalizálását, ill lehetővé teszik a felmerülő költségek előrejelzését a választott gazdálkodási iránytól függően (NYÉKI et. al., 2021). A precíziós mezőgazdaság feltételeinek kielégítésére egyre gyakrabban alkalmazzák a fejlett adatelemzési módszereket, beleértve a mesterséges intelligencia módszereiből származókat is.

Mesterséges idegi hálózat (ANN) az egyik leggyakrabban alkalmazott ilyen eszköz. A mesterséges neurális hálózatok helyettesíthetik a klasszikus módszereket, és a klasszikus matematikai modellek egyik fő alternatívája (KUJAWA és NIEDBAŁA, 2021).

2.3.2. *Mesterséges látás, képfeldolgozás*

A gépi látás a mezőgazdasági robotok legelterjedtebb információforrása. A műholdas távérzékelési módszereknél sok esetben mesterséges intelligencia dolgozza fel az adatokat és határozza meg az optimális beavatkozási módszert.

Nagy számú vizuális jellemző áll rendelkezésre az egyes növényfajok azonosítására, úgymint a biológiai (morfológia), spektrális jellemzők, és alaktani struktúra (GRINBLAT et al., 2013).

A felvételezéshez legtöbb esetben RGB vagy infrakamerákat alkalmaznak (NIJLAND et al., 2014). A növényállomány monitorozásánál az infrakamerás felvételek nagyon előnyösek, alkalmazásukkal megítélhető a kelés minősége, észlelhetőek a növényi betegségek, információ gyűjthető a precíziós öntözéshez vagy termésbecslés végezhető. Az RGB kamerák esetében a színekövető (color tracking) módszerrel a soron történő végighaladásra is lehetőség nyílik.

Azonban az információk pontosságát és megbízhatóságát a környezeti tényezők, például a természetes fény és annak változása, valamint a vizsgált objektumok véletlenszerűsége és sokfélesége nagymértékben befolyásolja (TARR et al., 1998).

A mély tanulás (Deep Learning = DL) a képfeldolgozás modern technikája, amely nagy lehetőségeket rejt magában. Különböző területeken sikeresen alkalmazva a közelmúltban a mezőgazdaság területére is bekerült (KAMILARIS et al., 2018). A képelemzés fontos kutatási terület a mezőgazdaság területén is: képazonosításra, osztályozásra, anomáliák kimutatására, stb. intelligens elemzési technikákat használnak különböző alkalmazásokban (TEKE et al., 2013;

ISHIMWE et al., 2014). A leggyakoribb képelemzéshez használt technikák a gépi tanulást is beleértve (K-közép, ANN) a különböző vegetációs indexek, leggyakrabban a normalizált differenciált vegetációs indexet (Normalized Difference Vegetation Index = NDVI) alkalmazzuk.

A fent említett technikák mellett a mély tanulás (Deep Learning = DL) egy modern megközelítés, amely sok lehetőséget rejt magába (LECUN és BENGIO, 2015). A DL azonban komplexebb neurális hálózatot alkot, amely az adatok hierarchikus megjelenítését biztosítja különféle konvolúciók segítségével. Ez jobb tanulási képességeket tesz lehetővé egy komplex rendszer teljes összetettségének megragadásához, és így a képzett modell jobb pontosságot érhet el (SCHMIDHUBER, 2015).

A konvolúciós neurális hálózat (Convolutional Neural Network = CNN) egy jól ismert mély tanulási módszer, amit az élőlények természetes vizuális érzékelési mechanizmusa ihlette (GU et al., 2015). A kutatások jelentős része az osztályozással és azonosítással foglalkozik, beleértve az akadályok észlelését (STEEN et al., 2016; CHRISTIANSEN et al., 2016), termésszámolást (SA et al., 2016). KUWATA és SHIBASAKI (2015) a kukorica hozamát határozták meg neurális hálózatok segítségével, amelyet NYÉKI et al. (2021) pontosított. SAXENA és ARMSTRONG (2014) optikai és röntgen képalkotást alkalmazott a gyümölcs és a csomagolt élelmiszerek osztályozásánál.

A robotokkal való hatékony munka érdekében fontos megemlíteni néhány lényeges komponenst. Mindenekelőtt a CV (Computer Vision), amely a digitális képek vagy videók egymáshoz igazításával egyfajta jövőképet ad a rendszernek. Ez a technológia lehetővé teszi a fejlett robotok számára, hogy emberi beavatkozás nélkül hajtsanak végre olyan


feladatokat, mint például: a beteg termény, vagy olyan olyan tárgyak felismerése, amelyeknek nem kellene a környezetben lenniük.

A Hough transzformáció az egyik leggyakrabban alkalmazott gépi látásmód alakzatok, folyamatos vonalak vagy görbék felismerésére. A Hough számítási szempontból hatékony eljárás így alkalmas a növényi részek elkülönítésére, az esetleges vetési vagy csírázási hibák azonosítására is (HEMMING és RATH, 2002).

A robotrendszereknek látórendszerekre van szükségük ahhoz, hogy felismerjék és megkülönböztessék a növényeket a gyomoktól. Ezért a legtöbb robot látásérzékelőkkel van felszerelve. Többnyire az RGB kamerák terjedtek el, bár legtöbbjük viszonylag alacsony felbontású. (640×480-tól 1624×1230-ig). Az alacsony felbontás magyarázattal szolgálhat arra, hogy a legtöbb esetben a kamera érzékelője a kívánt tárgy közelében van elhelyezve. A mechanikus gyomirtás alternatív érzékelői az infravörös kamerák és a sztereó kamera. A környezeti és fényviszonyok nagy hatással lehetnek a fényképezőgép képfeldolgozási technikáira. A LiDAR viszont pontos 3D mérési adatokat biztosít rövid és nagy távolságokról még kedvezőtlen időjárási és fényviszonyok között is.

A kamera képek elemzésének egy sarkalatos pontja a talaj elválasztása a növényektől. Ezt az eljárást elsőként 1989-ben az Egyesült Államokban alkalmazták arató-cséplőgépek sorvezetésére (MARCHANT és BRIVOT, 1995). Betakarításkor egy referencia (adott színű) tábla alkalmazásával az elkészült felvételek egyes pixeleinek színei összehasonlíthatóak a tábla értékeivel, így elválaszthatóvá válik egymástól a növény illetve a háttér (SLAUGHTER et al., 1997).

TILLETT és HAGUE (1999) infravörös szűrőt alkalmazott, ezzel fokozva a kontrasztot a természetett növény és a talaj között, így elkülönítve azokat egymástól meghatározta a növényi sorokat. Későbbi tanulmányában (TILLETT et al., 2001) a detektálás módjának finomítása érdekében sávszűrőt használt a sorok lokalizálásához. KISE et al. (2005) ezt a rendszert továbbfejlesztette és két RGB kamerát alkalmazva sztereovíziós rendszert alakított ki, aminek köszönhetően a növényi sorok egyenestől való eltérése 30-50 mm között változott a haladási sebesség függvényében. A kedvezőtlen hatások (árnyékok) kiküszöbölése miatt MARCHANT és ONYANGO (2000) a felvételeket RGB színcsatornákra bontották fel, így eredményként egy monokróm felvételt nyertek, amin a talaj sötétebb árnyalatú. Ezt felhasználva TILLETT et al., (2008) egy olyan detektációs módszert alakított, amely egy RGB kamera alkalmazásával határozza meg a növények helyzetét (5. ábra, zöld kereszt). A módszer alkalmazásával a gyomirtást követően 80%-kal sikerült a gyomosodás mértékét csökkenteni.



5. ábra – A növények kézzel mért (kék kereszt) és számított helyzete (zöld kereszt) (TILLETT et al., 2008)

ÅSTRAND és BAERVELDT (2002) a morfológia tulajdonságok figyelembe vételével azonosítják be a növényeket két kamera segítségével. A módszer egy, a haladási irányra ellentétesen elhelyezett infravörös szűrővel ellátott kamera felvételeire alapú, amelynek képein egy Hough transzformáció alkalmazásával ismerik fel a növényi sorokat (6. ábra).



6. ábra – A felismert növények soraira illesztett vonalak (ÅSTRAND és BAERVELDT, 2002)


A második RGB kamera a növények helyzetének meghatározását teszi lehetővé. Együttvéve 13 jellemzőt vizsgál meg, amelyből 6 színi tulajdonság, pl. a színösszetétel és 7 morfológia tulajdonság, mint pl. a felület nagysága.



7. ábra – A növény leveleinek felismerése morfológiai jellemzők alapján (ÅSTRAND és BAERVELDT, 2002)

Ennek a módszernek az alkalmazásával a termesztett növények pozíciójának meghatározása szegmentálás után 97%-os pontossággal lehetséges.

SØGAARD és OLSEN (2003) munkájukban olyan módszert fejlesztettek ki, amelynél a szegmentálás elhagyásával szintén RGB kamerát használva 720×576 pixel felbontás mellett történik a növénsorok detektációja. Az előzetes kalibráció után a berendezés $0,5 \text{ m/s}$ sebességű mozgása közben az elkészült szürkeárnyalatos felvételeket egy algoritmus vízszintes sávokra osztja fel. A program további része a növényi sorok és az osztások metszéspontját határozza meg az egyes szeletek hisztogramja alapján, így állapítva meg a sorok helyzetét (8. ábra).



8. ábra – A növényi sorok helyzetének on-the-go meghatározása (SØGAARD és OLSEN, 2003)

2.3.3. Paradicsom termés detektálása gépi látás alkalmazásával

A paradicsom (*Solanum lycopersicum L.*) Dél- és Közép-Amerikában őshonos a burgonyafélék családjába tartozó növény. Az elnevezés egyaránt utal a növényre és annak bogyótermésére is, amelyet Magyarországon elsősorban zöldségként használunk fel. A világ paradicsom termelése 2003 és 2017 között éves szinten 124 millió tonnáról több mint 177 millió tonnára nőtt, ezzel párhuzamosan a fogyasztás is tartósan, körülbelül 2,5%-kal nőtt (NEMESKÉRI et al., 2019).

Számos kutatás bizonyítja a számítógépes látáson alapuló roncsolásmentes vizsgálatok hatékonyságát a zöldség és gyümölcs osztályozás témakörében az élelmiszeriparban és precíziós mezőgazdaságban egyaránt. A paradicsom színének jellemzőit széleskörűen az érettségi szint felismerésének jó mutatójaként használják (SELVARAJ et al., 2013), ami kapcsolatban van a cukortartalommal, a savassággal és az ízzel is (LI et al., 2008). Éppen ezért a színi jellemzőket széles körben alkalmazzák a termés minőségének értékelésére. Ebben az esetben a szín jellemzői a képek mindegyik pixele három összetevőből származik: piros, zöld és kék.

A gépi tanulás a mesterséges intelligencia részhalmaza. Azonban a színszegmentálás több paraméterre is érzékeny úgy mint a megvilágítási viszonyokra, vagy az egyes kitakarásokra. Ezen problémák enyhítésére a szokásos RGB (piros, zöld, kék) színtér helyett más színtereket használnak, mint például a HSV (Hue, Saturation, Value), HIS (Hue, Intensity, Saturation), YIQ (perceived luminance, color/luminance information), YCbCr (luminance component, blue-difference chroma, red-difference chroma) azért, hogy színinformációt vonjunk ki a detektálandó

tárgyból, jelen esetben a gyümölcsből. QINGCHUN et al. (2015) kifejlesztette egy paradicsom begyűjtő robotot üvegházi körülmények között az érett paradicsom azonosítására és a gyümölcsök helyzetének meghatározására, ami az RGB színtér képeinek HIS színmodelljével dolgozik.

AREFI et al. (2011) egy olyan algoritmust javasolt ami kombinálja az RGB, HSI és YIQ színtereket és morfológiai jellemzőket az érett paradicsom felismerésére. MALIK et al. (2018) érett paradicsom kimutatást mutatott be a HSV színtéren alapuló algoritmusokat és Watershed szegmentációs módszert alkalmazta a fürtös gyümölcsök egymástól való elkülönítésére. HUANG et al. (2012) az $L^*a^*b^*$ színteret használta az érett paradicsom szegmentálására és lokalizálására üvegházban, és fuzzy logikát a gyümölcsök megkülönböztetésére a háttértől. JHAWAR (2016) egy mintafelismerésen alapuló lineáris regressziós módszert mutatott be az érettség meghatározására RGB képek felhasználásával. KHODABAKHSHIAN et al. (2017) multispektrális képeket használtak a bogyók minőségének értékeléséhez. MOHAMADI et al. (2004) átalakította a paradicsom RGB-képeit HSV képekre, majd szegmentálva azt az érett paradicsom régióját egy küszöbérték szerint a paradicsom középponti koordinátáinak kiszámításához használta fel. A fenti módszer főként a színháttér-leválasztáson alapul az érett paradicsom azonosítása végett. A felismerési hibaarány azonban viszonylagos magas, mert az éretlen zöld paradicsom színe hasonló a levélszínre. ZHANG et al. (2021) elválasztotta a paradicsomot a háttértől egy illesztési görbe segítségével, és háromdimenziós pozicionálást hajtott végre a vizuális képalkotásnak megfelelően. WANG et al. (2016) küszöbszegmentációt végzett a Niblack

algoritmuson keresztül, és kivonta az érett paradicsomot a minimális kritikus téglalap módszerrel. YAMAMOTO et al. (2014) kivonták a levelek, szárok színét és szerkezetét a háttérből, így kinyerve a paradicsom gyümölcsseinek képpontjait. A fenti módszerek főként a paradicsom egyes részleteit vonják le a képből (szín, forma, és textúra), majd osztályozót használnak az észleléshez és felismeréshez (EHRET et al., 2011). Azonban az átfedési és a kitakarási problémákra nem jelentenek megoldást (SENTHILNATH et al., 2016).

CLEMENT et al. (2012) bevezetett egy paradicsom osztályozó eljárást szín, méret és súly alapján. Az ilyen osztályozási módszereket jelentősen befolyásolják a termés minőségi hibái. A paradicsomhiba-észlelés javítása érdekében ARAKERI (2016) nagy felbontású képek és képtextúra használatát javasolta. Azonban a nagy felbontású képek használata, mint pl.: hiperspektrális és multispektrális (POLDER és HEIJDEN, 2010) képalkotó rendszerek használata sok számítási időt igényelnek és magas költségekkel járnak.

A gépi tanulási megoldásokon alapuló képi detektálási és osztályozási módszerek az adatgyűjtés által, a modell betanításával és a betanított modell felhasználásával képesek előrejelzéseket adni. A számítógépes látás a képet egy pixel halmaznak tekinti (KHAN és AL-HABSI, 2020). Az elmúlt évek kutatásai alapján, amelyek a mély tanulással, és a konvolúciós neurális hálózat (CNN) bevezetésével foglalkoztak, kijelenthető, hogy az objektum detektálási pontossága nagymértékű fejlődésen ment keresztül (TAYE, 2023).

A TensorFlow (URL³) egy nyílt forráskódú gépi tanulási platform a modellek fejlesztéséhez. Az adatok rövid időn belüli betanítása heterogén

számítási erőforrások, például CPU-k, GPU-k és TPU-k felhasználásával. A TensorFlow funkciók és osztályok széles skáláját kínálja, amelyek lehetővé teszik a felhasználók számára, hogy összetett modelleket építsenek fel. A modellfejlesztés betanítási szakasza iteratív jellegű, amelyben a konfigurációs paramétereket hangolják folyamatosan az előrejelzés pontosságának javítása érdekében (JANARDHANAN et al., 2020). Ezeket a paramétereket minden iteráció során archiválni kell, mert a vizsgálati eredmények jelzik a pontosságot.

Az igazságmátrix (confusion matrix) egy nagyon népszerű mutató, amelyet osztályozási problémák megoldása során használnak. Az igazságmátrix az előrejelzett és a tényleges értékekből származó számokat képviselik (2. táblázat).

2. táblázat – Igazságmátrix felépítése

Mérés \ valóság	Pozitív	Negatív
Pozitív	valós pozitív (VP)	álpozitív (ÁP)
Negatív	álnegatív (ÁN)	valós negatív (VN)

Különböző teljesítménymutatókat használnak az észlelés értékelésére például pontosságot, precizitást, F1 pontszámot stb. Pontosság (P) a valós pozitív és valós negatív eredmények arányát adja meg az összes kimenetelhez képest (2. egyenlet).

$$P = \frac{VP+VN}{VP+ÁP+ÁN+VP} \quad (2.)$$

A szenzitivitásnak a valós pozitív eredmények aránya az összes pozitív eredményhez képest (3. egyenlet).

$$R = \frac{VP}{VP+AP} \quad (3.)$$

Az F1-score a szenzitivitás és a pontosság harmonikus átlagának mértéket jelöli (4. egyenlet).

$$F_1 = \frac{2PR}{P+R} \quad (4.)$$

A paradicsom minőségi és betegségek szerinti osztályozása kihívást jelent, és a fizikai jellemzőiből adódóan nagyfokú nemlinearitást rejt magában (KUMAR et al., 2019).

SENTHILNATH et al. (2016) szabadföldi termesztésnél két UAV-eredetű képet használtak a paradicsom termésének osztályozására, de a paradicsom levelei és ágai eltakarták a gyümölcsöket, így csak alacsony detektálási pontosságot értek el.

YOSSY et al. (2017) mesterséges neurális hálózatot (ANN) alakított ki az érett és éretlen paradicsom osztályozására, 94%-os pontossággal. A gyümölcsök számlálását és méretbecslését MU et al. (2022) transzfer tanulási módszerekkel oldotta meg. Ez azonban hosszabb tréningezési időt eredményez, a pontosság 87,83%, a determinációs együttható (R^2) értéke a paradicsomszámra 0,87 volt. RAHNEMOONFAR és SHEPPARDY (2017) egy módosított Inception-ResNet-A modult tesztelt az észleléshez és számláláshoz több mint 90%-os betanítási és tesztelési pontossággal. FITZ-RODRÍGUEZ és GIACOMELLI (2009) olyan modelleket dolgozott ki üvegházi paradicsomból származó adatok felhasználásával dinamikus neurális hálózatok (NN) segítségével, amelyek tartalmazzák a betakarítási sebességet, a gyümölcs méretét és a gyümölcs fejlődési idejét. Az NN

modellek pontosan előre jelezték a gyümölcshez kapcsolódó paraméterek heti és szezonális ingadozásait 0,92; 0,76 és 0,88 együttthatókkal (R^2) a betakarítási sebességre, a gyümölcs friss tömegére és a fejlődési időre vonatkozóan a független validálás érdekében. GONG et al. (2021) új technikát javasolt az üvegházi paradicsom hozamának előrejelzésére az időbeli szekvenciafeldolgozáshoz használt két élvonalbeli Deep Neural Network (DNN) topológia, a Recurrent Neural Network (RNN) és a Temporal Convolutional Networks (TCN) kombinálásával.

WANG et al. (2021) üvegházakban a paradicsomtermés előrejelzési pontosságának javítására egy „wavelet neural network” (WNN) modellt fejlesztettek ki, amit egy „genetic” algoritmussal optimalizáltak (GA-WNN). A kísérleti eredmények azt mutatták, hogy a GA-WNN modell átlagos relatív hibái 0,0067, 0,0104 és 0,0242 voltak, így a GA-WNN modell nagyobb előrejelzési pontossággal és jobb illeszkedéssel rendelkezik a WNN előrejelzési modellhez képest.

QADDOUM et al. (2021) az Evolving Fuzzy Neural Network (EFuNN) módszert használták az üvegházhatású paradicsom hozamának előrejelzésére átlagosan 90%-os pontossággal. A prediktor által használt változók az üvegházban belüli környezeti paraméterek, nevezetesen a hőmérséklet, a CO_2 , a gőznyomás-deficit (VPD) és a sugárzás, valamint a 2004 és 2008 közötti múltbeli hozamokból álltak.

XIANG (2018) javította a képszegmentálási teljesítményt 385 éjszaka készített gyümölcskép kiértékelésével; a legjobb pontossági arány 90%-nál magasabb volt. A CropPointNet névre keresztelt mély konvolúciós neurális hálózatot JAYAKUMARI et al. (2021) dolgozta ki a növények szemantikai szegmentálására 3D-s perspektívából. A pontfelhőben lévő

paradicsom objektumokat a CropPointNet modell a legjobb, 65%-os teljes pontossággal osztotta fel.

Az ML módszert a paradicsom kimutatására szolgáló szín-, forma- és méretváltozók kinyerésével fejlesztették ki YAMAMOTO et al. (2014). A betanítási képek pixeleit négy osztályba sorolták (gyümölcsök, levelek, szarak és háttér). A paradicsom egyedi kimutatására foltalapú szegmentálást alkalmaztak. Az eredmények 80%-nál magasabb pontossági és visszahívási értékeket mutattak a tesztelési időszak alatt.

Az alacsony fogyasztású mikrokontrollerek miniatűr, nagymértékben optimalizált gépi tanulási modelleket futtathatnak. A beágyazott alkalmazások intelligensebbé, gyorsabbá és energiahatékonyabbá válhatnak azáltal, hogy közvetlenül a forrásnál elemzik az érzékelő által gyűjtött adatokat, ahelyett, hogy az adatokat a felhőbe továbbítanák és válaszra várnának. A beágyazott gépi tanulás vagy a TinyML ezt a koncepciót jelenti (URL⁴).

2.4. Képfeldolgozáshoz szükséges korrekciók

Digitális képfelvételezésnél nagyon fontos a kamera pontos kalibrálása különösen, ha metrikus információra van szükség (GAO és FIN, 2013). Számos gépi látási alkalmazásban ez döntő lépés az objektumot képe és annak fizikai mérete közötti kapcsolat pontos meghatározásához egy kalibrációs folyamat végrehajtásával. A számítási egyszerűség miatt a kamerát gyakran ideális lyukkamerának írják le belső és külső paraméterekkel. A belső paraméterek írják le a kamera belső geometriáját és optikai jellemzőit. A külső paraméterek leírják a kamera helyzetét és tájolását a témához képest egy rögzített koordináta-rendszerrel.


Az így felírt transzformációs mátrix pontos képmodellt biztosít ideális lyukkamera esetében. Azonban amikor fényképezőgépekhez nagy látószögű vagy olcsó objektíveket használnak, az objektív torzító hatását is figyelembe kell venni a lineáris képalkotás megtartása érdekében a projektív geometria szempontjából. Ez az optikai aberrációk egyik megnyilvánulása, amelyben a kép egyenes vonalai nem maradnak egyenesek az elektronikus képen (STANKIEWICZ et al., 2018). A lencsetorzításnak négy típusát különböztetjük meg: érintőleges (szimmetrikus), radiális (szimmetrikus), aszimmetrikus radiális vagy érintőleges, és véletlenszerű (TZAFESTAS et al., 2014).

Lencsetorzítás paraméterek leírják a kamera geometriai nemlinearitását. Az objektív torzulása miatt a meglévő digitális képfeldolgozási módszerek gyakran nehézségekbe ütköztek.

Számos módszert dolgoztak ki a kamera torzítás paramétereinek kiszámítására. Az első csoport explicit kalibrációt használ olyan objektummal, amelynek koordinátái ismertek (WENG et al., 1992). A második csoport csak egyetlen pont több nézetét használja fel ahelyett, hogy ismernie kellene a pontok valós 3D-s elhelyezkedését (ZHANG et al., 1996; STEIN, 1997). Ezek a módszerek epipoláris és trilineáris kényszereket használnak fel a számítások folyamatában. A harmadik csoport projektív invariánsokat használ, ezek a módszerek nem igényelnek sem kalibrációs objektumot, sem pontmegfelelési számítást, ráadásul ezeknek a módszereknek az az előnyük, hogy nagyon kevés feltételezésre van szükség a valós környezetből.

Síkbeli kalibrációs mintákat gyakran használnak az objektív torzításainak meghatározására, amelyek két pont között biztosítják a

kollinearitást és a 2D metrikus információkat (ZHANG, 1999). Rengeteg síkbeli diagramot használnak a kamera kalibrálásához, úgy mint 2D és 3D kalibrációs pontok. Ezek a minták többféle kialakításúak lehetnek, leggyakrabban köröket (HEIKKILA, 2000), négyzeteket (WENG et al., 1992; ZHANG, 2000) és sakktábla (LUCCHESI és MITRA, 2002) mintát használnak. Ezeket a mintákat általában sík felületen valamilyen nagy kontrasztú minta segítségével hozzák létre. Egy kamerában a kalibrációs minta képe kétféle átalakuláson megy keresztül: egy projektív transzformáció a relatív 3D pozíció következményeként és egy nemlineáris transzformáció a lencse különböző torzításai miatt (9. ábra).



9. ábra – Lencsetorzítási hibák szemléltetése

HANEISHI et al. (1995) kutatásukban a paraméterek becslése a legkisebb sajátérték minimalizálásával történik a rácspontokból nyert mátrixsal. ASARI (1999) a kalibrációs paraméterek kiszámításakor a legkisebb négyzetek módszerét alkalmazta iteratív vonalkeresési megközelítésekkel. BRAND et al. (1993) kalibrációs rácsot használt a lencsetorzítás meghatározásához, amely 2D vektormezőként van ábrázolva. A rácskép minden pontja nemlineárisan van leképezve egy virtuális koordináta rendszerbe tetszőleges pixel koordinátákkal, amely torzításmentes. Ezt a

transzformációt azután az összes pixelre ki kell terjeszteni a képen, helyi bilineáris interpolációs függvények segítségével.

A digitális képkorrelációval (DIC) rendelkező számítógépes látást széles körben alkalmazzák teljes térbeli elmozdulás- és alakváltozás mérésre (ZHAO et al., 2012). A képtorzítás eloszlása a képen nem következetes. Ez azt mutatja, hogy a képtorzítás okozta további mozgások megjelennek a detektálási eredményekben, és ezek a mozgások rontják a valós méréseket (PAN et al., 2013).

A leggyakrabban használt módszerek a parallaxis módszer, a szextáns módszer, a radar módszer stb. (ALTENA et al., 1995), amelyek nagyon összetettek, időigényesek és költségesek.

Tudjuk, hogy egy tárgy látszólagos mérete a megfigyelőtől mért távolságától függ. A képen lévő objektumok méretének mérése hasonló a kamera és az objektum közötti távolság kiszámításához – mindkét esetben meg kell határozni egy arányt, amely az adott mérőszámonkénti pixelek számát méri.

A képen lévő objektum méretének meghatározásához először „kalibrációt” kell végrehajtani egy referenciaobjektum segítségével. A referenciaobjektumunknak két fontos tulajdonsággal kell rendelkeznie:

1. Ismerni kell ennek az objektumnak a méreteit (szélességben vagy magasságban).
2. Könnyen meg kell találni ezt a referenciaobjektumot a képen, akár az objektum elhelyezése alapján (pl.: a referenciaobjektum mindig a kép bal felső sarkában van elhelyezve), akár a megjelenés alapján (pl. jellegzetes szín vagy forma, egyedi és különbözik a képen látható összes többi objektumtól).

Mindkét esetben az objektumnak valamilyen módon egyedileg azonosíthatónak kell lennie.

Számos kutatást végeztek annak érdekében, hogy egy adott tárgy távolságát meg lehessen határozni a képből. Alapvetően a legtöbb javasolt módszer csak egyetlen látásérzékelőt használ. RAHMAN et al. (2009), egy személy-kamera távolságmérő rendszert fejlesztett ki egyetlen kamera felhasználásával, a szemtávolság mérésére alapozva. Ezzel ellentétben WAHAB et al. (2011) monokuláris látást javasolt, amely Hough-transzformációkat használ. Rendszerük a relatív méretétől is függ a céltárgy távolság meghatározásához. Más megközelítést javasoltak egyetlen kamerával KIM et al. (2005). Távolságmérési módszerük kamerára és forgótükörré alapul. A forgó tükör előtti kamera visszaverődő képek sorozatát rögzíti. A távolságmérés azon az elgondoláson alapul, hogy egy nagyobb távolságra lévő tárgypontnak megfelelő pixel nagyobb sebességgel mozog a felvételek sorozatában. HOU et al. (2011) kutatásukban sztereó látást használnak távolság mérésre.

2.5. Paradicsom termés 3D modelljének előállítás 3D scanneléssel

Sok esetben szükséges egy termés pontos geometriai modelljének a kialakítása, pl. élettani folyamatok leírásához úgy, mint hűtési folyamatok (DEGHANNYA et al., 2010), az élelmiszerek konvektív szárítása (KAYA et al., 2006) vagy a hosszú távú tárolása (DELELE et al., 2010) céljából. A legvalóságosabb geometriai 3D modellek a „reverse engineering” technikák felhasználásával alakíthatók ki, amely során az objektum felhasználásával alkotják meg annak 3D-s modelljét. A folyamat során például szeletekről készült fényképek (GOŇI et al., 2007), különböző

szögből készült fényképek (MOUSTAKIDES et al., 2000), röntgen-CT vagy MRI felhasználásával jön létre a 3D modell (DEFRAEYE et al., 2012).

. CHIANG et al. (2023) munkájában egy paradicsom termésbecslő eljárást dolgoztak ki YOLOv5 modell RGB kamera és LiDAR alkalmazásával. Módszerük lényege, hogy egy a paradicsom-bogyók előzetesen átmérőmérése, valamint a neurális hálózat detektációja és az azonosított objektum követés alapján termésbecslés végzése, ahol felhasználják a LiDAR alapú távolságmérés adatait. Az adatgyűjtést egy Jetson Xavier mikroszámítógép végezte el majd azt asztali számítógépen elemezték tovább a paradicsomok felismeréséhez. Munkájukban kizárólag zárt termesztéstechnológiával foglalkoznak, szabadföldi alkalmazásra nem tesznek említést.

RINCON et al. (2022) munkájában egy 3D modellalkotási folyamatot mutat be, ami a környezet leképezését teszi lehetővé. Hardveresen egy egymásbe integrált LiDAR és kamerarendszert alkalmaznak, amely egy Intel Realsense L515 LiDAR kamera. A szerzők által bemutatott módszer a kamera és LiDAR rendszert a növény körül különböző magasságokban, 180°-os szögben fordítja el egy többtengelyes robotkar segítségével, így megalkotva a növény egy oldali 3D képét.

A 3D szkennerek olyan eszközök, amelyek geometriai információkat gyűjthetnek egy valós objektumról vagy a környezetről. Az információk feldolgozása a beolvasott elemek digitális 3D modelljének elkészítése érdekében történik. Az elmúlt években sok alacsony költségű, ambiciózus technológia jelent meg a 3D szkennelési eljárások között (ALLEGRA et al., 2016). Az eredményt egyetlen kamera rögzíti, és az objektum 3D-s információit különböző háromszögelési vagy vetületi geometriákat


használó szoftverek állítják vissza. Ezzel az eljárással nagyon sűrű és pontos pontfelhők nyerhetők (JAVAID et al., 2021b). Fenotipizálást 3D-s információkra alapozva WANG et al. (2022) javasoltak a paradicsomnövényeknél, így 3D pontfelhőket hoztak létre, amivel a szárhossz, a növénymagasság, a csomóközi hossz és a keresztirányú átmérő tekintetében 0,85-nél nagyobb R^2 értékeket generáltak. Ezen túlmenően a paradicsom becsült gyümölcstömege nagyobb volt, mint a pontfelhő adatok alapján, így a módszer alulbecsléssel dolgozott (OHASHI et al., 2020).

A Ciclop szabad forráskódú 3D scanner egymástól függetlenül két pontfelhő adatkészletet generál két infravörös lézer modul segítségével. A BQlabs készítette az Innovációs és Robotikai Tanszéken, Pythonban fejlesztették ki, és GPLv2 licenc alatt adták ki. A szkennel HD kamerával és két 650 nm-es vörös vonallézerrel van ellátva, amely 250 mm átmérőjű és 205 mm magas szkennelési területről 2-8 percen belül képes beolvasni egy tárgyat. A kiválasztott tárgyat egy forgó platformra kell helyezni. Amikor az objektumot egy léptetőmotor elforgatja, a két vonallézer két különböző szögből világítja meg a tárgyat és a kamera minden szöghelyzetben pásztázza az objektumot. A forgóasztalt egy NEMA 17 léptetőmotor hajtja, amely az érintett tárgyat 1,8°-os lépésekkel forgatja a központi tengelye körül. A két vonallézer 5 mW-os és egymással 135°-os szöveget zárnak be, a Logitech C270 webkamerával összehangolva mélységi adatok generálása lehetséges különböző szögekből. A kamera adataiból 3D pontfelhő keletkezik (SUN et al., 2016).

A szkennel a következő összetevőkből áll (10. ábra):

- 3D nyomtatott műanyag alkatrészek;

- összekötő rudak műanyag elemek között;
- nyomtatott áramköri lap (PCB) mikroprocesszoros vezérlőrendszerrel a helyi vezérléshez;
- két 650 nm-es vörös vonallézer;
- HD kamera a beolvasási adatok rögzítéséhez;
- léptetőmotor a forgóplatform mozgatásához;
- PC-alapú szoftveralkalmazás szkenneléshez és kalibrációhoz.



10. ábra – A Ciclops 3D szkennер

A pontos beolvasást követően használva a Poisson felületrekonstrukciós algoritmust (CENTIN et al., 2015) visszaállítható a beolvasott objektum külső felülete nagy pontossággal. A felületrekonstrukciós folyamat során a normálvektorok segítségével a pontfelhő adatait újraszámítással előkezeljük a legkisebb négyzetek módszerén alapuló módszerrel. A keletkezett felületen található folytonossági hibák javítására, amelyeket az algoritmus könnyen létrehozhat, egy iteratív utófeldolgozással egy negyedrendű parciális differenciálegyenleten alapuló módszerrel a lyukak száma csökkenthető. A

felszínrekonstrukció területén ZHANG et al. (2021) új megközelítést javasolt amely egyidejűleg képes zajtalanítani és paraméterezni a rendezetlen pontfelhő-adatoka. HUANG et al. (2013) egy 3D rekonstrukciós rendszert épített ki, amely gyors 3D-s modellezést végez egy Kinect szenzor segítségével és képes nyomon követi egy objektum pozícióját ICP algoritmus segítségével.

3. ANYAG ÉS MÓDSZER

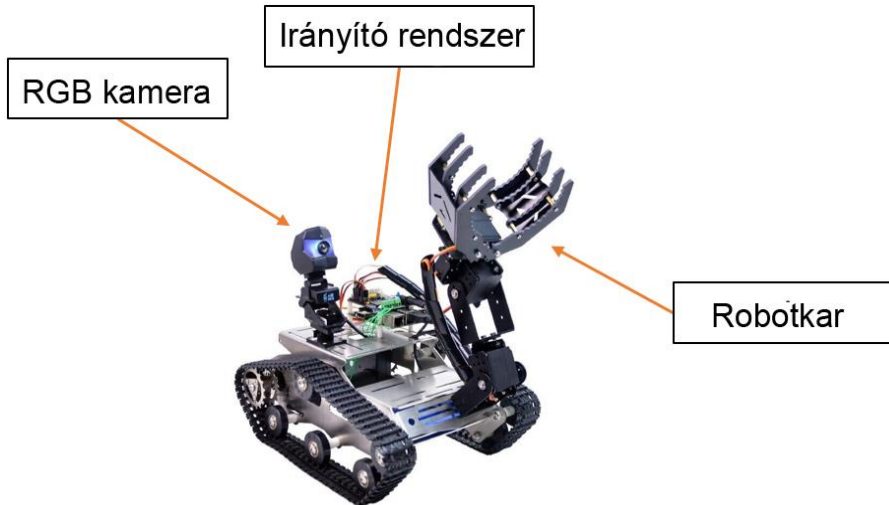
„Ha meg tudsz mérni valamit, és számokkal ki tudod fejezni, akkor tudsz csak igazán róla valamit”

– Lord Kelvin

3.1. Alap robotrendszer bemutatása

Az eredeti robotrendszer a XiaoR Geek TH Robot Car Kit (tervezője: Shenzhen XiaoR Geek Technology Co., Ltd.) típusú szabad forráskódú robot platform volt (11. ábra), amely nyílt interfészekkel rendelkezik. Ez a rendszer alacsony költséggel és kiterjedt dokumentációval rendelkezett, amely segítséget nyújtott a módosításokhoz az eredeti rendszerhez képest. A berendezés kompakt, moduláris felépítésű, mind hardveresen, mind szoftveresen. Három részre osztható, így a tápegységet, a vezérlőrendszert és a beavatkozási eszközöket tartalmazó részre. A járószerkezet gumihevederrel van kialakítva a talajhoz való megfelelő tapadás érdekében, és ennek a kialakításnak köszönhetően a robot irányítása is könnyen megvalósítható. Két egyenáramú hajtóműves motor (DC) hajtja. A központi egység egy Raspberry Pi 4 mikroszámítógép. A robot négy szabadságfokkal rendelkező (4-DOF) robotkarral van felszerelve, amely szervomotorokkal mozgatható két egymásra merőleges irányba. Fel van szerelve egy RGB kamerával is, amely két tengely mentén szervomotorokkal pozícionálható. A robot vezérlőszoftvere Python programozási nyelven íródott. Lehetővé teszi a felhasználó számára a gép teljes irányítását és optimalizálását. Lehetőség van vezetékes

(LAN) és vezeték nélküli (Wifi, Bluetooth) kapcsolaton keresztül is működtetni a készüléket.



11. ábra – Az eredeti robotplatform kinézete és főbb részei


3.2. Robotfejlesztés (A gép és a vezérlőrendszer újratervezése)

Az eredeti robotrendszert a kutatási céloknak megfelelően nagyfokú módosításoknak vetettük alá hardveresen és szoftveresen is.

3.2.1. Vázszerkezet, meghajtás


A vázszerkezeti elemek kibővítésre kerültek a nagyobb szerkezeti stabilitás és a terepi munkavégzés végett. A robot fémváz szerkezete $300 \times 230 \times 233$ mm méretű. A szerkezetnek az alacsony hasmagassága miatt nem alkalmas közvetlen terepi használatra, ezért a magasság növelésére volt szükség. A fémvázszerkezet eredeti rögzítési pontjai alapján egy 1 mm vastag rozsdamentes lemez került kialakításra, amely ezt a feladatot látja el. Erre a lemezre kerültek a járószerkezet

alkotóelemei. A vázszerkezet kialakításának köszönhetően a robot magassága könnyen állítható az adott termény magasságához 150 és 250 mm között (12. ábra).



12. ábra – Módosított vázszerkezet 3D terve

Az előzetes terepi mérések alapján az eredeti meghajtó rendszer motorjai nem nyújtottak elegendő teljesítményt a terepi viszonyok közötti munkavégzéshez. Így nagyobb teljesítményű GW31ZY típusú hajtóműves, csigakerekes tartó nyomatékmotorok lettek beépítve (13. ábra). A motorok az eredeti járászerkezet megtartása mellett a kibővített oldalsó szerkezeti elemeken kaptak helyet. Ezeknek a motoroknak a fordulatszámja szabályozható és nagy nyomatékuknak köszönhetően alkalmasak a szántóföldön belüli mozgásra. A nagyobb teljesítményű motorok működtetése érdekében az eredeti H-hidas motorvezérlő áramkört egy hasonló felépítésű motorvezérlő áramkörre cseréltük, amely L298N típusú, és a jobb hűtés érdekében külön áramköri lapon helyezkedik el a robot hátsó részén egy furatokkal ellátott dobozban.



Névleges feszültség (V)	Névleges fordulatszám (Rpm)	Névleges forgatónyomaték (N×cm)	Névleges áramfelvétel (A)
DC 12	50	75	1.5

13. ábra – A hajtómotorok geometriai és elektromos tulajdonságai (URL⁵)

3.2.2. Tápellátás

Az áramellátást Li-Ion akkumulátorcsomag biztosítja egy akkumulátor felügyeleti rendszeren (BMS 3S 40A) keresztül. Kilenc akkumulátor (típus: 18650) csatlakozik egymáshoz 3S-3P kapcsolásban, mindegyik 3,6 V feszültséggel és 3500 mAh teljesítménnyel. Az akkumulátor körülbelül 12 V DC feszültséget tud leadni. A többi alacsonyabb feszültséget igénylő rendszert a megfelelő tápfeszültséggel (5 V és 3,3 V) LM2596 típusú DC-DC konverterek látják el.

3.2.3. *Mikroszámítógép és programozás*

A központi vezérlő kiválasztásánál fő szempont volt az elegendő nagyságú teljesítmény mellett az is, hogy megfelelő kompatibilitással rendelkezzen a másodlagos rendszerekkel (pl.: szenzorok). A Raspberry PI mikroszámítógép elegendő teljesítménnyel rendelkezik a megfelelő idejű és szintű adatfeldolgozáshoz még a jóval nagyobb teljesítményű Tinkerboard és Jetson fejlesztőplatformokhoz képest is. A készülék központi egységéhez eredetileg egy speciálisan ehhez a robothoz fejlesztett "Shield" panellel egészült ki, amely tartalmazza a többi elektronikai alkatrészt és a csatlakozókat. A robot módosítása után ez a nyomtatott áramköri lap nem került felhasználásra.

A robotot és az egyes alrendszereket irányító programok Python programozási nyelven íródtak. Az egyes input-output portok a szabványos Raspberry PI programozási könyvtár segítségével programozhatók. A robotra telepítésre került egy mesterséges intelligencia modul, amely az RGB kamera képeit képes osztályozni. Ez a módszer az Edges Impulse platformon keresztül létrehozott neurális hálózati modellt használja a TensorFlow szoftverkönyvtár felhasználásával.

3.2.4. *Távvezérlő rendszer*





Eredetileg vezetékes (LAN) és vezeték nélküli (Wifi, Bluetooth) kapcsolat is elérhető a robotplatformon. Terepi körülmények között optimális a vezeték nélküli vezérlés, ami TCP/IP kapcsolaton keresztül valósul meg, az adatátvitel Hex Stringeken keresztül történik. A robotot

egy saját fejlesztésű alkalmazás irányítja számítógépen, okostelefonon vagy táblagépen keresztül. Ezzel az alkalmazással a robot minden funkciója irányítható nem csak a robot mozgása irányítható, hanem a szervomotor karja is mozgatható, valamint az adatgyűjtő, feldolgozó és átviteli rendszer is működtethető.

3.2.5. Telepített érzékelők


A robot számos szenzorral van felszerelve, kiválasztásuk során azokat a paramétereket vettük figyelembe, amelyek a szántóföldi körülmények közötti legfontosabb információkat hordozzák. A következő adatokat gyűjti a környezetből: globális sugárzás, környezeti hőmérséklet és páratartalom. A talaj tulajdonságai közül: talajfelszíni infravörös-hőmérő, talajhőmérséklet, talajnedvességtartalom, EC, pH, NPK tartalom (3. táblázat).

3. táblázat – Telepített érzékelők és tulajdonságaik

Típus Referencia	Mérési paraméterek	Mérési tartomány	Kép	
MLX90614 URL ⁶	Hőmérsékletmérési tartomány	-40...+125 °C		
	Pontosság	max ±0,5 °C (Szélsőséges esetekben)		
BME280 URL ⁷	Hőmérsékletmérési tartomány	-40 ... +80 °C		
	Páratartalom mérési tartomány	0 ... 100 %		
	Nyomásmérési tartomány	300...1100 hPa		
	Pontosság	0,1 °C; 0,1 RH%, 0,0013 hPa		
BH1750 URL ⁸	Fénymérési tartomány	1...65535 lux		
	Pontosság	±4 lux		
7 az 1-ben Talajszonda URL ⁹	EC	Tartomány	0- 20000 µS/cm	
		Érzékenység	1 µS/cm	
	Talajnedvesség	Tartomány	0-100%	
		Érzékenység	±0,1%	
	Talaj hőmérséklet	Tartomány	- 40...+80 °C	
		Érzékenység	±0,1 °C	
	A talaj pH-ja	Tartomány	pH: 3...9	
		Érzékenység	±0,1	
	NPK	Tartomány	1-1999 mg/kg (mg/l)	
		Érzékenység	1 mg/kg (mg/l)	

A 14. ábra és annak számozott részei a robot kapcsolási rajzát és annak részeit mutatja. Az -1- rész tartalmazza az energiaellátó eszközöket. A BMS 4S 40A típusú továbbfejlesztett akkumulátorvédelmi rendszer, ami az akkumulátor töltéséért és védelméért felel, amely így 12 V egyenfeszültséget termelnek, melyet egy 220 μF 16 V-os elektrolit kondenzátor bufferol és szűr. A többi alacsonyabb feszültség előállításához 3 db LM2596S DC-DC átalakítót használtunk (-2-), amelyek 5 V és 3,3 V (plusz 3 db 100 nF kerámia kondenzátor szűrés végett) feszültséget hoznak létre az RPi tápfeszültségének ellátásához valamint a szervomotorok és érzékelők táplálására. Az egyes alrendszerek tápellátása közvetlenül ezekről az átalakítókról történik. Az alrendszerek különböző kommunikációs portokon, buszrendszeren keresztül csatlakoznak a központi egységhez, annak saját GPIO (General Purpose Target Input and Output) portjain keresztül. A LiDAR (-3-), GPS/GNSS (-4-), RGB kamera (-5-), GSM modul (-6-) és talajszonda (-7-) soros porton keresztül kommunikál, az első három RS232 szabványt az utolsó RS485 szabványt használ Modbus-RTU kommunikációs protokollon keresztül. A környezeti paraméterek figyelésére szolgáló érzékelők a következők: hőmérséklet, relatív páratartalom, légnyomás (-8-), globál sugárzás (-9-), és felületi hőmérséklet (-10-). Ezek az érzékelőt I²C kommunikációs protokolon keresztül működnek. Az RPi szervomotorjai (-11-) és ultrahangos érzékelői (-12-) közvetlenül a hozzájuk rendelt GPIO-hoz csatlakoznak. Egy L298n típusú H-híd motorvezérlő áramkört (-13-) használtunk a robot mozgatásáért felelős egyenáramú motorok (-14-) vezérlésére, amelyek szintén közvetlenül kapcsolódnak az RPi GPIO-ihoz. Egy piezo hangszóró (-15-) segítségével a robot visszajelzést tud adni az

adott folyamatokról a kezelőnek. A szervomotor alapú kar végeffektorjához egy relé vezérlésű szivattyú is kapcsolódik (-16-) amely a berendezés működését segíti elő.



14. ábra – A robot kapcsolási rajza és részei (Forrás: Fritzing program által generált saját diagram)

A talajszonda elektródája közvetlenül méri a talajban lévő oldható sóionok vezetőképességét. A talaj térfogati víztartalmának körülbelül 20%-nál magasabbnak kell lennie, ennek a feltételnek a teljesülése esetén a talajban lévő oldható ionok pontosan tükrözik a talaj vezetőképességét. A hosszú távú megfigyelésnél az öntözés vagy csapadék után mért érték közelebb áll a valós szinthez.

A berendezés autonóm mozgása céljából LiDAR (RPLIDAR A1) és GPS/GNSS (VK-162 G-Mouse) érzékelővel rendelkezik (15. ábra), amelyekkel autonóm módon képes mozogni a természetett növények sorai között. A beépített DFRobot Unbox chip alapú vevő nem vesz részt a robot irányításában, hanem eltárolja a robot pozícióját, ami aztán grafikusán megjeleníthető. A GPS/GNSS-vevő nem rendelkezik valós idejű korrekcióval (RTK), így a pontossága legfeljebb 3 m.



15. ábra – RPLIDAR A1 típusú Lidar érzékelő

Előzetes laboratóriumi méréseket végeztünk a kialakított irányítórendszer pontosságának megállapításához. Ennek során különböző meghatározott távolságokat állítottunk be a robot számára kitüntetett szereppel rendelkező irányokban úgy, mint közvetlenül előtte, jobbra, és balra. A vizsgálat során 20 cm, 30 cm, 40 cm, 50 cm távolságok mellett megvizsgáltuk a kialakított irányítórendszer pontosságát a robot mozgása közben a távolságtartás vonatkozásában. A méréseket először külön jobb és bal oldalt végeztük el, a robotot sík felület (fal) mellett végigvezetve, majd folytatva a vizsgálatot két oldalt sík felület (folyosó) mentén is megvizsgáltuk a robot mozgását. Ezek után a vizsgálatot megismételtük a úgy, hogy több a terepi

körülményeket (levélzet, ágak benyúlását) szimuláló műanyag növényt helyeztünk a sík felületek mellé.

3.3. Kísérleti helyszínek bemutatása

A robottal végzett kísérleti méréseket két különböző helyszínen végeztük el. Az egyik helyszínen szabadföldi termesztési rendszerben, a másik helyszínen zárt termesztő rendszerben (növényházban) végeztük el vizsgálatainkat. Mindkét helyszínen paradicsom hibrid kultúra volt telepítve.

3.3.1. Szabadföldi kísérlet

A kísérleti parcella a Magyar Agrár- és Élettudományi Egyetem (GPS: 47°34'51.6"N 19°22'39.0"E) kertészeti kísérleti telepén volt, Gödöllőn (16. ábra).



16. ábra – A szántóföldi kísérleti hely

A talajt agyagos textúra jellemzi, 47,5% iszap, 41% homok és 11,5% agyag. A kísérletben vizsgált paradicsom hibrid H1015

(Pomodoro AGRO Kft., Mezőberény, Magyarország) típusú volt. Ez egy determináns növekedésű hibrid, korai érettséggel, tömbös termőalakú, 70 g körüli gyümölcstömegű. A sortávolság 140 cm, a tőtávolság 20 cm volt, így a növényesűrűség 3,57 tő/m², az egyes sorok hossza 24 m volt. A palánták átültetése 2002. május 10-én történt. A trágyázás a kezelésekben (T0 kivételével) egyenletesen oszlott el a paradicsomnövények fenológiai fázisa tekintetében granulált formában, azaz 159, 70, 137 kg/ha, N, P₂O₅ és K₂O a teljes tenyészidőszakra. A vízellátást csepegtető öntözőrendszerrel biztosítottuk. A kísérlet 5 kezelésből áll, nevezetesen T0, T1, T2, T3, T4, két ismétlésben. Minden kezeléshez 2 mintahely tartozik (T0-1, T0-2, T0-3, T0-4). Az adatgyűjtést összesen 20 mintahelyet jelent, ami kezelésként 4 ismétlés.

Az összes kezelést egyenletesen 10 mm-es öntözésben részesítettük közvetlenül az átültetés után, majd ismét ugyanennyit 6 nap után. A T4 kezelésben a növények 100%-ban kapták meg az öntözővizet, a T3-as kezelést a T4-hez képest csak 75%-ban, a T2-ben pedig 50%-ban a T4-hez képest. A T1 a nem öntözött kontroll (csak az átültetés utáni időszakban volt öntözött, összesen 20 mm). A különböző mennyiségű vizet különböző típusú csepegtető szalagokkal juttattuk ki. A csepegtetővonalak elhelyezkedése nem különbözött az egyes kezeléseknél, az összes vonalat minden paradicsomsor azonos oldalára helyeztük. A T0-s kezelés ugyanannyi öntözést kapott, mint a T4, de csak az alpműtrágyát alkalmaztuk (24, 45, 45 kg NPK). Az öntözési kezelés június 14-én kezdődött, az utolsó öntözés augusztus 8-án történt. A 2022-es tenyészidőszakban a csapadék nem volt jelentős,

mindössze 119 mm volt. A kumulált vízkészlet 472, 472, 390, 306 és 139 mm volt a T0, T1, T2, T3 és T4 kezeléseknél.

3.3.2. Növényházas kísérlet

A kísérleti parcella a Dunakiliti község (GPS: É 47°58' 00,95, E 17°17' 42,86) belterületen volt, a Ranyák kertészet tulajdonában lévő zárt termesztő rendszerű üzemben (17. ábra).



17. ábra – A növényházas kísérleti helyszín

A talajt a Szigetközre jellemző öntéstalaj jellemzi. A kísérletben vizsgált paradicsom hibrid K3 F1 (RÉDEI KERTIMAG - Vetőmagkereskedelmi Zrt., Réde, Magyarország) típusú volt. Determinált növekedésű, igen korai érésű hibrid. Egy időben érő bogyói közép nagyok, kemények, megnyúlt gömb alakúak, 2-3 rekeszűek, tömegük 70-80 g.

A sortávolság 120 cm, a tőtávolság 30 cm, így a növénytűrség 2,77 tő/m², az egyes sorok hossza 30 m volt. A növényeket kordonrendszer

mellett futtatásos technológiában természetették. A vízellátást csepegtető öntözőrendszerrel biztosítottuk. A kísérletben nem voltak külön kezelések kialakítva. Az adatgyűjtést összesen 27 mintahelyről végeztük, 1-től 27-ig számozva, ami összesen 27 tövet jelentett. A vízellátást csepegtető öntözőrendszerrel biztosítottuk. A kísérleti helyszínre a növényház környezeti adatainak mérésére egy Libelium Smart Agriculture Xtreme típusú mérő és adatgyűjtő állomás lett telepítve, amely 15 percenként szolgáltatott adatokat (hőmérséklet, relatív páratartalom, légnyomás) a területről. Az állomás működését 2022. 05. 18-án kezdte meg meg és 2022. 09. 26-án fejezte be.

3.4. Adatgyűjtés és a feldolgozás módszerei

A képi adatgyűjtés két platform alkalmazásával történt. A robot RGB kamerája mellett egy digitális tükörreflexes (DSLR) fényképezőgépet is alkalmaztunk elsősorban az adatok validációja miatt.

3.4.1. Képi-adatgyűjtés RGB DSLR kamerával

A képek egy 12,2 Megapixeles 22,2×14.8 mm szenzorméretű Canon EOS 1100D fényképezőgéppel készültek, Canon EF-S 18-55mm, f/3.5-5.6 objektívvel, RGB (piros, zöld és kék) színtartományban 4272×2848 pixeles felbontásban, 24 bites színmélység mellett készültek.

Szabadszíri kísérletben a fényképek a fényképezőgép teljes manuális módjában történt ISO800 érzékenység, 1/400 s záridő és 18 mm fúkosztávolság mellett 100 cm-es távolságra a paradicsomnövények felett fényképezőgép állvány felhasználásával.

Az adatelemzéshez minden egyes mintavételi helyen 5 RGB-képből álló adatkészletet használtunk fel panorámaképpé összefűzve, így képet adva a teljes mintavételi helyszínről (18. ábra).



18. ábra – Szabadföldi kísérlet DSLR panoráma képe a T2-es kezelésről

Növényházas kísérletben a képeket oldalnézetben a növénsoroktól 100 cm távolságban fényképezőgép állvány segítségével készítettünk, a szabadföldi kísérletnél alkalmazott fényképezőgép beállítások mellett. A felvételek készítésénél a további növényi sorok elszeparálása miatt egy fehér színű paravánt alkalmaztunk (19. ábra).



19. ábra –Növényházas kísérlet DSLR képe a 24-es mintanövényről

A feldolgozásnál mivel minden mintavételi helyről (minden növényről) csak egy kép készült nem volt szükséges a panorámaképekké való egyesítés, viszont a képeket a megfelelő méretűvé vágtuk a szomszédos növények részeinek eltávolítása végett. Az elemzés során mindkét kísérletnél csak színek szerinti szegmentálást alkalmaztunk.

3.4.2. Képi-adatgyűjtés a saját fejlesztésű robottal

A képi adatgyűjtés a robotba integrált 1,3 Megapixeles 3,00×4,32 mm szenzorméretű kamera segítségével történt meg. A kamera fix fókuszú objektívvel 640×480 pixeles felbontással, ISO800 érzékenységgel és RGB 16 bites színmélységgel rendelkezik.

A szabadföldi és növényházas kísérlet esetében is a robot egy irányból készítette a felvételeket a növényi soroktól számított előre meghatározott távolságok mellett, amely 40 cm volt.

Szabadföldi kísérletben egy menetben történt a felvételezés, az elkészült képeket úgyszintén panorámaképekké egyesítettük (20. ábra).



20. ábra – Szabadföldi kísérlet robot általi panorámaképe a T2-es kezelésről

Növényházas kísérlet esetében, mivel a növények magassága és a kamera látómezője nem tette lehetővé a teljes növény egy képen való megjelenését ezért a felvételezése két menetben történt meg 0° (21/a. ábra) és 45° (21/b. ábra) kamera állásban.

**a****b**

21. ábra – Növényházas kísérlet robot általi képei a 24-es mintanövényről

A távolság tartását autonóm módon a beépített LiDAR távolságmérése alapján valósítottuk meg. A távolság adatok a későbbi képi feldolgozás végett .csv formátumban elmentésre kerültek.

3.4.3. Képfeldolgozási módszerek

A képi információk feldolgozását két irányba különítettük el. Egyrészt egy objektumfelismerési eljárással mestereséges intelligencia (CNN) segítségével a paradicsom termést osztályoztuk, másrészt utófeldolgozással szegmentálást alkalmaztunk a paradicsomtermés mennyiségi és tömegbecslése érdekében.

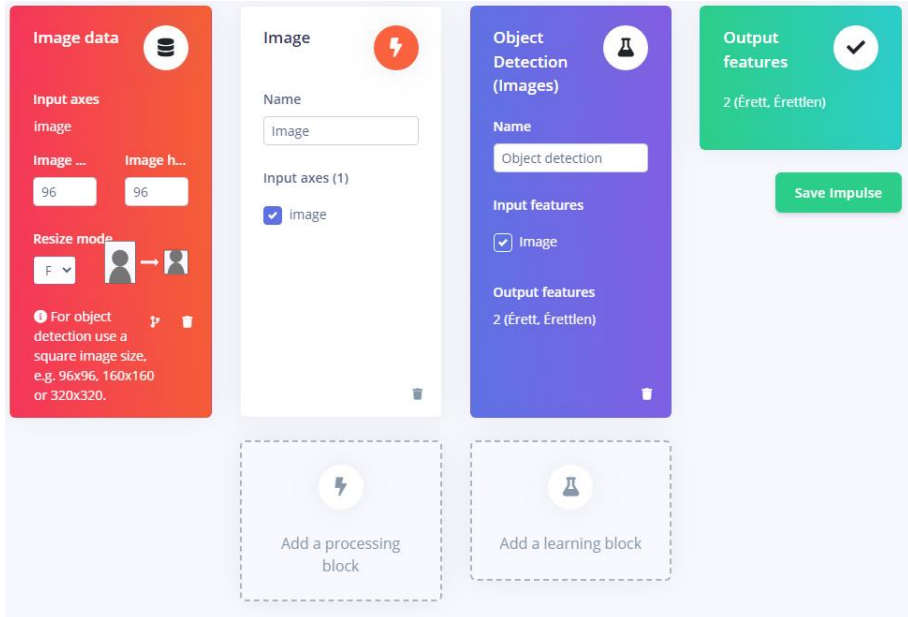
A termékek osztályozásához az Edge Impulse (URL¹⁰) fejlesztői platformot felhasználva betanítottunk, optimalizáltunk egy objektumfelismerő modellt előzetesen felvételezett képeket felhasználva. A Tensorflow nyílt forráskódú könyvtárat (URL¹¹) alkalmaztuk a képeken megtalálható paradicsom termékek osztályozásához. Első lépésként kialakítottunk egy reprezentatív

adatkészletet az objektumok gépi tanulással történő azonosításához. A felvételezés több alkalmmal történt a növényházban végzett kísérleti helyszínen (2022. május 20. és július 15. között) a reprezentatív adatkészlet létrehozásához a paradicsom termés érésének folyamatához igazodva. Összesen 924 kép felhasználásával kialakítottunk két különböző osztályt; érett (piros) és éretlen (zöld) csoportokat (22. ábra).



22. ábra – A CNN betanítása során kialakított két osztály grafikus kijelölése

A FOMO (Faster Objects, More Objects) MobileNetV2 0.35 egy MobileNetV2-n alapuló objektumészlelési modellt (alpha 0.35) használtunk a betanítási és osztályozási folyamathoz. Az Edge Impulse automatikusan generálja az eredeti modellt (float32) és az tiny modellt (int8). A fotók 80%-át a MobileNetV2 architektúra betanítására használtuk, a fotók másik 20%-át a betanítás utáni validálásra használtuk fel (23. ábra).



23. ábra – A képklasszifikáló CNN beállításai

A tréning során futó program eredeti beállításai mellett a modell paramétereit a következőképpen állítottuk be: ciklusok száma 60, learning rate 0,001 (1. melléklet). A tréningezés folyamatát az 24. ábra mutatja be.

Training output Cancel 🔊 (0) ▲

Epoch	Train Loss	Validation Loss	Precision	Recall	F1
56	0.06815	0.08190	1.00	0.59	0.74
57	0.06564	0.08804	1.00	0.60	0.75
58	0.07479	0.05437	1.00	0.63	0.78
59	0.07073	0.03580	1.00	0.70	0.82

Finished training

24. ábra – A CNN tréning folyamata

Az Edge Impulse rendszer nem működött közvetlenül online a robottal, hanem egy önálló alkalmazást futtatott, kihagyva a vezeték nélküli adatkapcsolatot. A számítási kapacitás miatt a képkockasebesség maximum 5 FPS volt, ami a robot alacsony sebessége mellett elegendőnek bizonyult.

A képfeldolgozás másik módszerül egy gépi látást megvalósító OpenCV függvénykönytárat alkalmazó utófeldolgozási módszert használtunk, amely a színek szerinti szétválasztással, távolságadatok és a paradicsom termés előzetes paramétereinek felhasználásával állapítja meg a termésszámot és a hozammennyiségét.

Ezen elemzés során bemenő paraméterként nemcsak a robot, illetve a kézi kamera felvételét használtuk fel, hanem a fényképek mért távolságát az objektívtól, a vizsgált paradicsom termésekre meghatározott sűrűségeket, valamint a termés térfogatának két módszerrel történő közelítését is. A felvételek készítésekor figyelembe

vettük az uralkodó fényviszonyokat is a megfelelő minőségű kijelölés végett. 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, egymásralapolódása miatt gyakran nem különültek el, ezért a „Watershed” algoritmust 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 (2. melléklet).

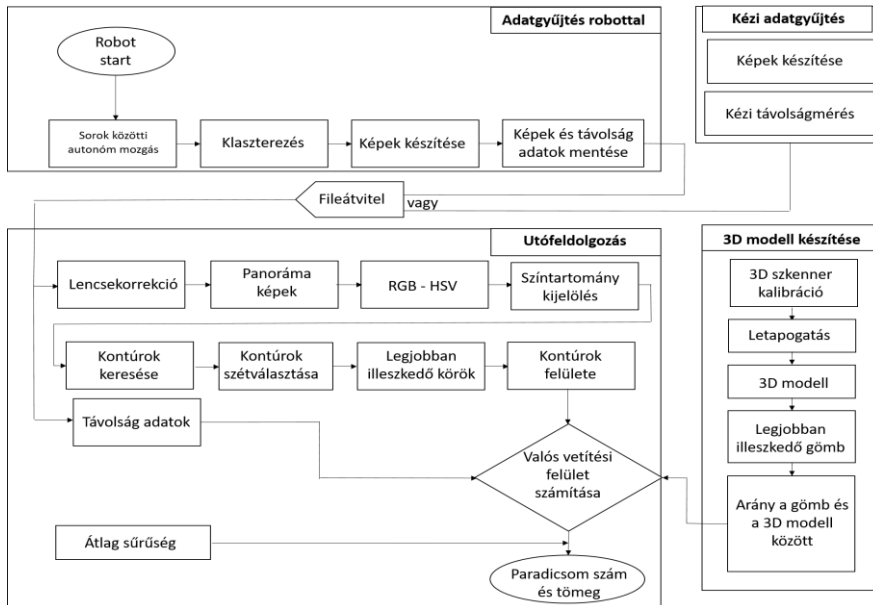
A felvételen lévő paradicsom termésekre illesztett körök sugarát felhasználva kiszámítható minden egyes körnek a pixelben számított nagyságú felülete. A felvétel és az objektív távolság adatainak felhasználásával a kamerára jellemző távolság/pixel metrika megadásával az egyes körök valós felülete is megadható cm^2 dimenzióban, ami a paradicsombogyók az adott távolságra lévő felületre projektált vetületét jelenti. Ezt felhasználva a termések térfogata is megadható. A térfogat megadásakor két módszert is alkalmaztunk; gömbbel és a termés 3D modelljével való közelítést. Gömbbel való közelítéskor a számított felületnagyságokat az 5–7. egyenlet alapján határoztuk meg.

$$V_{sphere} = \frac{4}{3}\pi r^3 \quad (5.)$$

$$A_{spherical\ projection} = \pi r^2 \rightarrow r = \sqrt{\frac{A_{spherical\ projection}}{\pi}} \quad (6.)$$

$$V_{sphere} = \frac{4}{3}\pi \left(\frac{A_{spherical\ projection}}{\pi}\right)^{\frac{3}{2}} = \frac{4A_{spherical\ projection}^{\frac{3}{2}}}{3\sqrt{\pi}} \quad (7.)$$

Pontosabb súlyozás érhető el a 3D modell esetében, amikor figyelembe vettük az előbbi gömb térfogata és a 3D modell térfogata közötti arányosságot. Az érett paradicsombogyók tömege a paradicsom fajtákra jellemző átlagos sűrűség bevezetésével számítható ki. A 25. ábra a képelemzési módszerek lépéseit mutatja.



25. ábra – A képelemzési módszer átfogó folyamatábrája

3.4.4. Regresszió elemzés

Regresszió számítást alkalmaztunk az összefüggés megállapításához a kézi mérésekkel és a két becslési módszerrel meghatározott tömeg és termésszám adatok között. Ezek mellett a szabadföldi kísérlet esetében ugyan ezzel az eljárással megvizsgáltuk az érett paradicsombogyó tömegek és a kijutatott öntözővíz kapcsolatát is.

A regresszió elemzést a válaszváltozó és a magyarázó változó közötti kapcsolat elemzésére és meghatározására használják. A lineáris regresszió (LR) a független változó (öntözési mennyiség) és a becsült termés, mint függő változó közötti kapcsolat megállapítására szolgál. A lineáris regressziót olyan technikának tekintik, amelyet egy Y válaszváltozó elemzésére használnak, amely a β érték ismeretében az X beavatkozási változó értékével változik. SPSS-t használtunk az R^2 és a korrigált R^2 , valamint a β (Unstandardized, Standardized) értékek kiszámításához.


3.5. Képfeldolgozáshoz szükséges korrekciós módszerek

3.5.1. Lencsekorrekció

A digitális képfeldolgozási módszerek általában alacsony észlelési pontosságot mutattak az objektív torzulása miatt (SUN et al., 2015). A pontosabb eredmények érdekében kalibrációs eljárásokat alkalmaztunk ezen torzulások kiküszöbölésére. Lineáris kalibrálást végeztünk kalibrációs mintával az Adobe Lens Profile Creator 1.0.4 (URL¹²) szoftver segítségével.

A DSLR fényképezőgép esetében az objektív torzítása ismert volt, ezért ebben az esetben nem készült kalibráció, a már létező kalibrációs modellt alkalmaztuk.

A robot esetében az eddig ismeretlen lencsetorzítás kiküszöbölésére végeztünk méréseket. A kalibráció során egy sakktábla mintájú kalibrációs panelt alkalmaztunk, amely 91 db 10 mm oldalhosszúságú fehér és fekete négyzetekből áll soronként 7 és oszloponként 13-as elrendezésben (26. ábra).



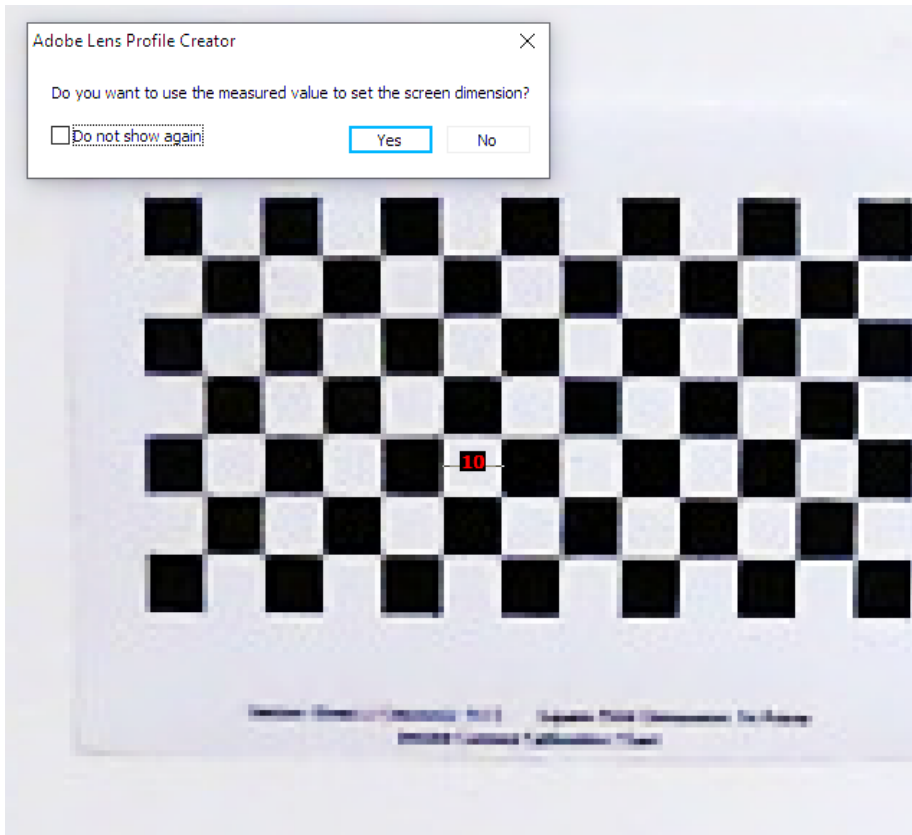
Version (Rows x Columns): 7x13 Square Print Dimension: 54 Points
Adobe Camera Calibration Chart

26. ábra – Az alkalmazott sakktábla mintájú kalibrációs tábla

A kalibrációs táblát a minta torzulásának kiküszöbölése érdekében sík felületre rögzítettük amit egy üveglap biztosított. Majd az optimális megvilágítás végett ezt a táblát két irányból is 45 °-os szögben 60 W-os lámpákkal megvilágítottuk.

A kalibrációs panelről a robot kamerája különböző tetszőlegesen megválasztott távolságokból és szögekből készített fényképeket. A kalibrációs táblán lévő sorok és oszlopok számán és a rajta lévő négyzetek méretén túlmenően a programnak ismernie kell a sakktábla rögzített méretét is. Ennek meghatározásához a mérés eszközt

segítségével ki kell jelölne egy négyzet tetszőleges oldalát és megadni a valós méretét, ami az általunk alkalmazott táblán 10 mm volt. A kiválasztott négyzet tetszőlegesen lehet fehér vagy fekete, a kijelölést bármelyik képen végre lehet hajtani. A kijelölés méretének legalább 20 pixelnek kell lennie, de a 30 képpont feletti kedvezőbb, mert kevesebb hibához vezet. A pixelméret túl nagy értéke kedvezőtlen, mert a lencseprofilozó algoritmusnak meglehetősen sűrű sakktábla-mintára van szüksége a pontos profilok előállításához. A mérés során ez az érték 24 pixel volt (27. ábra).



27. ábra – A sakktáblaminta méreteinek meghatározása a lencsekalibrációs programban

3.5.2. Távolságkalibráció

A képeken a paradicsomok (objektumok) egy adott távolságra történő vetületi területének meghatározásához, egy kalibrációs eljárást végeztünk egy referencia objektum segítségével. A referenciaobjektumnak két fontos tulajdonsággal kell rendelkeznie: az objektum méreteinek (szélesség vagy magasság) ismerete mérhető egységben (például milliméterben, hüvelykben stb.); valamint ezt a referenciaobjektumot könnyen meg kell találni a képeken, akár az objektum elhelyezése alapján (például a referenciaobjektum mindig a kép bal felső sarkában van elhelyezve), akár megjelenés alapján (például megkülönböztető szín, vagy forma, egyedi és különbözik a képen látható többi objektumtól). Összességében az objektumnak egyedileg azonosíthatónak kell lennie.

A kalibráló mérés során mindkét adatgyűjtő platform felhasználásával készítettünk felvételeket egy általunk megválasztott referencia objektumról, amely egy ismert felületű piros kör volt. Célunk a referencia objektum valós felületének (cm^2) és a felvételeken meghatározott felület ($db\ pix$) közötti kapcsolat meghatározása. A referencia objektum egy fehér háttérre nyomtatott piros színű körlap volt. A felvételeket a kamerák azonos beállítása mellett ISO800, 1/400 s értékekkel készítettük el 20 és 200 cm -es távolságok között 10 cm -es lépésekben

3.5.3. Szín és fénykorrekció

A képszegmentációs eljárások legfontosabb jellemzője a megfelelő értékű színtér adatok meghatározása a pontos kijelölés kialakítása miatt. A vizsgálat során HSV értékeket alkalmaztunk. Az értékek meghatározásához a paradicsom termésről különböző megvilágítási viszonyok mellett készült képeket használtuk fel a képek külön csatornáit ábrázoló hisztogramok felhasználásával. A hisztogramokból kinyertük a kép jellemző színeit és ezen színek HSV értékeit használtuk fel az szegmentációs intervallumok meghatározásához. Ezen adatok segítségével meghatározható az optimális színintervallum és a megvilágítás határértékei is, amelynél a legjobb színek szerinti szegmentáció valósítható meg.


A vizsgálat során 15 azonos beállítású képet készítettünk a növényházas kísérletről begyűjtött 4 db érett paradicsom mintáról. A képek készítésekor a Canon EOS 1100d típusú DSLR fényképezőgépet alkalmaztuk, minden kép készítésekor ugyanolyan beállítás mellett; 4272×2848 pixeles felbontás, ISO 800 érzékenység, 1/1000 s záridő, f/4,6 apertúraérték és 32 mm fokális hossz mellett. A felvételek fehér háttér előtt és fokozatmentesen szabályozható mesterséges megvilágítás mellett készültek, egy 1000 W teljesítményű stúdiólámpa segítségével. A stúdiólámpa fényforrásának köszönhetően a kibocsájtott fény folytonos spektrumú eloszlás jellemzi, úgymint a napfény eloszlását. A szabályozásról egy toroid transzformátor gondoskodott. Az elkészült képekhez 15 féle megvilágítási érték tartozott, amelynek megméréséhez a robotnál is alkalmazott BH1750 típusú fényerősségmérő szenzort alkalmaztunk egy Arduino nano platform működtetésével (3. melléklet).

3.6. Paradicsom termés 3D modellezésének módszere

A paradicsom termés 3D-s modelljének megalkotásához egy utánépített szabad forráskódú Ciclop 3D lézer scannert (URL¹³) használtunk fel. A Ciclop által generált pontfelhőket a Horus szoftver (URL¹⁴) dolgozza fel. Grafikus felhasználói felülettel rendelkezik, amely a szkennelhez való csatlakozásra, konfigurálására, vezérlésére, kalibrálására és szkennelésére szolgál. A berendezés működtetéséhez előzetes kalibrációk szükségesek, ami egy sakktábla mintájú kalibrációs panel alkalmazásával történik meg.

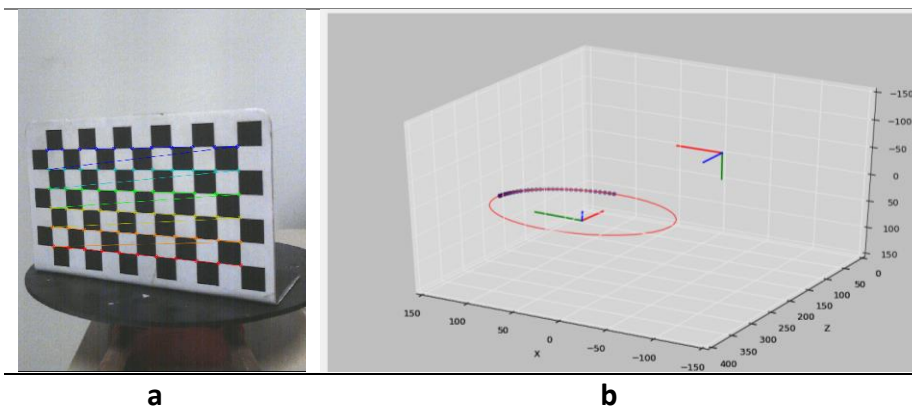
Elsőként az automatikus kalibrációs asszisztens futtatása, amint a program elindul. Ebben az esetben a felhasználónak csak a kalibráló lemezt kell a leolvasó platformra helyeznie a megfelelő pozícióba, és elindítja a kalibrálást. Egy másik lehetőség az eszköz kalibrálása a Horus fejlett kalibrációjával. Ennek az opciónak a kiválasztásakor különféle beállítások nyílnak meg, amelyek segítségével külön-külön kalibrálhatók a kívánt funkciók. Ebben az esetben a szkennelés végeredménye lényegesen jobban befolyásolható testreszabott beállításokkal. A kalibrálás azzal kezdődött, hogy a kamera színegyensúlyát a megfelelőre állítottuk úgy, hogy a tárgyról visszaverődő lézersugarat egyértelműen rögzíteni tudta a kamera. Továbbá a kamera által másodpercenként készített képek száma (Frame rate) és felbontásának beállítása is ekkor történik. Ezek az értékek jelentősen befolyásolják a szkennelés minőségét. A színegyensúly megfelelő beállítása után magát a kamerát is kalibráltuk. A folyamat során a kamera sok képet készít a kalibráló tábláról különböző szögekből. A kamera felismeri, hogy melyik helyzetben van a lemez, és melyik helyzetben vannak a kalibrációs négyzetek. A kalibrálás

eredményeit a szoftver grafikusan megjeleníti (28. ábra), ahonnan a különböző szögek és távolságok leolvashatók.



28. ábra – 3D scanner kamerakalibrációs eredményei


Ezután a készülék lézereit kalibráltuk. A kalibrálás egy kalibrációs tábla segítségével történik, amely ugyan olyan kialakítású, mint a lencsekorrekciós eljárásnál (29/a. ábra). A lézersugarak a kalibrációs platform fekete és fehér rácshálójáról különböző intenzitással verődnek vissza. Ebben az esetben megtudjuk a lézerek és a kamera centrális távolságait (29/b. ábra).



29. ábra – 3D scanner lézerekalibrációs eredményei

Végül kalibráljuk a készülék forgó platformját, amelyre rákerül a szkennelt tárgy. Ebben a kalibrálásban is kalibráló táblát használtunk, amely egy fordulattal forgott a platformon, és meghatározta a platform forgásának tulajdonságait.

A kalibráció után történik a tényleges szkennelés. A kívánt tárgyat a letapogatási platform közepére helyezzük úgy, hogy mindkét lézer felé mutasson. Szkennelés befejezése után, a beolvasott pontfelhő mentésre kerül, további feldolgozás céljából. A pontfelhőt a Meshlab (Visual Computing Laboratory) nevű szoftverrel dolgoztuk fel (30. ábra).



30. ábra – A 3D szkennelés módszertani folyamatábrája és modellépítés a paradicsom gyümölcséhez

Mind a szabadföldi, mind a növényházas mérési területen a termésmintákat véletlenszerűen választottuk ki, ügyelve arra, hogy minden minta azonos érési állapotban legyen. A minták begyűjtése a szabadföldi és a növényházas első mérés esetében a képi adatgyűjtés után, a mérés utolsó lépéseként történt, így a mintáknak ugyan olyan fejlődési, illetve érési állapotban kellett lenniük, mint a mérés közben. A begyűjtött mintákat hűtve tároltuk a további esetleges érési


folyamatok lelassítása céljából egészen a szkennelés megkezdéséig, amelyet a mérést követő napon el is végeztünk. A bogyók fizikai tulajdonságainak meghatározása során a kapott paradicsom bogyó sűrűségek értéke az egyes minták között maximum $0,08 \text{ g/cm}^3$ eltérést mutatott, amely szintén az azonos érettségi állapotra utal, így, a kiválasztott bogyókat reprezentatív mintáknak tekintettük (ZSOMNÉ, 2008).

Mind két fajtából három-három mintát gyűjtöttünk be, amelyeket a Cyclops 3D szkennelőkészítő kalibrációja után letapogattunk (31. ábra).



31. ábra – 3D szkennelés folyamata

A szkennelési folyamat után egy 3D pontfelhő keletkezett, amely reprezentálja mind a két paradicsom fajta morfológiai tulajdonságait. A pontfelhő alapján előállítottuk a termékek zárt felületű 3D modelljét. A feldolgozás első lépéseként a Horus szkennelőkészítő által generált pontfelhő minden egyes pontjához a "Compute normals for points sets" paranccsal a program kiszámítja a pontok alapján a háló minden egyes felületeleméhez tartozó normálist (32. ábra).



32. ábra – A 3D pontfelhő normálisainak vektorai (kék nyílsokaság)

A következő lépés egy felület-rekonstrukciós szűrő alkalmazása („Poisson surface reconstruction”), amely a pontfelhő összes pontját egyetlen hálóvá olvasztja, integrálva a különböző részeket, hogy tökéletesen illeszkedjenek egymáshoz, ez esetlegesen a letapogatás során keletkező folytonosságokat is pótolva.

4. EREDMÉNYEK

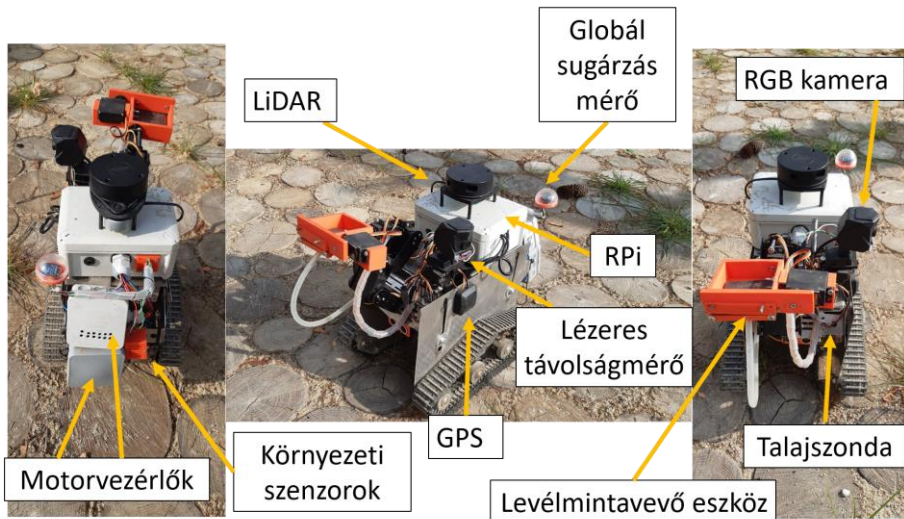
„Ha adott esetben "fúrca" következtetésekre jutunk (...), akkor lényegtelen, hogy ez tetszik-e nekünk, vagy sem. Az egyetlen lényeges kérdés az, vajon ezek a következtetések összeegyeztethetők-e a kísérleti tapasztalattal vagy sem.”

– FEYNMAN

4.1. Robotfejlesztés eredményei

4.1.1. Szerkezeti elemek

A továbbfejlesztett robot geometriai méretei a következők; hossza 35 cm (kar nélkül), szélessége járószerkezettel együtt 25 cm, maximális magassága 40 cm, hasmagassága 20 cm (talajszondát nem beleszámolva). Teljes tömege beleértve az akkumulátort is 6,4 kg. Szántóföldi körülmények között és üvegházi paradicsomkultúrákban is teszteltük. A berendezés maximális sebessége 10 cm/s, ami elegendőnek bizonyult az adatok (szenzor és képi) gyűjtéséhez és elemzéséhez. Megfelelő körülmények között körülbelül 4 óra üzemidő áll rendelkezésre. A rendelkezésre álló 12 V DC feszültség mellett a robot alaplappotban mozgás nélkül 500 mA áramfelvétellel, mozgás közben pedig 3500 mA áramfelvétellel rendelkezik. A 33. ábra szemlélteti a robot főbb részeit: a központi vezérlést (RPi), a környezeti, vizuális és talajérzékelőket, a mozgásvezérlő berendezést és a szervomotor-karon lévő beavatkozási berendezést. A terepen történt tesztek során meggyőződünk a módosított vázszerkezet stabilitásáról, ami megfelelőnek bizonyult, mind a szabadföldi, mind a növényházas kísérleti területen. A robot kinyújtott kar mellett is stabilnak bizonyult az utonóm mozgás során.




33. ábra – A saját fejlesztésű robot fő komponenseivel

A kiindulási rendszert működtető Python programozási nyelven írt szabad forráskódú program is jelentős átdolgozáson esett át, amely során beépítésre kerültek az egyes alrendszereket működtető alprogramok, illetve szubrutinok.

4.1.2. Navigáció

A robot autonóm módon képes irányítani magát a termény sorok között. Ehhez a művelethez elsősorban RPLIDAR A1 típusú lézeres távérzékelő modult használja fel. A LiDAR szenzor képes a előre meghatározott irányokban végez méréseket (34. ábra) és kiszámítani a távolságadatokat, ha a mért távolság kisebb, mint egy előre beállított érték, akkor az ellenkező irányba mozgatja a robotot.



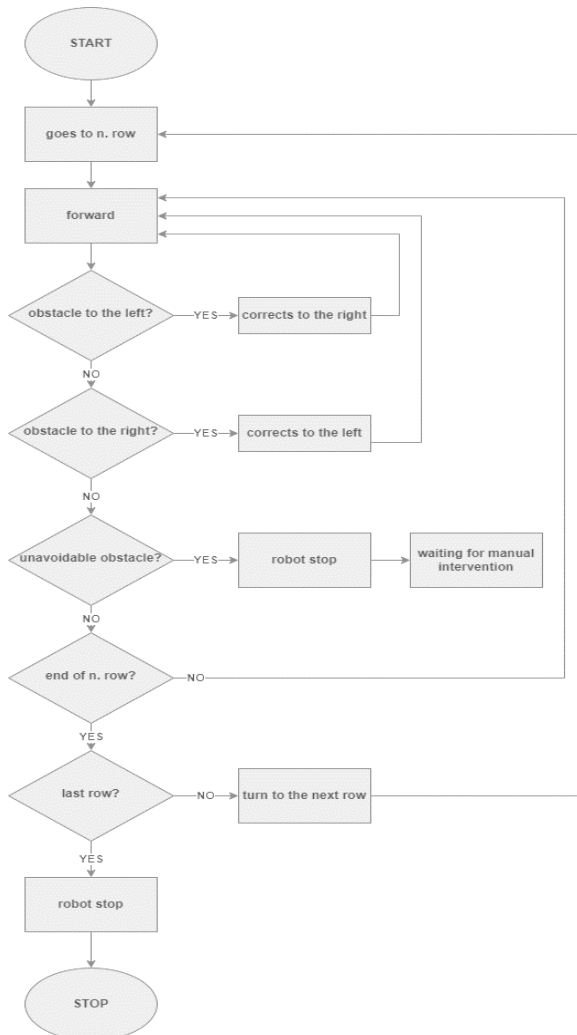
34. ábra – A navigáció által vizsgált irányok

A roboton nem választottuk külön a trajektória és a mozgástervezést. A klasszikus vonalkövető, labirintusból kiszabaduló, útvonalkereső algoritmusokhoz hasonlóan a terep feltérképezése közben a mozgással párhuzamosan, lokálisan tervezi az útvonalat. A globális térképről csak a kezdőpontot (a robot pontra helyezésével) és a végpontot kapja meg (paradicsomsorok darabszáma segítségével).

Ha a két paradicsomsort, ami között a robotnak el kell haladnia, két falnak tekintjük, akkor a labirintusokhoz hasonlóan a falak mellett kell mozognia a robotnak. Ami bonyolultabbá teszi a feladatot, hogy a paradicsomok nem biztosítanak egybefüggő, homogén falfelületet, ezért folyamatosan mindkét oldalt figyelnie kell. Sőt előfordulhatnak olyan esetek is, hogy a szakadások együtt jelennek meg a jobb és a bal oldalon, ilyenkor fel kell ismernie, hogy még nem egy elágazáshoz jutott (pl. üres terület nagyságából).

Mindkét oldalról belóghatnak az útra paradicsomok, ilyenkor a robot nem egyenesen halad tovább, hanem az akadállyal ellentétes irányban, biztonságosan kikerüli azt, figyelve a másik oldal növényeire. Ha a robot kikerülhetetlen akadályba ütközik (pl. útra beborultak a paradicsomok, az utat teljesen eltorlaszolva), akkor nem fordul vissza, hanem megáll és vár a manuális beavatkozásig.

Ha a robot közvetlenül előtte észlel egy tárgyat, megáll és kézi beavatkozásra vár. A LiDAR által mért adatok feldolgozását és döntését követően beavatkozik a jármű mozgásába. A kialakított alprogram a LiDAR-hoz elérhető függvénykönyvtárak alapján saját fejlesztésű (4. melléklet). A 35. ábra a robot navigációs logikáját szemlélteti.



35. ábra – A navigációs logika

Előzetes laboratóriumi méréseknél, ami a kialakított rendszer pontosságának megállapításához volt szükséges a sík felület (fal) mentén a beállított távolságtól az eltérés átlagban 1 *cm* alatt volt, mind jobb, mind bal oldalra nézve. A robot a mérés során egyenes vonalban halad végig a felületek mellett. A terepi körülmények szimulációja során az eltérés átlagosan 1,8 *cm* volt, ami a változatosabb, sík felülettől való eltéréssel és a robot mozgásának egyenestől való eltéréseiből fakadó pontatlanabb távolságméréssel magyarázható.

A terepi alkalmazás során az alkalmazott érzékelési eljárás alapján a robot nagyobb bizonytalansággal működött az eltérés átlagosan ± 2 *cm* volt, viszont a beavatkozási módszer elegendőnek bizonyult a robot pontos soron tartáshoz. A növényházas kísérlet során a robot valós LiDAR alapú mozgását a 36. ábrán a piros vonal, a korrekciós jel nélkül rögzített helyzetét pedig a fehér körök szemléltetik.




36. ábra – GPS/GNSS adatok grafikus megjelenítése (fehér körök) és a valós nyomvonal (piros vonal)

4.1.3. Alkalmazott érzékelők

Környezeti szenzorok

A robot érzékelő rendszere a megfelelő buszrendszeren keresztül és az előírt tápfeszültség értékek mellett kapcsolódik az RPi-hez. A kezelő program az elérhető függvénykönyvtárak alapján saját kialakítású algoritmusok és rutinok segítségével képes az összegyűjtött adatokat lokálisan és felhő alapon is tárolni. Az alkalmazott érzékelők két csoportra oszthatók: az egyik a helyi környezeti és légköri paramétereket, míg a másik a talaj tulajdonságait méri. A környezeti érzékelők közül a BME280 kombinált hőmérséklet-, nyomás- és páratartalom-érzékelőt alkalmaztuk. A BH1750 fényintenzitás-érzékelő méri a globális sugárzást. Érintésmentes MLX90614 infravörös hőmérő került beépítésre, amely a talajfelszín felé irányult, így a robot a talaj felszíni hőmérsékletét is tudja mérni. Mindegyik érzékelő egy saját tervezésű és kivitelezésű PLA-ból 3D nyomtatással készített tokban található (37. ábra).



37. ábra – A robot környezeti érzékelőit tartalmazó részek 3D terve

A terepi mérések során az alkalmazott szenzorok megfelelően funkcionáltak. Az érzékelők által mért paraméterek intervalluma, és felbontása bőven elegendőnek bizonyult a terepi körülmények közötti alkalmazáshoz. Az adatküldést a robot központi egysége felé nem befolyásolta a roboton futó más alprogramok, így adatvesztés nem fordult elő. A saját fejlesztésű tokok kialakítása és elhelyezése sikeres volt, a kialakítás módja és az elhelyezkedés nem befolyásolta a működésüket.

A mérések során minden egyes alkalommal a szenzorok is szolgáltatott információt a mérési területről, amelyeket összevetettük a mérési területekre kihelyezett fix helyzetű szenzorok adataival is. Az eredményeket a 4., 5. és 6. táblázat szemlélteti.

4. Táblázat – A szabadföldi mérés során a robot és a fix helyzetű mérőállomás által gyűjtött környezeti tulajdonságok

	Robot			Fix állomás		
	min	max	átlag	min	max	átlag
Hőm. (°C)	22,74	37,32	30,39	18,6	33,3	26,0
Rel. pára. (%)	32,77	74,59	51,45	-	-	60,7
Légny. (hPa)	989,67	990,85	990,26	-	-	-
Fénye. (lux)	2232,50	54612,50	38903,17	-	-	-

5. Táblázat - A növényházas 1. mérés során a robot és a fix helyzetű mérőállomás által gyűjtött környezeti tulajdonságok

	Robot			Fix állomás		
	min	max	átlag	min	max	átlag
Hőm. (°C)	35,96	38,09	36,95	31,99	35,28	34,09
Rel. pára. (%)	35,53	44,39	39,66	39,78	48,38	44,08
Légny. (hPa)	1001,09	1001,67	1001,48	1002,56	1004,97	1003,98
Fénye. (lux)	6744,16	38107,5	27200,33	-	-	-

6. Táblázat – A növényházas 2. mérés során a robot és a fix helyzetű mérőállomás által gyűjtött környezeti tulajdonságok

	Robot			Fix állomás		
	min	max	átlag	min	max	átlag
Hőm. (°C)	27,17	31,75	28,68	24,23	29,74	26,98
Rel. pára. (%)	56,53	69,74	64,66	58,48	74,82	66,65
Légny. (hPa)	999,03	999,56	999,38	999,77	1003,38	1001,70
Fénye. (lux)	10004,92	25600,00	10004,92	-	-	-

A szabadföldi mérés esetében a hőmérséklet mérés relatív hibája 16,88% volt, míg a szabadföldi kísérletnél ez az érték az első mérésnél 8,38% míg a második mérésnél 6,3% volt. A relatív páratartalom a szabadföldi mérésnél 15,23%-os relatív hibával jelentkezett, a növényházas méréseknél 10,02% -os és 2,98%-os hibával volt jelen. A légnyomás értékek mérésére a növényházas kísérletnél volt lehetőségünk ahol is az eltérés az első mérésnél 0,24% míg a második mérésnél 0,23% volt. Az értékek eltérését a szenzorok nem azonosan mérési helyzeti folyásolta be.

Talajszonda

A robot a talaj főbb tulajdonságainak mérésére is alkalmas. Erre a célra egy talajszondát telepítettünk, amely a talajhőmérsékletet, a talaj nedvességtartalmát, vezetőképességét (EC), pH-értékét és mikroelem-tartalmát (N, P, K) gyűjti a talaj felső rétegének 5 cm mélységéből. A talajtulajdonságokat érzékelő szondát (38/a. ábra) egy léptetőmotor (Nema 17) juttatja a talajba egy saját tervezésű lineáris aktuátor segítségével egy fogaskerekes áttételen keresztül (38/b. ábra), egy H-híd motorvezérlő áramkör (L298n) segítségével. A mechanizmus tartóelemei alumíniumból, a fogaskerekek és a talajszondát tartó konzol 3D nyomtatással készültek (műgyantából és PLA-ból).

**a****b**

38. ábra – A talajérzékelő elhelyezkedése (a) és a mozgó mechanizmus (b)

A talajba hatolásért felelős aktuátor mozgatásáért külön egy a szervo motort működtető alprogram készült. A program a szonda mozgatását 10 mm-es lépésközzel oldja meg, így pontosan lehet pozicionálni a megfelelő mélység eléréséhez. A talajszondát működtető alprogram szintén saját fejlesztésű és a talajszondához elérhető használati utasítások alapján készült. A talaj tulajdonságainak mért hexadecimális

értékeit ez az alprogram alakítja át decimális értékekre (7. táblázat). Az így átszámított talajparaméterek táblázatos formában (.csv) kerülnek mentésre.

7. Táblázat – A talajszonda nyers és feldolgozott adatok

		Paraméterek	Mértékegység	Értékek
Cím	x01			
Funkció	x03	-	-	-
Érvényes bájtok	x0E			
	x01 x8d	Nedvességtartalom	%	39,7
	x00 xde	Hőmérséklet	°C	22,2
	x01 xe0	EC	uS/cm	480
HEX Adatok	x00 x4d	pH	-	7,7
	x00 x13	N	mg/kg	19
	x00 xa1	P	mg/kg	161
	x00 x41	K	mg/kg	65
CRC	x7b	-	-	-
	xr6	-	-	-

RGB kamera

A kamera 640×480 pixeles felbontású, 24 bites színmélységű és 96 dpi-s képeket képes rögzíteni. A szabad forráskódú MJPG-Streamer alkalmazás felelős a kamera működéséért. Az MJPG-Streamer egy parancssori alkalmazás, amely a JPEG formátumú képeket képes online streamelni külső eszközökre vezeték nélküli kapcsolatot felhasználva, így továbbítva azt a robot irányító applikációjára. A készíthető képek száma szabadon beállítható, a felvételek a helyi memóriába (SD kártya) kerülnek mentésre időbélyegzővel ellátva (39. ábra).



39. ábra – A robot által készített képek szabadföldi termesztésről és növényházból

4.1.4. Adatgyűjtési és továbbítási módszerek


A berendezés az összegyűjtött adatokat kétféleképpen tárolja. Először is, táblázatos formában (.csv fájl) tudja rögzíteni az értékeket a saját memóriájában a kívánt intervallum beállításával. A másik egy felhő alapú tárolórendszer. Az adatátvitelhez vezeték nélküli Arduino MKR GSM 1400 technológiát integráltunk a robotba, amely az Arduino

és a globális GSM funkcionalitását ötvözi 3G hálózati kapcsolattal. Az Atmel SAMD21 és egy SARAU201 GSM modulon alapul, amely ideális megoldás IoT projektekhez. A nagy energiaigény miatt a modul tápellátásához külön 5V DC-DC modul került beépítésre. Az adatok 20 másodpercenként kerülnek továbbításra a távoli szerverre. A modul egy RS232 soros porton keresztül csatlakozik az RPi-hez, amelyen keresztül az adatok string formátumban elküldésre kerülnek a GSM modulba, majd a megfelelő változóba beillesztve továbbítják a szerverhez. A rendszer két külön programból áll; az egyik az RPi-n fut és az adatok küldéséért valamint a beolvasott adatok megfelelő string formátumú átalakítását végzi el, a másik program a GSM modulon található az Arduino saját programozási nyelvén készült el. A program kialakítása során felhasználtuk az Arduino alapú modul alap függvénykönyvtárait. A 40. ábra a GSM modul programjának részletét szemlélteti.

```
temp = atof(strings[0]);
hum = atof(strings[1]);
lux = atof(strings[2]);
objtemp = atof(strings[3]);
newData = false;
  ThingSpeak.setField(1, temp);
ThingSpeak.setField(2, hum);
ThingSpeak.setField(3, lux);
ThingSpeak.setField(4, objtemp);
int x = ThingSpeak.writeFields(myChannelNumber, myWriteAPIKey);
if(x == 200){
  digitalWrite(greenLED, HIGH);
  delay(1000);
  digitalWrite(greenLED, LOW);
  delay(1000);
  digitalWrite(greenLED, HIGH);
  delay(1000);
  digitalWrite(greenLED, LOW);
  delay(1000);
}
else{
}
delay(20000);
```

40. ábra – Adatküldő Python alprogram részlete


A mért adatok közvetlenül felhasználhatók a növényállomány monitorozására, valamint előrejelzésre, modellezésre. Az adatok tárolásához a ThingSpeak nevű online IoT-elemző platform szolgáltatást alkalmaztuk, amely lehetővé teszi élő adatfolyamok összesítését, megjelenítését és elemzését a felhő alapú tárolást megvalósítva (41. ábra). Az adatsorok közvetlenül számítógépről, vagy okostelefonról azonnal elérhetőek, ezen felül a robot a kezelő felé az irányító applikáción keresztül meg is jeleníti az adatokat.



41. ábra – A robot által gyűjtött adatok idősoros grafikonjai a ThingSpeak szerveren

4.1.5. Levélmintavevő működtető

A szenzorok által szolgáltatott adatok kiegészítése végett a robotra integráltunk egy mintavevő effektor is (42. ábra).



42. ábra – A levélmintavevő aktuátor felépítése és működése

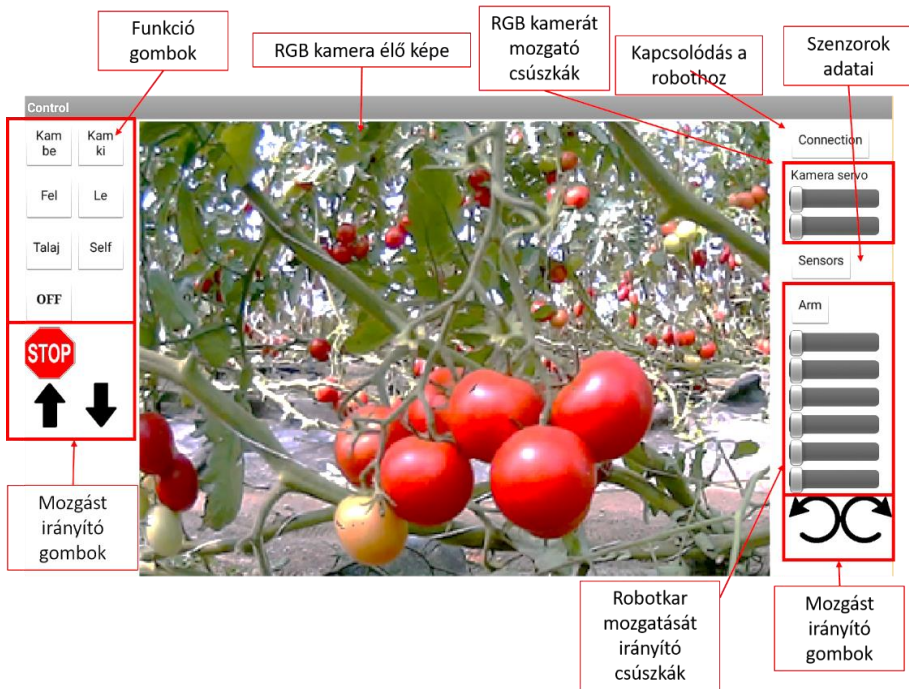
A berendezés az eredeti robotkar átalakításával készült, a kar csuklós szerkezetét megtartva az utolsó tag (fogószerkezet) eltávolításával, és helyettesítésével. A kar két szervó motor segítségével két tengely mentén mozgatható, valamint a mintavevő rész a saját tengelye körül egy további szervó motorral 180°-ban elforgatható. A mintavevő effektor nyíró munkafolyamat során képes mintát venni a növényzetből, amelyet szintén egy szervomotor aktivál. Az alkatrész minden része saját tervezésű és kivitelezésű PLA anyagból készül, FDM (Fused Deposition Modeling) 3D nyomtatással, CATIA V5 tervezőszoftver segítségével. A készülék alsó részén található furathoz egy rugalmas 5 mm belső átmérőjű szilikon cső csatlakozik, amely a mintavevőt egy relé vezérlésű légsűrítőhöz köti, amely a mintavétel (vágás) pillanatában megtámasztja a paradicsom növény leveleit (43. ábra).



43. ábra – Levélminták gyűjtése

4.1.6. Távirányítás

A robot terepi körülmények közötti felhasználóbarát irányítása végett egy saját fejlesztésű alkalmazás került kialakításra, melynek segítségével a továbbfejlesztett robot minden funkciója könnyen elérhető és kezelhető (44. ábra).

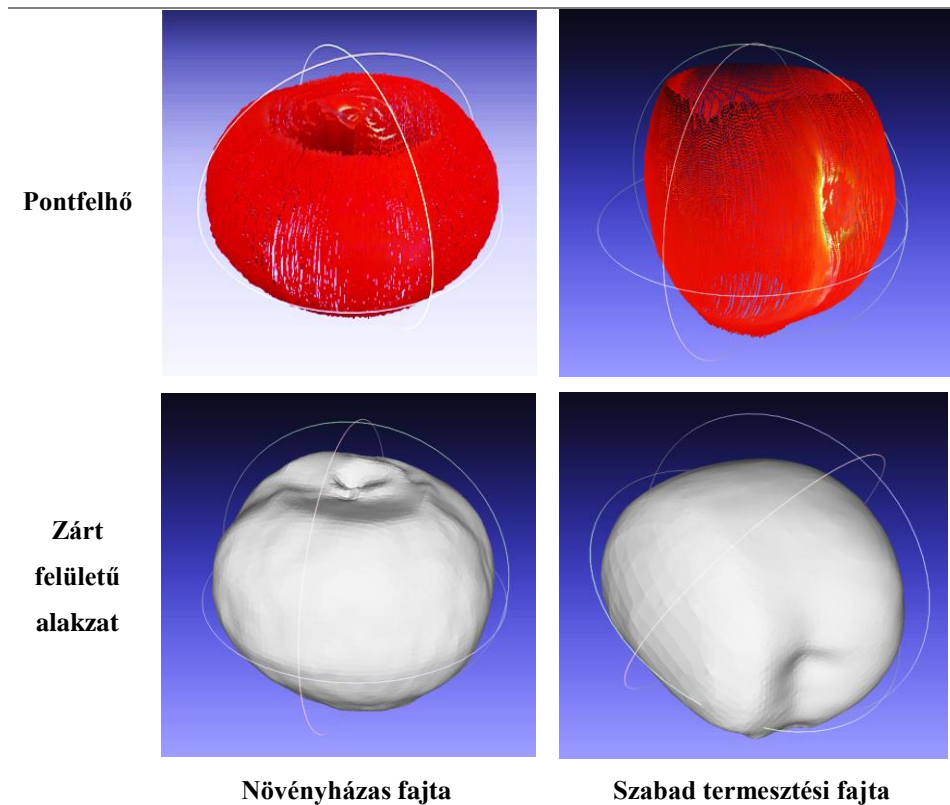


44. ábra – A távirányító grafikus interfész alkalmazás és részei

Az alkalmazás grafikus felületet biztosít a robot teljes körű kezeléséhez. Nyomógombok segítségével valósítható meg a berendezés mozgatása, egyes funkcióinak aktiválása (pl.: talajszondával történő mérés, képosztályozás, stb.). A mintavevő kar mozgatása és a mintavételezés a csúszkák mozgatásával történik, ugyanilyen elven pozicionálható az RGB kamera is. A fejlesztéséhez az MIT App Inventor programot használtuk (URL¹⁵). Az MIT App Inventor egy intuitív, vizuális programozási környezet, amely lehetővé teszi a felhasználó számára, hogy teljesen működőképes alkalmazásokat hozzon létre okostelefonokhoz és táblagépekhez. Az inventor blokk alapú programozási nyelvet használ így a program nem hagyományos szerkezetű.

4.2. Paradicsom termés 3D modellezésének eredményei

A paradicsom termésbecslése érdekében megalkottuk a paradicsom termés 3D szkennelével készült modelljét mind a két kísérleti helyszínen begyűjtött a két különböző fajta érett paradicsom minták alapján (45. ábra).



45. ábra – A felületrekonstrukció grafikus eredményei mindkét vizsgált paradicsomfajtánál

A létrejött alakzat geometriai tulajdonságai a feldolgozó szoftver segítségével kinyerhető, így meghatározható a lineáris méret, térfogat, a felület, a tömegközéppont, stb.

A paradicsom modell térfogatának meghatározása után a legkisebb négyzetek módszerével hozzáillesztettük a legjobban illeszkedő

gömböket (8–11. egyenlet), amelyek a bogyók közelítését szolgálják a termésbecsléshez.

$$A = 2 \left(\frac{1}{N} \sum_{k=1}^n v_k \cdot v_k^T - \bar{v}_k \cdot \bar{v}_k^T \right) \quad (8.)$$


$$b = \bar{v}_k^3 - \left(\bar{v}_k^2 \right) \bar{v}_k \quad (9.)$$

$$m = A^{-1} \cdot b \quad (10.)$$

$$r = \sqrt{\frac{1}{N} \sum_{k=1}^n (v_k - m)^2} \quad (11.)$$

ahol, v_k a pontfelhők pontvektorai, r a sugár, m pedig a gömb tömegközéppontjának koordinátája (URL¹⁶).

Ennek során meghatároztuk a pontfelhő középpontját, amely az illesztett gömb középpontja lesz, valamint az illesztett gömb sugarát (46. ábra).



Növényházas fajta

Szabad termesztésű fajta

46. ábra – A legjobban illeszkedő gömbök grafikus eredményei mindkét vizsgált fajtánál

Mindkét mintaterületről begyűjtött bogyók tulajdonságait kézi mérésekkel is meghatároztuk. Figyelembe véve a gömb térfogatának a paradicsombogyók térfogatához viszonyított arányát, mint korrekciós tényezőt, valamint a paradicsombogyó termésének átlagos sűrűségét, a képek feldolgozásával termésbecslés végezhető el (8. és 9. táblázat).

8. táblázat – Szabadföldi kísérletnél alkalmazott paradicsom fizikai paraméterei

Számított eredmények (Meshlab)				Kézi mérés eredményi			
Bogyók térfogata (cm ³)	Illesztett gömb térfogata (cm ³)	Térfogat eltérés hibája (%)	Térfogat arány (-)	Bogyók térfogata (cm ³)	Mért paradicsom tömeg (g)	Számolt sűrűség (g/cm ³)	
1	47,3023	37,7113	20,28	1,2543	56,7	60,2	1,0617
2	74,7714	61,4698	17,79	1,2163	84,8	87,5	1,0318
3	47,9358	38,9529	18,74	1,2306	52,3	57,6	1,1013
\bar{x}	46,0447	56,6698	23,08	<u>1,2337</u>	64,6	68,4	<u>1,0649</u>


9. táblázat – Növényházas kísérletnél alkalmazott paradicsom fizikai paraméterei

Számított eredmények (Meshlab)				Kézi mérés eredményi			
Bogyók térfogata (cm ³)	Illesztett gömb térfogata (cm ³)	Térfogat eltérés hibája (%)	Térfogat arány (-)	Bogyók térfogata (cm ³)	Mért paradicsom tömeg (g)	Számolt sűrűség (g/cm ³)	
1	108,5074	109,5648	0,97	1,0097	106,1	102,1	0,9622
2	123,2558	137,4851	11,54	1,1154	98,1	85,9	0,8756
3	158,0477	171,4178	8,46	1,0845	100,9	91,1	0,9028
\bar{x}	129,9373	139,4892	7,35	<u>1,0699</u>	101,7	93,03	<u>0,9136</u>

4.3. Optikai korrekciós eredmények

4.3.1. Lencsekorrekciós eredmények

Az optikai torzítási hibák kiküszöbölésére egy kalibrációs minta segítségével lineáris kalibrációt végeztünk. A program által a kalibrációs mintára illesztett rácshálóból az optikai rendszer leképezésével kapcsolatos információk nyerhetők ki, amelyek felhasználhatóak a lencse, lencsetagok torzításának kiküszöbölésére (47. ábra).



47. ábra – A korrekció során a kalibrációs tábla rácspontjaira illesztett egyenesek egy kalibrációs kép esetében

A folyamat során az Adobe Lens Profile Creator 1.0.4 szoftvert alkalmaztuk, amely egy kalibrációs mátrixot hozott létre a kalibrációs minta különböző irányából és távolságából a robot által készített képei

alapján (5. melléklet). A torzítási együtthatókat felhasználva a képeket perspektivikus nézetre korigálja a program (48. ábra).

```
<stCamera:FocalLengthX>0.811545</stCamera:FocalLengthX>
<stCamera:FocalLengthY>0.811545</stCamera:FocalLengthY>
<stCamera:ImageXCenter>0.523748</stCamera:ImageXCenter>
<stCamera:ImageYCenter>0.546923</stCamera:ImageYCenter>
<stCamera:RadialDistortParam1>-
0.063126</stCamera:RadialDistortParam1>


<stCamera:RadialDistortParam2>0.295717</stCamera:RadialD
istortParam2>
<stCamera:ResidualMeanError>0.000198</stCamera:ResidualM
eanError>
<stCamera:ResidualStandardDeviation>0.000097</stCamera:R
esidualStandardDeviation>
```

48. ábra – Kamera torzítási együtthatók

A 12. egyenletet felhasználva.

$$s[x_i \ y_i \ 1] = \bar{\bar{H}}[X_w \ Y_w \ 1] \quad (12.)$$



ahol, x_i és y_i a képből kinyert sarokpontok képp koordinátái, X_w és Y_w pedig a világ koordinátái; a $\bar{\bar{H}}$ homográfia 3×3 mátrix, s pedig tetszőleges léptéktényező (SUN et al., 2015) torzítás nélkül meg lehet határozni a paradicsom bogyójának egy adott távolságú felületre vetített felületének pontos nagyságát (49. ábra).





49. ábra – Képkalibrálás kalibrációs mintával a kis robot kameráján

4.3.2. Fénykorrekciós és színi vizsgálatok eredményei

A vizsgálat során a képek feldolgozásához OpenCV alapú technikát alkalmaztunk, amely függvénykönyvtárral a képekből kinyertük a képre jellemző öt különböző színt és ezen színek HSV értékeit (6. melléklet). A színek egy része a háttér fehér részét jellemezte, két szín viszont a paradicsom színére irányult. Ezen két szín értékeket szemlélteti az 50. és az 51. ábra.



50. ábra – Az érett paradicsomra jellemző első szín és HSV értékeik



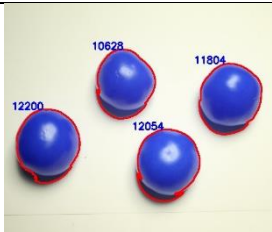
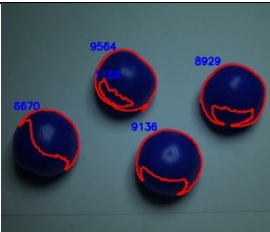
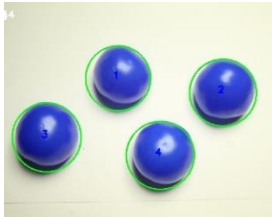
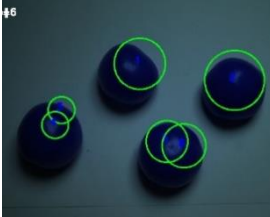
51. ábra – Az érett paradicsomra jellemző második szín és HSV értékeik

A HSV minimum és maximum értékének felhasználásával megállapítható a szegmentáció intervallumának értékei (10. táblázat), ami az érett paradicsom jellemző H-S-V értékeit jelenti.

10. táblázat – Az érett paradicsomra megállapított HSV intervallum


	H	S	V
Alsó határ	0	62	0
Felső határ	15	255	255

A 7. táblázat alapján meghatározott színek szerinti szegmentációs intervallumot felhasználva minden egyes megvilágítás melletti képeken gépi látást alkalmazó algoritmussal meghatároztuk a kijelölt területek nagyságát pixelben és ehhez a legjobban illeszkedő kört illesztettük (52. ábra).

Képszám	1.	10.
Megvilágítás (lx)	11935,42	1635,83
Kijelölt terület nagysága (pixel)		
Illesztett befoglaló körök helyzet és száma (db)		

52. ábra – A megvilágítás, a kijelölt felületelemek és az illesztett körök kapcsolata

Az eredmények alapján megállapítható, hogy a kijelölt terület nagysága 3000 lx megvilágításnál kisebb értékek mellett meredeken kezd csökkenni, 1600 lx érték mellett a valós terület megközelítőleg felét már nem jelöli ki az eljárás (53. ábra).




53. ábra – A szegmentációs eljárás folyamán kijelölt terület nagysága a megvilágítás függvényében

A nem megfelelő kijelölés miatt az illesztett körök pozíciója és száma 3000 lx megvilágításnál kisebb értékekénél már nem elegendő a megfelelő szintű termésbecsléshez.

4.3.3. Távságkalibráció eredményei

Az alkalmazott referencia objektum színi kiválasztása a 4.3.2. fejezetben meghatározott HSV intervallum felhasználásával történt meg. (54. ábra).




54. ábra – Távolság kalibrálása referencia objektummal különböző távolságokból a robotkamera felvételén

Az így elkészült képeknél a lencsetorzítás kiküszöbölése után szín szerinti szegmentálást alkalmaztunk, amely során elválasztottuk és kijelöltük a referencia objektumot a képeken, valamint meghatároztuk a pixelben mért felületét. Ezt a számot ezután elosztottuk a referenciaobjektum cm^2 -ben megadott felületével így eredményként egy pix / cm^2 arányt kaptunk (13. egyenlet).

$$\varepsilon = \frac{A_{pix}}{A_{valós}} \quad (13.)$$

ahol, $A_{valós}$ a referencia objektum ismert feülete (piros kör), A_{pix} pedig a referencia objektum vetületi felülete a képen adott távolságban.

A kapott érték a képeken látható felület és a valós felület metrikájának felel meg. A referencia objektum felülete $50 cm^2$, amely az új objektumok méreteinek becslésére használt referenciaérték, amit az ε ráció és a felvételek kamerától való távolságának felhasználásával határoztunk meg (55. ábra).



55. ábra – DSLR és robotkamera távolságkalibráció

Ahogy a 49. ábrából látható mind két platform esetében hasonló a 14. egyenletben leírt általános alakú hiperbolikus összefüggéseket nyertünk ki, az eltérés az egyenletek konstansaiban, illetve a negatív hatványkitevőben található.

$$\varepsilon = cd^{-x} \quad (14.)$$

ahol, c állandó, d a referencia objektum távolsága és ε a 13. egyenletből származó arány.


A 13. és 14. egyenletet felhasználva megadható egy a kamerától adott távolságban található objektum arra a távolságra állított síkra vetített merőleges vetületének a valós (cm^2) felülete.

4.4. Képfeldolgozás eredményei

4.4.1. Paradicsom termés detektáló módszerének eredményei

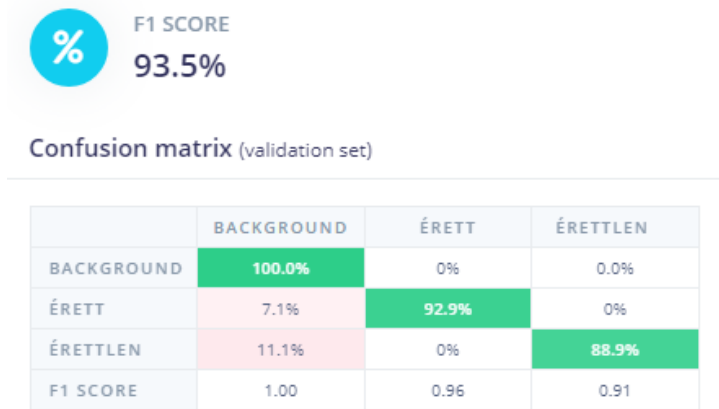
A robot mozgása során elemzi a rögzített képeket, amit egy gépi tanulás alapú CNN tesz lehetővé, amit paradicsom növény termésének osztályozására a termésbecslést megelőzően elkészített képek felhasználásával készítettünk el.

Az 56. ábra a tréningezési folyamat eredményeit szemlélteti a ciklusok függvényében.



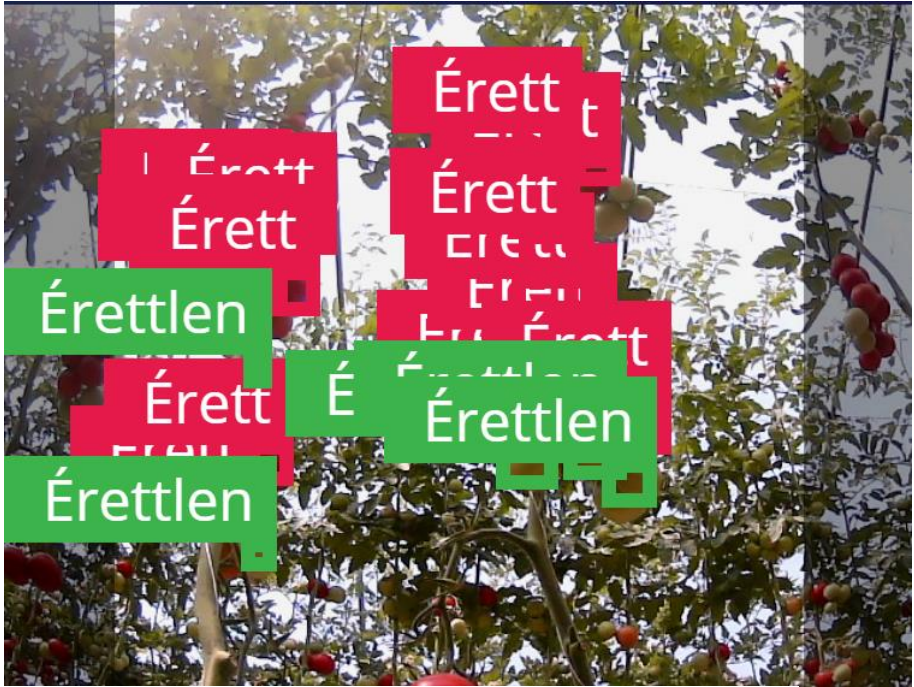
56. ábra – A CNN tréning grafikus eredményei

A tréning folyamat befejeztével az elkészült modell tulajdonságait az igazságmátrix tartalmazza. A teszt (validációs) adatkészlet képei szolgáltatják az igazságmátrix értékeit (57. ábra); ez a mátrix összehasonlítja a tényleges célértékeket (függőleges oszlopok) az előrejelzettekkel (vízszintes vonalak).



57. ábra – Igazság mátrix (érvényesítési készlettel)

A táblázat alapján az F1 teljesítménymutató értéke több mint 90%-nak adódott, jelezve, hogy a modell minden megfigyelést helyesen jelez előre. A modell teszteléséhez az alkalmazás lehetőséget biztosít a teszt adatkészlet alapján a pontosság ellenőrzésére, amely során a fényképeken végrehajtja az osztályozást megállapítva a valószínűségét az adott osztálynak és az eredményt összehasonlítja az eredetileg a képen meghatározott kategóriákkal. A teszt eredménye a képek 20%-án 75,03%-os pontosságot eredményezett (58. ábra).



58. ábra – A CNN tesztelése a betanítása osztályok és a klaszterezés eredménye és helyzete a tesztkészlet egy képén

Az Edge Impulse eredendően online platformként szolgál különböző eszközöknek a neurális hálózat távoli vezeték nélküli elsősorban Wi-Fi-n keresztüli eléréséhez. Ez a megoldás terepi körülmények között nem megfelelő, mivel a robot ezt a kapcsolatot az irányításra használja. Így egy offline működő programot készítettünk felhasználva az Edge Impulse és a Tensorflow függvénykönyvtárakat (7. melléklet). Az elkészített és tesztelt modellt a robot központi egységébe letöltve online kapcsolat nélkül is alkalmazható a klaszterezés. A szoftver alacsony 96×96 pixeles felbontású képeket használ (59/a. ábra), mert a neurális hálózat modellje négyzet alapú alacsony felbontású képeket vár. Az 59/b. ábra az eredeti méretű és felbontású kép (640×480 pixel) látható a megjelölt osztály markerével.



a

Vágott, alacsony
felbontású kép markerrel



b

Eredeti méretű és felbontású kép

59. ábra – Észlelt paradicsombogyók különböző felbontású képeken.

Az azonosított paradicsomrészek képeinek számozással és időbélyegzővel ellátott mentése mellett a gép az osztályozás tulajdonságait is elmenti táblázatos .csv formában (11. táblázat). Ez a táblázat tartalmazza a kép száma és időbélyegzője mellett az osztály nevét (O), valószínűségét (V), helyzetét (x, y) és a marker szélességét (SZ) és magasságát (M) pixelekből.

11. táblázat – A mentett paradicsombogyó-képek tulajdonságai

NO (db)	Dátum (Y.M.D.)	Idő (h:min:s)	O (-)	V (%)	x (pix)	y (pix)	SZ (pix)	M (pix)
103	2022. 07.29	10:50:58	Érett	0,75	80	32	16	8
	2022. 07.29	10:51:04	Érett	0,99	48	24	8	8

A klaszterező alprogram közvetlenül elindítható a robot irányító applikációjából, amellyel párhuzamosan az autonóm mozgást irányító alprogram is működésbe lép az automatikus mozgás végrehajtásához. Az érett paradicsombogyó detektációjakor a robot a piezo hangszóró segítségével hangjelzést is ad. A detektáció futása közben a kamera képeinek streamelése az applikációban szünetel.

4.4.2. Paradicsom-levélelváltozás detektálásának eredményei

A paradicsom termés klaszterezésének mintájára elkészítettünk egy a paradicsom növény leveleinek elváltozásait kimutatni képes CNN modellt is. Ez a modell képes észlelni a paradicsom növény levélzetének elváltozásait (zöld és nem zöld részek), amelyekből a

növény betegségeire és tápanyaghiányára lehet következtetni. A paradicsombogyókat osztályozó modell kialakításához hasonló módon történt ennek a modellnek az elkészítése is. Egy osztályt hoztunk létre összesen 924 paradicsom levél mindkét oldaláról készült képek felhasználásával, amely reprezentálja a levélzet elváltozásait. A felvételezés több alkalmmal történt a növényházban végzett kísérleti helyszínen (2022. május 20. és július 15. között). A modell a tréning után 53,7%-os F1 érték mellett, 21%-os pontossággal működött (60. ábra).



a



b

Vágott, alacsony felbontású
kép markerrel

Eredeti méretű és felbontású kép

60. ábra – Növény levelek elváltozásainak érzékelése különböző felbontású képeken

Az azonosított elváltozások képeinek számozással és időbélyegzővel ellátott képe mentése mellett a gép az osztályozás tulajdonságait is elemi táblázatos .csv formában (12. táblázat). Ez a

táblázat tartalmazza a kép száma és időbélyegzője mellett az osztály nevét (O), valószínűségét (V), helyzetét (x, y) és a marker szélességét (SZ) és magasságát (M) pixelekbén.

12. táblázat – A mentett levélsérülésképek tulajdonságai

NO	Dátum	Idő	O	V	x	y	SZ	M
(db)	(Y.M.D.)	(h:min:s)	(-)	(%)	(pix)	(pix)	(pix)	(pix)
3732	2022.08.2	10:49:04	ELV	0,75	0,72	40	48	8

A modell jelenleg nem képes konkrétan elkülöníteni az egyes elváltoztatásokat. Ezen modell képzése során a betanítási adatkészlet nem szelektív módon tartalmazta az egyes elváltozásokat, csupán az egészséges levélzettől való elkülönítését szorgalmazta, így nem képes specifikusan az egyes elváltozások elkülönítésére. Az elváltozások egymástól való tényleges elkülönítéséhez további növényvédelmi monitoringra, valamint megfigyelésekre van szükség.

4.4.3. A hozambecslési módszer eredményei

A kétféle módszerrel készített felvételek alapján nemcsak a termések szín szerinti szétszeparálását, hanem OpenCV alapú utófeldolgozással termésbecslést is végeztünk.

A szabadföldi kísérletnél a robottal végzett felvételezés során az érett paradicsombogyók kijelöléséhez szükséges sugár 25 és 60-as érték mellett működött megfelelően abban az esetben, amikor a robot az előre megadott távolságot maximum $\pm 3-4$ cm eltéréssel tartotta. A nagyobb eltérés esetében a T2-2, T1-4, T0-3 és T3-4 mintavételi helyen az illesztett körök pontatlanok voltak így a hozambecslés eredményei nem

voltak értelmezhetőek. A kézi kamerás felvételezésnél az illesztett körök sugara 25 és 35-ös érték mellett működött megfelelően. A növényházas kísérletnél a robot képei esetében az illesztett körök sugara 25 és 40 intervallumon, míg a DSLR felvételezésnél 30 és 45 intervallumon működött legpontosabban.

4.4.4. *Paradicsombogyók tömegének meghatározásának eredményei szabadföldi kísérletben és növényházban*

A fejezetekben bevezetésre kerülő nagyszámú változók egyértelműsítő jelölésmódja a „11. jelmagyarázat” részben található. A paradicsom termés tömegét a készített felvételek OpenCV alapú utófeldolgozásával nyertük ki.

A kísérlet végrehajtásakor megvizsgáltuk a lineáris kapcsolat mértékét a kézi méréssel meghatározott paradicsom össztömeg (\bar{M}) és az alkalmazott módszer által megállapított paradicsom össztömeg között (\bar{m}_x), amelynél a 15. számú egyenletet alkalmaztuk.

$$\bar{m}_x = a\bar{M} + b \quad (15.)$$

ahol, a , b , állandók, x pedig 1 – 11 között a mérés számát jelöli.


Az össztömeg meghatározásakor a paradicsombogyók térfogatának kiszámításával a gömbbel és a 3D modellel való közelítést is alkalmaztuk. Valamint felhasználtuk a LiDAR által mért távolságadatokat és a mintaterületen termesztett paradicsomokra meghatározott átlagsűrűséget is. Az eredmények összehasonlítása

végezt meg határoztuk a mért és a számított értékek közötti eltéréseket, az összes kezelésre vonatkozó átlagot (\bar{x}), az összes kezelésre vonatkozó átlagos szórást (σ), a mérés átlagos abszolút hibáját (H), és a mérés átlagos relatív hibáját is (h).

4.4.4.1. DSLR fényképezőgép képeinek eredményei

Szabadföldi paradicsomkísérlet

A kísérlet öt kezelésből áll, nevezetesen T0, T1, T2, T3, T4, két ismétlésben. Minden kezeléshez 2 mintahely tartozik (T0-1, T0-2, T0-3, T0-4). Az adatgyűjtés összesen 20 mintahelyet jelent, ami kezelésenként négy ismétlés. A mintavétel 5 db kép készítésével történt, így összesen 100 kép készült a szántóföldi paradicsomkísérletből 2022. augusztus 29-én. A képelemzési folyamat folyamatábrája az 61. ábrán látható.



61. ábra – A DSLR fényképezőgép képi adatainak kiértékelése a szabadföldi kísérletnél

Végeredményként megkaptuk a paradicsombogyók össztömegét a gömbbel ($\overline{m_1}$), és a 3D modellel ($\overline{m_2}$) való közelítéssel, amely az adott mintaterületre jellemző (8. melléklet).

A 13. táblázat a paradicsombogyók tömege közötti összefüggést mutatja a gömb és 3D modellekkel mért tömegközelítés között (9. és 10. melléklet).


13. táblázat – A paradicsomtömegek korrelációja a gömb és a 3D modellekkel való közelítéskor az egyes kezeléseknél

Kezelések	Konstansok (közelítés gömbbel)		Konstansok (közelítés 3D modellel)		R^2
	<i>a</i>	<i>b</i>	<i>a</i>	<i>b</i>	
T0	0,6004	3,9148	0,4962	3.2354	0,9139
T1	1.965	-1,3574	1,6239	-1,1219	0,9676
T2	0,5407	2.1386	0,4469	1,7675	0,7346
T3	0,7523	1,7713	0,6217	1,4639	0,9863
T4	-1,7826x	38.452	-1,4732x	31.778	0,7289

A két különböző modellel való közelítés minden kezelésnél $R^2 = 0,7289 - 0,9863$ közötti korrelációt eredményezett az egyes kezelésekre nézve. A T4-es kezelés negatív együtthatójának oka magasabb öntözési mennyiségben keresendő, mivel a fejlettebb, nagyobb számú levélzet nagyobb mértékű kitakarást eredményezett.

Az összes kezelésre meghatározott korrelációs együttható értéke $R^2 = 0,8678$ értékkel bírt mind a két alkalmazott modell esetében.

A 62. ábra a kezelések alapján mért és számított tömegeket foglalja össze, a hozammennyiségek növekedésének sorrendjében. A legtöbb öntözést kapott T4-es kezelésnél a legnagyobb eltérés, ami a nagyobb mennyiségű lombzat okozta kitakarásokból adódik.



62. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján.

A 14. táblázat a módszer által számított és a valós tömegek közötti eltéréseket szemlélteti.

14. táblázat - A két közelítéssel meghatározott össztömegek és eltéréseik

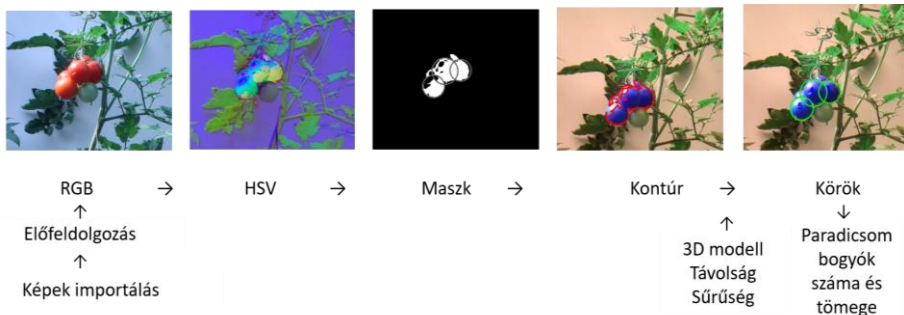
	\bar{M} (kg)	\bar{m}_1 (kg)	H_{m1} (kg)	h_{m1} (%)	\bar{m}_2 (kg)	H_{m2} (kg)	h_{m2} (%)
\bar{x}	10,35	7,10	3,42	25,52	8,59	2,45	21,90
σ	7,59	4,33	3,74	17,03	5,24	2,82	17,96

A számított tömegek átlaga a valósnál kisebb értékeket mutatott. A két módszerrel való közelítés esetében a 3D modell alkalmazásakor a módszer átlagos relatív hibája ($h_{m2} = 21,90\%$) kisebbnek mutatkozott, mint a gömbbel való közelítés hibája ($h_{m1} = 25,52\%$), ami pontosabb

előrejelzést eredményezett. Az átlagos eltérés a valós össztömegekhez képest $H_{m1} = 3,42$ kg és $H_{m2} = 2,45$ kg volt.

Növényházas paradicsomkísérlet

A kísérleti területen két alkalommal végeztünk méréseket; először 2022. július 29-én, másodszer 2022. augusztus 26-án. A mérés során 27 mintanövényt választottunk ki, amelyek egymás mellett egy sorban helyezkedtek el sorszámozva 1 – 27 között. Minden egyes mintanövényről egy fénykép készült, amely összesen 27 képet eredményezett. A képelemzési folyamat folyamatábrája a 63. ábrán látható.



63. ábra – A DSLR fényképezőgép képi adatainak kiértékelése a növényházas kísérletnél


Végeredményként megkaptuk a paradicsombogyók össztömegét az egyes mintanövényekre nézve, a gömbbel első mérésnél \overline{m}_3 , második mérésnél \overline{m}_5 és a 3D modellel első mérésnél \overline{m}_4 , második mérésnél \overline{m}_6 való közelítéssel (11. és 12. melléklet).

A 15. táblázat a paradicsombogyók tömege közötti összefüggést mutatja a gömb és 3D modellel mért tömegközelítés között mindkét mérés esetében (13., 14., 15., és 16. melléklet).


15. táblázat – A paradicsomtömegek korrelációja a gömb és a 3D modellekkel való közelítéskor mindkét mérésnél

Mérés sorszáma (-)	Konstansok (közelítés gömbbel)		Konstansok (közelítés 3D modellel)		R^2
	a	b	a	b	
1. mérés	1,0623	-0,1663	1,1396	0,1779	0,9286
2. mérés	0,9376	-0,081	1,0031	-0,0866	0,8044

A két különböző modellel való közelítés az egész kísérletre nézve $R^2 = 0,9286$ értékű korrelációt eredményezett az 1. mérés esetében, míg a 2. mérésnél alacsonyabb $R^2 = 0,8044$ korrelációt mutatott. A 64. és 65. ábra az egyes mintanövényekre nézve a mért és számított tömegeket foglalja össze, a hozammennyiségek növekedésének sorrendjében.



64. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján az első méréskor



65. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján a második méréskor

A második mérés esetében a 11, 21, 10 és 23-as mintanövény esetében megfigyelhető a valós tömeghez képesti az átlagnál nagyobb eltérés ami a levélzet kitakarásával magyarázható.

A 16. és 17. táblázat az előre jelzett és a valós tömegek közötti eltéréseket szemlélteti mind a két mérés esetében.

16. táblázat – A két közelítéssel meghatározott össztömegek és eltéréseik az első méréskor

	\bar{M} (kg)	\bar{m}_3 (kg)	H_{m3} (kg)	h_{m3} (%)	\bar{m}_4 (kg)	H_{m4} (kg)	h_{m4} (%)
\bar{x}	2,52	2,27	0,30	14,03	2,43	0,25	12,62
σ	1,11	1,11	0,25	12,13	1,18	0,21	10,63

17. táblázat – A két közelítéssel meghatározott össztömegek és eltéréseik a második méréskor


	\bar{M} (kg)	\bar{m}_5 (kg)	H_{m5} (kg)	h_{m5} (%)	\bar{m}_6 (kg)	H_{m6} (kg)	h_{m6} (%)
\bar{x}	1,23	1,07	0,17	13,72	1,15	0,13	9,95
σ	0,31	0,32	0,13	9,28	0,35	0,12	8,25

Mindkét mérés esetében az egyes mintanövényekre nézve a 3D modell alkalmazásakor a módszer átlagos relatív hibája kisebbnek mutatkozott, mint a gömb modellel való közelítés hibája viszont a valós össztömegértékekhez képest, néhány esetben túlbecslés figyelhető meg, ami a paradicsombogyók egymás közötti átfedéséből fakadó felületkijelölési hibákra vezethető vissza. Az átlagos eltérés a valós össztömegekhez képest mindkét mérésre nézve $H_{m6} = 0,13$ kg és $H_{m3} = 0,30$ kg között volt. A mérések legkisebb relatív hibája $h_{m6} = 9,95\%$ ami a legjobb számított eredményt hozta.

4.4.4.2. A robot képeinek eredményei

Szabadszabó paradicsomkísérlet

A szabadszabó paradicsomkísérletből a robot a betakarításkor összesen 453 felvétel készített. A felvételek készítésének időzítése és száma a robot neurális hálózata alapján történő érett paradicsom detektációra alapozva történt, így az egyes mitaterületekre nézve nem egyenlő számban készültek képek. A képelemzési folyamat folyamatábrája a 66. ábrán látható.



66. ábra – A robot kamera képi adatainak kiértékelése a szabadföldes kísérletnél

Az elemzés végtermékeként megkaptuk a gömbbel ($\overline{m_7}$), és a 3D modellel ($\overline{m_8}$), való közelítés tömegadatait (17. melléklet).


Mindkét modellel való közelítés esetében a korreláció az egyes kezelésekre nézve $R^2 = 0,77 - 0,95$ közötti értékeket eredményezett (4. táblázat). Ebben az esetben is a paradicsombogyók számított tömege is negatív együtthatóval eredményezett a T4 kezelésben mért terméssel. A 18. táblázat a paradicsombogyók tömege közötti összefüggést mutatja a gömb és 3D modellel mért tömegközelítés között mindkét mérés esetében (18. és 19. melléklet)

18. Táblázat – A paradicsomtömegek korrelációja a gömb- és 3D-modellekkel az egyes kezeléseknél

Kezelések	Konstansok (közelítés gömbbel)		Konstansok (közelítés 3D modellel)		R2
	<i>a</i>	<i>b</i>	<i>a</i>	<i>b</i>	
T0	0,2518	0,858	0,2081	0,7091	0,8553
T1	0,2622	-0,1765	0,2167	-0,1459	0,8793
T2	0,4107	-0,9199	0,3394	-0,7602	0,8938
T3	0,2557	-0,296	0,2113	-0,2447	0,9582
T4	-0,6924	15,245	-0,5722	12,599	0,7764

Az összes kezelésre vonatkoztatott korreláció $R^2 = 0,907$ volt, ami magasabb érték, mint a DSRL kamera képei esetében. Ebben az esetben is mindkét közelítésnél észrevehető a T4 kezelés kiugró értéke.

A 67. ábra a kezelések alapján mért és számított tömegeket foglalja össze a terménynövekedés sorrendjében. A legtöbb öntözést kapott T4 kezelésnél a különbség is a legnagyobb, akárcsak a DSLR képek esetében. A T2-2, T1-4, T0-3 és T3-4 kezelések esetében a robot az előre meghatározott soroktól mért távolságot nagy eltérésekkel volt képes tartani (az alacsony növényzet miatt a LiDAR nem érzékelte a sorokat) ami a távolság értékek nagyfokú lengését eredményezte, így ezen kezelések esetében a tömegek meghatározása nem volt lehetséges.



67. ábra – Paradicsombogyó tömegének összehasonlítása különböző módszerek alapján az egyes kezelések növekvő hozama alapján

A 19. táblázat az előre jelzett és a valós tömegek közötti eltéréseket szemlélteti.

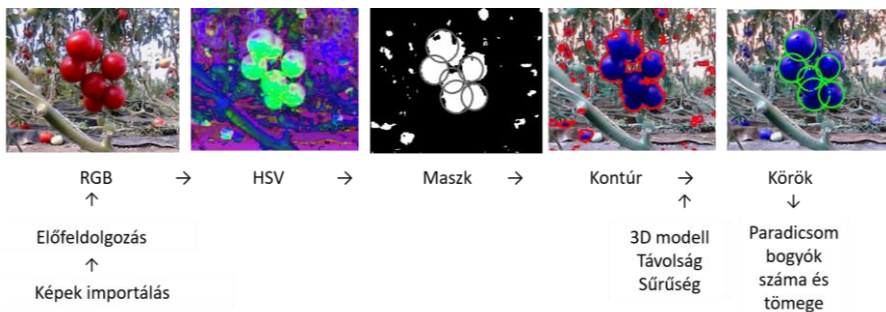
19. táblázat – A két közelítéssel meghatározott össztömegek és eltéréseik

	\bar{M} (kg)	\bar{m}_7 (kg)	H_{m7} (kg)	h_{m7} (%)	\bar{m}_8 (kg)	H_{m8} (kg)	h_{m8} (%)
\bar{x}	10,35	2,42	8,69	80,22	2,93	8,18	76,07
σ	7,59	1,98	6,18	5,84	2,39	5,80	7,07

A relatív hiba magas, $h_{m8} = 76,07\%$ és $h_{m7} = 80,22\%$ -os értékét a képrögzítési módszer okozta, amely szerint a növényállománynak csak az egyik oldalról került rögzítésre, így a többi részletről (paradicsom) nem áll rendelkezésre információ. Ezért az átlagos eltérés a valós tömegtől $H_{m7}=8,69$ kg és $H_{m8} = 8,18$ kg között volt.

Növényházas paradicsomkísérlet

A kísérlet esetében ugyanazon két időpontban a DSLR kamerával való méréssel párhuzamosan végeztük le a felvételek készítését ugyan azon 27 db mintanövényen. A képelemzési folyamat folyamatábrája a 68. ábrán látható.



68. ábra – A robot kamera képi adatainak kiértékelése a növényházas kísérletnél

A kiértékelés folyamán, a gömbbel első mérésnél \overline{m}_9 , második mérésnél \overline{m}_{11} és a 3D modellel első mérésnél \overline{m}_{10} , második mérésnél \overline{m}_{12} való közelítéssel kinyertük a paradicsom tömegeket (20. és 21. melléklet)


A 20. táblázat a paradicsom termések tömege közötti összefüggést mutatja a gömb és 3D modellekkel mért tömegközelítés között (22., 23., 24. és 25. melléklet).

20. táblázat – A paradicsomtömegek korrelációja a gömb és a 3D modellekkel való közelítéskor mindkét mérésnél


Mérés sorszáma (-)	Konstansok (közelítés gömbbel)		Konstansok (közelítés 3D modellel)		R^2
	a	b	a	b	
1. mérés	0,8141	-0,0297	0,871	0,0318	0,9029
2. mérés	0,6841	0,0427	0,732	0,0457	0,8473

A két különböző modellel való közelítés minden kezelésnél az első mérésnél $R^2 = 0,9029$, a második mérésnél $R^2 = 0,8473$ értékű korrelációt eredményezett, ami arányaiban megegyezik a DSLR kamerával való mérés korrelációs eredményeivel.

A 69. és 70. ábra az egyes mintanövényekre nézve a mért és számított tömegeket foglalja össze, a hozammennyiségek növekedésének sorrendjében.



69. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján az első méréskor



70. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján a második méréskor

A második mérés esetében a DSLR kamerás mérésnél a 11, 21, 10 és 23-as növénynél tapasztalt a valós tömeghez képesti az átlagnál nagyobb eltérés ezen mérés esetében sem figyelhető meg, amit a felvételezési módszer eltérése okozza, miszerint a kisebb felvételezési távolság és az adott mintanövényről a két különböző szögből készült felvétel nagyobb betekintést engedett a lombzat közé.

A 21. és 22. táblázat a számított és a valós tömegek közötti eltéréseket szemlélteti.

21. táblázat – A két közelítéssel meghatározott össztömegek és differenciáik az első méréskor

	\bar{M} (kg)	\bar{m}_9 (kg)	H_{m9} (kg)	h_{m9} (%)	\bar{m}_{10} (kg)	H_{m10} (kg)	h_{m10} (%)
\bar{x}	2,52	2,02	0,51	21,48	2,16	0,39	17,07
σ	1,11	0,95	0,35	12,41	1,01	0,32	12,16

22. táblázat – A két közelítéssel meghatározott össztömegek és differenciáik a második méréskor

	\bar{M} (kg)	\bar{m}_{11} (kg)	H_{m11} (kg)	h_{m11} (%)	\bar{m}_{12} (kg)	H_{m12} (kg)	h_{m12} (%)
\bar{x}	1,23	0,88	0,35	27,92	0,95	0,29	22,88
σ	0,31	0,23	0,13	7,80	0,24	0,13	8,34

Mind a két mérés folyamán a 3D modell alkalmazásakor kaptuk a kedvezőbb eredményeket. Az átlagos eltérés a valós össztömegekhez képest mindkét mérésre nézve $H_{m12} = 0,29$ kg és $H_{m9} = 0,510$ kg között volt. A mérések legkisebb relatív hibája $h_{m10} = 17,07\%$ ami a legjobb számított eredményt hozta.

A 23. táblázat a szabadföldi tömeg meghatározás összefoglaló eredményeit szemlélteti.

23. táblázat – A szabadföldi kísérlet összesítő tömegadatai

Platform (-)	Közelítés (-)	\bar{M} (kg)	\bar{m}_x (kg)	\bar{x} (kg)	H_x (kg)	h_x (%)
DSLR	Gömb	10,35	\bar{m}_1	7,10	3,42	25,52
	3D		\bar{m}_2	8,59	2,45	21,90
Robot	Gömb		\bar{m}_7	2,42	8,69	80,22
	3D		\bar{m}_8	2,93	8,18	76,07

A 24. táblázat a növényházas tömeg meghatározás összefoglaló eredményeit szemlélteti.

24. táblázat – A növényházas kísérlet összesítő tömegadatai

Mérés sorszáma (-)	Platform (-)	Közelítés (-)	\bar{M} (kg)	\bar{m}_x (kg)	\bar{x} (kg)	H_x (kg)	h_x (%)
1. mérés	DSLR	Gömb	2,52	\bar{m}_3	2,27	0,30	14,03
		3D		\bar{m}_4	2,43	0,25	12,62
	Robot	Gömb		\bar{m}_9	2,02	0,51	21,48
		3D		\bar{m}_{10}	2,16	0,39	17,07
2. mérés	DSLR	Gömb	1,23	\bar{m}_5	1,07	0,17	13,72
		3D		\bar{m}_6	1,15	0,13	9,95
	Robot	Gömb		\bar{m}_{11}	0,88	0,35	27,92
		3D		\bar{m}_{12}	0,95	0,29	22,88

4.4.5. Paradicsom bogyószám meghatározásának eredményei szabadföldi kísérletben és növényházban

A paradicsombogyók termésszámának meghatározásakor ugyanazt a képi adatkészletet használtuk fel, mint amit a tömegek meghatározásakor. A DSLR fényképező által készített felvételek esetében a bogyószám kiszámításakor ugyan azt a színek szerinti felületkijelölési eljárást alkalmaztuk, mint a tömegek meghatározásakor, míg a robot esetében a szegmentációs elemzés mellett CNN segítségével is meghatároztuk a bogyószámot.

A kísérlet kiértékelésekor megvizsgáltuk a lineáris kapcsolat mértékét a kézi méréssel meghatározott érett paradicsom szám (\bar{N}) és az alkalmazott módszer által megállapított paradicsom számok között (\bar{n}_y), amelynél a 16. számú egyenletet alkalmaztuk.

$$\mathbf{n}_y = c\bar{N} + d \quad (16.)$$

ahol, c , d , állandók, y pedig 1 – 11 között a mérés számát jelöli.

Az eredmények összehasonlítása végett meghatároztuk a mért és a számított értékek közötti eltéréseket: az összes mintára vonatkozó átlagot (\bar{x}), az összes mintára vonatkozó szórást (σ), a mérés átlagos abszolút hibáját (H), és a mérés átlagos relatív hibáját is (h).

4.4.5.1. DSLR fényképezőgép képeinek eredményei

Szabadföldi paradicsomkísérlet eredményei


A képi utóelemzés során megkapuk a számított paradicsom termésszámot ($\overline{n_1}$) az adott kezelésekre vetítve (8. melléklet).

A 25. táblázat az egyes kezelésekre nézve a lineáris kapcsolat mértékét szemlélteti ami $R^2 = 0,8831$ és $R^2 = 0,9965$ között volt. A teljes kísérletre nézve pedig az $R^2 = 0,744$ eredményt mutatott (26. melléklet).

25. táblázat – A mért és számított paradicsom termésszám korrelációja DSLR kamerás képek alapján.

Kezelések	Konstansok		R ²
	<i>c</i>	<i>d</i>	
T0	0,2192	114,33	0,9500
T1	0,9391	- 9,79	0,9966
T2	0,7075	20.896	0,9965
T3	0,2937	81,073	0,8831
T4	0,7027	- 50,422	0,9864

A 71. ábra a paradicsombogyók kézi számlálással és az elemzés által meghatározott értékeit foglalja össze a kezelési egységek alapján, a paradicsombogyók kézi számlálással meghatározott darabszámának növekedésétől függően.



71. ábra – A paradicsom termésszám összehasonlítása az egyes kezelések növekvő hozama alapján.

Az alkalmazott eljárás a T4-es kezelésben a darabszám nagymértékű alulbecslését eredményezte, amely eredmény összhangban van a kezelés paradicsom tömegének alulbecslésével.

A 26. táblázat a számított és a valós bogyószám közötti eltéréseket és azok statisztikai hibáit szemlélteti.

26. táblázat – A becsült paradicsom termésszám és eltéréseik

	\bar{N} (db)	\bar{n}_1 (db)	H_{n1} (db)	h_{n1} (%)
\bar{x}	207,55	136,65	70,90	28,57
σ	92,46	38,88	62,16	16,02

A valós darabszámtól való átlagos eltérés $H_{n1} \approx 71$ db, míg a relatív hiba átlaga $h_{n1} = 28,57\%$ -nak adódott, így a módszer nagymértékben alábecsülte a valós értéket.

 Növényházas paradicsomkísérlet

Ezen mérések esetében is meghatároztuk a számított paradicsom termésszámot első mérésnél \bar{n}_2 második mérésnél \bar{n}_3 az adott mintavételi helyekre vetítve (11. és 12. melléklet).


A 27. táblázat a lineáris regresszió eredményeit mutatja be.

27. táblázat – A mért és számított paradicsom termésszám korrelációja a robot kamerás képek alapján mindkét mérésnél


Mérés sorszáma	Konstansok		R^2
	c	d	
1. mérés	0,9839	0,092	0,9545
2. mérés	0,8135	1,7406	0,8667

A két mérés kiértékelése során meghatározott korrelációs együtthatók értéke $R^2 = 0,9545$ és $R^2 = 0,8667$ arányaiban megegyezik a mérések tömegének meghatározásakor kapott együtthatókkal (27. és 28. melléklet).

A 72. és 73. ábra a paradicsombogyók kézi számlálással és az elemzés által meghatározott értékeit foglalja össze a kezelési egységek alapján, a paradicsombogyók kézi számlálással meghatározott darabszámának növekedésétől függően.



72. ábra – A paradicsom termésszám összehasonlítása az egyes mintanövények növekvő hozama alapján az első méréskor



73. ábra – A paradicsom termésszám összehasonlítása az egyes mintanövények növekvő hozama alapján a második méréskor

A második mérés esetében úgy, mint a tömegek meghatározásának esetében a 11, 21, 10 és a 23-as mintanövényeknél szintén megfigyelhető az átlagnál nagyobb eltérés, ami a levélzet kitakarásával úgyszintén magyarázható.

A 28. táblázat a számított és a valós bogyószám közötti eltéréseket és azok statisztikai hibáit szemlélteti.

28. Táblázat – A becsült paradicsom termésszám és eltéréseik az első és második méréskor

	1. mérés				2. mérés			
	\bar{N}	\bar{n}_2	H_{n2}	h_{n2}	\bar{N}	\bar{n}_3	H_{n3}	h_{n3}
	(db)	(db)	(db)	(%)	(db)	(db)	(db)	(%)
\bar{x}	14,92	14,77	1,11	9,20	20,85	18,70	2,74	12,66
σ	7,13	7,18	1,05	8,78	8,00	6,99	2,40	8,81

A tömegek meghatározásával összhangban a bogyószámok meghatározásának a valós értéktől való eltérései is hasonló arányban jelenik meg. Az első mérés esetében az abszolút hiba átlaga $H_{n2} \approx 1$ db volt, ami $h_{n2} = 9,20\%$ átlagos relatív hibának felel meg. A pontosabb eredményeket a kordonra futtatott termesztési technológia okozta, a pontosabb detektációnak köszönhetően.

4.4.5.2. Robot képeinek eredményei

Szabadföldi paradicsomkísérlet

A képi adatkészletre alapozott a kiértékelés végén megállapítottuk a számított paradicsom termésszámot a szegmentációs eljárással (\bar{n}_4) és


a CNN-re alapozva ($\overline{n_5}$) is, az adott kezelésekre vetítve (29. táblázat, 17. melléklet).

29. táblázat – A mért és számított paradicsom termésszám korrelációja robot kamerás képek alapján minkét módszerrel


Kezelések	Konstansok (CNN elemzés)		R^2	Konstansok (Szegetmentáció)		R^2
	c	d		c	d	
T0	0,1302	13,4	0,7539	0,136	16.622	0,8333
T1	0,275	-8,8216	0,9422	0,277	-6,7166	0,6974
T2	0,1589	4,5791	0,4945	0,2784	-7,959	0,8703
T3	0,0432	27,853	0,7155	0,0962	27,756	0,6182
T4	0,278	-24,588	0,696	0,2979	-28.727	0,6813

A CNN-re alapozott termésszám meghatározás R^2 értékei 0,4945 és 0,9422 között változtak az egyes kezelésekre nézve. A szegetmentációs eljárás során az R^2 értékei 0,618 és 0,870 között voltak az egyes kezelésekre esetében. A teljes mérésre megvizsgálva az együtthatók $R^2 = 0,7849$ értéket mutatott a szegetmentációs eljárás esetében és kedvezőbb $R^2 = 0,8069$ értéket pedig a CNN elemzési mód alkalmazásakor (29. és 30. melléklet).

A 74. és 75. ábra a kézi számlálással és az elemzés által meghatározott értékeit foglalja össze a kezelési egységek alapján, a paradicsombogyók kézi számlálással meghatározott darabszámának növekedésétől függően. A legnagyobb aránybeli különbség a legtöbb öntözést kapott T4-es kezelésben számolt paradicsom számában figyelhető meg.



74. ábra – A paradicsom termésszám összehasonlítása CNN elemzés alapján a kis robotkamerás képekből



75. ábra – A paradicsom termésszám összehasonlítása szegmentáció alapján a kis robotkamerás képekből

Mindkét eljárást nagyfokú több mint 80%-os alulbecslés jellemezte. A T4-es kezelésben a DSLR fényképezővel való méréssel ellentétben nem mutatta a bogyószám nagymértékű alulbecslését. Az eredmények eltéréseinek oka úgyszintén a felvételezés módjában keresendő.

A 30. táblázat a számított és a valós bogyószám közötti eltéréseket és azok statisztikai hibáit szemlélteti.

30. táblázat – A becsült paradicsom termésszám és eltéréseik mindkét módszer alapján

Módszer	CNN elemzés				Szegmentáció			
	\bar{N} (db)	\bar{n}_4 (db)	H_{n4} (db)	h_{n4} (%)	\bar{N} (db)	\bar{n}_5 (db)	H_{n5} (db)	h_{n5} (%)
\bar{x}	207,55	41	175	84,23	207,55	44,81	171,7	83,32
σ	92,46	17,24	80,4	10,55	92,46	18,08	75,48	9,32

Mindkét eljárás vizsgálata során közel azonos átlagos hibát tapasztaltunk $H_{n4} = 175$ db és $H_{n5} \approx 172$ db értékekkel, így a relatív hiba átlaga is magas, de megközelítőleg egyenlő nagyságú $h_{n4} \approx 84$ db és $h_{n5} \approx 83$ db volt. Így a két módszer eredményei megközelítőleg azonosak, kismértékben a CNN-re alapozott módszer mutatott kedvezőbb eredményeket.

Növényházas paradicsomkísérlet

Ezen mérések esetében is meghatároztuk a számított paradicsom termésszámot két különböző módszerrel. Az első mérésnél CNN-re alapozva \bar{n}_6 , második mérésnél \bar{n}_8 , értékeket; majd első mérésnél

szegmentációra alapozva $\overline{n_7}$, második mérésnél $\overline{n_9}$, értékeket az adott mintavételi helyekre vetítve (20. és 21. melléklet).


A 31. táblázat a lineáris regresszió eredményeit mutatja be.

31. táblázat – A mért és számított paradicsom termésszám korrelációja a robot kamerás képek elemzésekor mindkét mérésnél mindkét módszer alapján


Mérés sorsszáma	Konstansok (Szegetmentáció)		R^2	Konstansok (CNN elemzés)		R^2
	<i>c</i>	<i>d</i>		<i>c</i>	<i>d</i>	
1. mérés	0,86	-0,0952	0,9145	0,6759	1,3187	0,8394
2. mérés	0,6325	0,9214	0,8526	0,6325	0,9214	0,8220

Mindkét mérés esetében a szegmentációs eljárás hozott kedvezőbb eredményeket. Az első mérés esetében $R^2 = 0,9145$ míg a második mérésnél $R^2 = 0,8394$ értéket adva az összes mintanövényre nézve (31. 32. 33. és 34. melléklet).

A 76. 77. 78. és 79. ábra a kézi számlálással és az elemzés által meghatározott értékeit foglalja össze a kezelési egységek alapján, a paradicsombogyók kézi számlálással meghatározott darabszámának növekedésétől függően.




76. ábra – A paradicsom természsám összehasonlítása az egyes mintanövények növekvő hozama alapján az első méréskor CNN elemzés alapján




77. ábra – A paradicsom természsám összehasonlítása az egyes mintanövények növekvő hozama alapján az első méréskor szegmentáció alapján

A DSLR kamerás méréssel megközelítőleg egyező nagyságú eredményeket kaptunk mindkét módszer esetében. A szabadföldi kísérlettel ellentétben nem mutattak olyan nagyfokú alulbecslést.



78. ábra – A paradicsom termés szám összehasonlítása az egyes mintanövények növekvő hozama alapján a második méréskor CNN elemzés alapján



79. ábra – A paradicsom termés szám összehasonlítása az egyes mintanövények növekvő hozama alapján a második méréskor szegmentáció alapján

A DSLR mérés esetében a 11, 21, 10 és a 23-as mintanövényeknél megfigyelhető az átlagnál nagyobb eltérés ezen mérés esetében nem jelentkezett, amely tömegmeghatározásnál jelentkező hasonló okok miatt lehetséges.

A 32. és 33. táblázat a számított és a valós bogyószám közötti eltéréseket és azok statisztikai hibáit szemlélteti.

32. táblázat – A becsült bogyószámok és eltéréseik az első mérésakor

Módszer	CNN				Szegmentáció			
	N (db)	n ₆ (db)	H _{n6} (db)	h _{n6} (%)	N (db)	n ₇ (db)	H _{n7} (db)	h _{n7} (%)
\bar{x}	14,92	11,40	3,59	23,18	14,92	12,74	2,48	18,02
σ	7,13	5,26	3,04	14,47	7,13	6,41	1,76	12,03

33. táblázat – A becsült bogyószámok és eltéréseik a második mérésakor

Módszer	CNN				Szegmentáció			
	N (db)	n ₈ (db)	H _{n8} (db)	h _{n8} (%)	N (db)	n ₉ (db)	H _{n9} (db)	h _{n9} (%)
\bar{x}	20,85	14,11	6,74	32,35	20,85	14,77	6,07	28,27%
σ	8,00	5,58	3,77	12,81	8,00	5,11	3,82	9,58%

Mindkét mérés és mindkét eljárás alkalmazásakor közel azonos átlagos hibát tapasztaltunk H_n értékei 2,48 db és 6,74 db között voltak jelen. Az átlagos relatív hiba pedig 18,02% és 32,35% között mozogtak. A 34. táblázat a szabadföldi termésszám meghatározás eredményeit szemlélteti.

34. táblázat — A szabadföldi kísérlet összesítő termésszám adatai

Elemzési módszer (-)	Platform (-)	\bar{N} (db)	\bar{n}_y (db)	\bar{x} (db)	H_y (db)	h_y (%)
Szegmentáció	DSLR		\bar{n}_1	136,65	70,90	28,57
Szegmentáció	Robot	207,55	\bar{n}_4	41	175	84,23
CNN	Robot		\bar{n}_5	44,81	171,7	83,32

A 35. táblázat a növényházás termésszám meghatározás eredményeit szemlélteti.

35. táblázat – A növényházás kísérlet összesítő termésszám adatai

Mérés sorszáma (-)	Elemzési módszer (-)	Platform (-)	\bar{N} (db)	\bar{n}_y (db)	\bar{x} (db)	H_y (db)	h_y (%)
1. mérés	Szegmentáció	DSLR		\bar{n}_2	14,77	1,11	9,20
	CNN	Robot	14,92	\bar{n}_6	11,40	3,59	23,18
	Szegmentáció	Robot		\bar{n}_7	12,74	2,48	18,02
2. mérés	Szegmentáció	DSLR		\bar{n}_3	18,70	2,74	12,66
	CNN	Robot	20,85	\bar{n}_8	14,11	6,74	32,35
	Szegmentáció	Robot		\bar{n}_9	14,77	6,07	28,27

4.4.6. Regressziós elemzés eredményei

Az R^2 érték egyértelműen mutatja, hogy a terméshozam elsősorban az öntözés mennyiségétől függ.

A 36. táblázat mutatja a regressziós elemzés eredményeit. Ha a kapott R^2 értéke nagyobb, mint 0,5, akkor a válaszváltozó és a magyarázó változó közötti kapcsolat meglehetősen magas. Az R^2 eredményei egyértelműen azt mutatják, hogy a paradicsom terméshozama nagymértékben függ az öntözés mennyiségétől.

36. táblázat – Lineáris regresszió az öntözés mennyisége és az összes vizsgált tulajdonság között (robot)

Tulajdonságok	R ²	Adjusted R ²	Unstandardized coefficients β	Standardized coefficients β
\bar{M}	0,578	0,554	0,045	0,760
\bar{m}_7	0,412	0,379	0,009	0,642
\bar{m}_8	0,479	0,450	0,047	0,692
\bar{N}	0,534	0,509	0,529	0,731
\bar{n}_4	0,532	0,506	0,096	0,729

Ebben a vizsgálatban az öntözési mennyiség minden tulajdonságnál pozitív értékkel bír a regressziós együtthatóra, a legmagasabb érték (mért paradicsom tömeg) az \bar{M} -hez kapcsolódott, e tulajdonság varianciájának közel 58%-a az öntözési mennyiség különbségével magyarázható, ill. a β érték azt jelzi, hogy az öntözés mennyiségének egy egységnyi növekedése 0,045-ös növekedésnek felel meg ebben a tulajdonságban (37. táblázat).

37. táblázat – Lineáris regresszió az öntözés mennyisége és az összes vizsgált tulajdonság között (DSLR fényképezőgép)

Tulajdonságok	R ²	Adjusted R ²	Unstandardized coefficients β	Standardized coefficients β
\bar{M}	0,578	0,554	0,045	0,760
\bar{m}_1	0,505	0,478	0,024	0,711
\bar{m}_2	0,505	0,478	0,029	0,711
\bar{N}	0,534	0,509	0,529	0,731
\bar{n}_1	0,570	0,546	0,222	0,755

A DSLR fényképezőgép esetében az öntözési mennyiség pozitív értéket mutat a regressziós együtthatóra minden tulajdonságnál, a legmagasabb érték \bar{M} -hez és \bar{n}_1 -hez tartozott, ezen tulajdonságok varianciájának közel 57% az öntözési mennyiség különbségével magyarázható, a β érték pedig azt jelzi, hogy az öntözés mennyiségének egy egységnyi növekedése 0,045, illetve 0,222 növekedésnek felel meg ezekben a tulajdonságokban.

5. KÖVETKEZTETÉSEK, JAVASLATOK

5.1. Robot fejlesztés

A kutatómunka során egy olyan szabadföldi és növényházas termesztési technológia mellett is működőképes robot rendszert terveztünk és fejlesztettünk ki, ami beleilleszkedik a precíziós mezőgazdasági technológia feltételrendszerébe, segíti és kiegészíti az adatgyűjtést, feldolgozást, és a beavatkozást különböző szenzorokat és IoT adatkommunikácót is felhasználva, saját fejlesztésű hardveres és szoftveres háttérrel. Az integrált érzékelők a környezetből, talajból gyűjtenek adatokat, az RGB kameraképek elemzésével neurális hálózatokra épülő mesterséges intelligencia képes észlelni a növényi részeket és elváltozásait, valamint ezekről tájékoztatni a robotkezelőt.

A robot kialakítása során törekedtünk a kompakt méretre az egyszerűsége és a költséghatékonyságra úgy, ahogy PRAMOD és JITHINMON (2019) tanulmányában is tette. Hasonló célú és kialakítású robotról ír OTA et al. (2018) cikkükben, amely robot célja a paradicsom termés érési faktorának meghatározása (hozambecslés), viszont a robot eltérésként betakarításra is képes. A paradicsom érettségének klaszterezésére SEO et al. (2021) is hasonló berendezést fejlesztett, a környezeti monitoring a paradicsom termés érettségi fokának megállapítása. OUYANG et al. 2022-es munkájában egy nagyobb méretű viszont célját tekintve egybevágó robotot alkottak, ami betakarításra is képes gépi tanulási technikát felhasználva.

További fejlesztési javaslatunk az eddigi paradicsom vizsgálatok kitejesztése, tág sorállás kultúrnövényekben való alkalmazása (pl.: kukorica). A szenzorálás lehetőségek kibővítése (pl.: NIR) valamint, só, mező és mikorelem detektálása, illetve más innovatív érzékelők: elektronikus fül, orr alkalmazása.

5.2. Paradicsom termés 3D modellezése

A 3D szkennelés folyamata során egy szabad forráskódú, általunk épített hobbi célokra tervezett szkennert alkalmaztunk, amelynek szerkezeti elemeit 3D nyomattatással készítettünk el, illetve szereltünk össze, így alkatrészei nem analitikai eszközök. Igaz a berendezés rendelkezik kalibrációs eljárásokkal, amelyek a kialakításból adódó hibákat is igyekeznek megszüntetni, viszont ezen hibák teljes eliminálását nem teszik lehetővé. A berendezés működtetése közben a forgó platformra helyezett tárgyat a pontos letapogatás miatt a tárgyasztal közepére kell helyezni, mivel a kalibráció ilyen elhelyezés esetében szolgáltat megfelelő eredményt, éppen ezért a szkennelést több ismétlésben végeztük el, amely közül a kézi mérésekhez legjobban illeszkedőt választottuk ki. A paradicsom bogyók valós térfogatának meghatározásakor analitikai mérleggel határoztuk meg a tömegüket, illetve a bogyókat víz alá merítve a kiszorított víz térfogata segítségével a térfogatukat, utóbbi mérés esetében a kiszorított víz tömegének meghatározása nagyfokú hibákkal terhelt.

A 3D modellalkotás folyamán a szkennert által generált pontfelhőt a feldolgozó MeshLab szoftver segítségével egy zárt felületet hoztunk létre. A folyamat során mivel a pontfelhő egyes régiói nem folytonosak

a szkennel számára nem látható részeken így ezeken a részeken a felület rekonstrukció nem követi kielégítően a valós felületet. Ezen hibák okozzák a valós ténfogatától való eltérést.

5.3. Kalibrációs módszerek

A képi adatgyűjtés és feldolgozás elengedhetetlen összetevői a kalibrációs eljárások, amelyek egyrészt a felvételek optikai, színi hibáit küszöbölik ki, másrészt a képeken lévő objektumok valós tulajdonságait (méretek, felület, stb.) szolgáltatják.

Kijelenthető, hogy a dolgozatban bemutatott lencsetorzítást megszüntető módszer alkalmazása, amit CAI (2011) tanulmányukban is alkalmazott javított a színszegmentációs eljáráson.

A színi vizsgálatok eredményei alátámasztják, hogy egy felvételen egy szintartomány pontos kijelöléséhez elengedhetetlen a megfelelő színintervallum megadása. Megállapítható, hogy az alkalmazott intervallum megfelelőnek bizonyult a felületelemek kijelöléséhez, amely összhangban van LIU et al. (2019) írt tanulmányával. Ugyanakkor, ahogy QINGCHUN et al. (2014) is kijelenti, hogy a színintervallum mellett fontos szerepe van a megfelelő mértékű megvilágításnak is.

A felvételeken jelenlévő objektumok (paradicsombogyók) valós tulajdonságainak meghatározásához (vetületi felület) a vizsgálatok során kialakított metrika megfelelőnek bizonyult a valós vetítési méretek meghatározásához, ahogy MUSTAFFA et al. (2017) munkájukban is említik. Fontosnak tartjuk megjegyezni, hogy a módszer a távolság mérés nagyfokú pontosságán alapul, az alkalmazott

közelítés hiperbolikus jellege miatt (45. ábra) kis távolságoknál a pontatlan mérések nagymértékű hibát generálnak. Optimális esetben az elkészített felvételek sorra azonos távolságokban vannak a képrögzítő eszköztől.

Arra a következtetésre jutottunk, hogy az alkalmazott korrekciós eljárások továbbfejlesztése mellett úgy, mint mesterséges megvilágítás alkalmazása pontosíthatók a becslési módszerek.

5.4. Machine learning alapú paradicsom detektáció

A gépi tanulás alapú Tensorflow platformot felhasználó érett paradicsom termés felismerésére képes modell a validációs adatkészlete alapján 92,9% pontossággal működött, ami alacsonyabb, mint a WAN et al. (2018) által használt módszernél, amely 99,31% volt, viszont magasabb XIANG (2018) értékénél is, amely 91,67% volt.

ZHOU et al. (2017) kimutatta, hogy a hagyományos CNN modellhez képest a teljesítmény nagymértékben javítható a Fast R-CNN modell alkalmazásakor a paradicsom részeinek azonosítására. SUN et al. (2020) munkájukban az átlagos pontosság 90,7-ről 99,5%-ra javult ezen modell alkalmazásával.

A CNN képzéséhez használt 924 kép nagyságrendileg egyezik LIU (2018) és SUN et al. (2020) tanulmányában használt képek számával.

Az Edge Impulse alkalmazásban a modell létrehozásakor a létrehozni kívánt osztályokat az egyes képeken manuális módszerrel kell meghatározni, jelölőnégyzettel kijelölve a kép azon részét ahol az adott osztályba tartozó részlet található. A kijelölés pontossága

nagymértékben befolyásolja a validációs adatkészleten és a további alkalmazásokon tapasztalt pontosságot. A kamera rendszer felbontása ezt a kijelölést megnehezítette, ennek köszönhető a validációs adatokon tapasztalt pontosság csökkenése.

Az alkalmazott neurális hálózat működése során négyzet alakú képeket vár el, mint bemenő információ, amelynek felbontása igaz, hogy nagyobb értéket is, akár 320×320 pixelt is felvehet, viszont ebben az esetben a detektáció futási ideje drasztikusan megnő. A kutatómunka a kifejlesztett rendszer hardveres és szoftveres elemeire fókuszál, amelynek korlátait figyelembe véve ezen felbontás mellett képes megfelelően működni a detektáció. Emellett más típusú neurális hálózatok alkalmazása esetén, mint pl. egy nagyon kompakt YOLOv5 modell, amelyet szintén nagyon alacsony felbontású bemeneti képpel kombinálva (300px-nél kisebb), még 8 bites kvantálás esetén sem érhető el 4-5 FPS-nál nagyobb sebesség, amit ASHFAQ et al. (2022) munkája is alátámaszt. A neurális hálózatok esetleges hardveres gyorsítása viszont drága kompromisszumot jelent a pontosság rovására, így ezen megoldások alkalmazása nem jelentene előnyt a jelenleg alkalmazottal szemben, amit a gyors, on-the-go (real-time) módszerek és a precíziós növénytermesztés feltételrendszere megköveteli.

5.5. Paradicsom termésszámlálás és becslés

A paradicsom termésszám meghatározás érdekében két különböző képrögzítő platformot és két különböző roncsolásmentes adatelemzési stratégiát alakítottunk ki. Az alkalmazott módszert vizsgálva a machine learning esetében kaptunk jobb eredményeket mindkét kísérleti

területet nézve. Mindkét mérési területen a robot által rögzített képek esetében a szegmentációs és a machine learning módszer közötti eltérés átlagosan 3,38%, külön vizsgálva a két kísérleti területet az eltérés szabadföldön 0,91% míg növényházban 4,62%. A két képrögzítési módszer között az eltérés mindkét kísérleti területet nézve nagyfokú 28,08%, a növényházban végzett méréseknél az átlagos eltérés 14,52% a szabadföldi kísérletnek pedig nagyobb 55,20%.

A paradicsomtermés terméshozam becslése érdekében a fenti platformok felvételeit használtuk, valamint Ciclops 3D szkener segítségével 3D modellezést végeztünk. HERRERO-HUERTA et al. (2015) úgyszintén 3D modellezési technikát alkalmazott hozambecslési célra, viszont on-the-go módon szőlőültetvényeknél. Az így elkészült modell minden esetben a legjobb becslést adta a gömb modellel való közelítéssel ellentétben. A tömeg meghatározás eltérése a két modell között és mindkét kísérletre nézve átlagosan 3,73%-nak adódott. A szabadföldi kísérlet esetében az eltérés átlagosan 3,88% míg a növényház esetében alacsonyabb érték 3,67% adódott. Az eredmények alapján kijelenthető, hogy az alkalmazott 3D modellezési módszer javított a hozambecslés eredményein. A szabadföldi kísérlet esetében a két különböző platformról származó eredmények között nagymértékű átlagos 54,43% eltérés figyelhető meg, míg a növényházas vizsgálat eredményei között átlagosan 7,80% az eltérés. Az eltérések elsődleges oka a termesztéstechnológiában, a lombozat okozta elzáródásokban keresendő. A kísérleti helyszínek esetében a DSLR fényképezőgép által készített képek nyújtottak jobb eredményeket. A szabadföldi kísérlet esetében a paradicsom tömegét a DSLR fényképezőgép képein

21,90%-os relatív hibával és 17,96%-os szórással adta meg, míg a növényházas kísérlet esetében a 9,95%-os relatív hibával és 8,25%-os szórással adta meg.

A két modellre alapozott megközelítés között a legfőbb különbség a meghatározáskor alkalmazott térfogatok közelítése, ami az egyik esetben a paradicsom bogyókhöz illesztett gömb térfogata, a másik esetben ehhez a gömbhöz a legkisebb négyzetek módszerével kapcsolt 3D modell térfogatának aránya, amely befolyásolja a tömegmérésnél az adott felületelemhez meghatározott tömegek nagyságát. Ez a gömb modell esetében a 3D modellhez képest alulbecslést eredményezett, aminek az okát a paradicsom bogyók átfedései, valamint a levélzet kitakarásával magyarázható. Mivel minden felületelemhez külön kerül kiszámításra a tömeg nagysága, amely a program futásának a végén összegződik, így az eredmények eltolódnak a térfogataránytól, mint korrekciós együtthatótól függően, ezzel együtt az átlag és szórásértékek is, viszont a determinációs együttható értéke nem változik meg. Tehát a 3D modell alkalmazása pontosította a hozambecslés eredményét, így a tömegmérés pontosságát befolyásoló tényezője nem csak a bogyók felismerése, pontos detektációja, hanem az alkalmazott modell, és ez által a térfogat közelítésének módszere is.

A mért és becsült terméshozam, valamint a paradicsom termésszáma közötti összefüggés becsülésére használt közelítő módszerek összességében alulszámolták a bogyók tömegét és számát. Ennek oka a felvételezés módjában rejlik, miszerint a robot által készített képek nem tartalmazzák az összes képi információt a paradicsombogyókról. A szántóföldi paradicsom lombkoronaszerkezete hiányos pontokat

eredményezett a paradicsom kimutatásban. Ennek okai a robot által csak az egyik oldalról készített felvételek voltak. A kézi kamera esetében a nagyobb hatótáv miatt (a sorok felülről fényképezve) pontosabb értékek voltak.

A becsült paradicsom termésszámának, tömegének és a kézi méréssel meghatározott R^2 értékei kisebbek voltak, mint BINI et al. (2022) és munkatársai cikkében, ami 0,98 volt. Ez különösen igaz volt a T4-es kezelésben, ahol a nagyobb levélfelületet (biomasszát) a legnagyobb öntözési mennyiség eredményezte. Ezeknél a kezeléseknél a paradicsom terméséről nem állt rendelkezésre elegendő képi információ.

Ezenkívül az öntözés mennyisége pozitív regressziós együtthatóval rendelkezik minden tulajdonságra vonatkozóan; a legmagasabb érték a mért paradicsom tömege volt, ami azt jelenti, hogy ezen tulajdonság varianciájának közel 58%-a az öntözési mennyiség különbségével magyarázható a robotképek esetében. Minden tulajdonságnál az öntözés mennyisége pozitív regressziós együtthatóval is bírt a DSLR fényképezőgép esetében is. Az R^2 érték azt jelzi, hogy az eltérés közel 57%-a az öntözési mennyiség különbségével magyarázható.

Emellett más kutatások elsősorban az üvegházban termesztett paradicsomra fókuszálnak (KIM et al., 2022), mivel ez fontosabb és relevánsabb, mint az ipari szabadföldi termesztés. A szabadföldi kutatások a távérzékelési megközelítést helyezik előtérbe, mindenekelőtt a drónok és a vegetációs indexek alkalmazását (TATSUMI et al., 2022; LILLO-SAAVEDRA et al., 2022).

Véleményünk, hogy ezen becslési-technológiák kidolgozása és gyakorlati adaptációja még számos megfigyelést és mindenekelőtt pontos adatfeldolgozást igényel, elsősorban a felületleképezési módszer lehető legpontosabb távolságmérését.

6. ÖSSZEFOGLALÁS

A precíziós gazdálkodás modern technológiai eszközökkel optimalizálja a termelési folyamatokat, amivel a kockázati tényezők hatása is csökkenthető. A környezeti állapotjelzők folyamatos monitorozása hálózatba kötöten, különböző érzékelők segítségével valósítható meg. A célzott beavatkozások a megfelelő adatok rendelkezésre állásán alapulnak. A közeljövőben a jelenleg használt rendszereket felváltják az emberi beavatkozást nem igénylő autonóm rendszerek, amelyek egyre több szenzorrendszerrel szerelhetők fel. Emellett a jelenleg használatos telepített (fix helyzetű) adatgyűjtő rendszereket mobil szenzorhálózatok váltják fel.

A dolgozatban egy kisméretű mobil adatgyűjtő robotot fejlesztettünk ki a precíziós mezőgazdaság számára mind szabadföldi, mind üvegházi technológiákban a paradicsomnövény érzékelésére, különböző szenzorokkal, saját fejlesztésű hardveres és szoftveres háttérrel. A hardver és szoftver fejlesztés körülbelül két évig tartott, ezalatt a berendezés elérte jelenlegi állapotát. A robot tetszőleges időközönként képes automatikusan információkat gyűjteni a talajról és a paradicsomnövényekről. Az érzékelők a környezetből gyűjtenek adatokat beleértve a globális sugárzást, a páratartalmat, a hőmérsékletet, a légköri nyomást, a talaj nedvességtartalmát és hőmérsékletét, valamint a talaj változóit. Az RGB kameraképek elemzésével neurális hálózatokra épülő mesterséges intelligencia képes észlelni a növényi részek változásait és tájékoztatni a robotkezelőt. Ez a módszer az Edges Impulse platformon keresztül létrehozott neurális hálózati modellt használta. A készülék valós időben képes megállapítani

a levél elváltozásokat. A kamera vagy másodpercenként készít képet, vagy ha érzékeli az érett paradicsomnövényeket és eltárolja azokat. Egy másik képelemzési módszerrel a készített képeket felhasználva OpenCV analízist használva a LiDAR-ral mért termény és a kamera közötti távolság adatok, és a termény fizikai tulajdonságai felhasználhatóak a paradicsomtermés becslésére. Validáció miatt egy DSLR kamerával is készítettünk felvételeket a paradicsom növényekről. Ezt követően a rögzített képeket szegmentáltuk az előzetes megállapított HSV értékek alapján a kameralencse-korrekción és a távolságkalibráció alkalmazása után watershed algoritmust alkalmazva. A pontos paradicsomtermés-modell javítása és a terméshozam becslése érdekében Ciclops 3D szkennelvel letapogattuk a paradicsom termését majd ez alapján a legjobban illeszkedő 3D-s modell előállítottuk. Végül a DSLR és a robotkamera fényképei alapján kiszámítottuk a paradicsombogyók számát és tömegét.

A fent említett robot a HRI (Human Robot Interaction) előnyeit használja a levélmintavétel biztosítására. Továbbá az érzékelőpark innovatív szenzorokkal (hiperspektrális kamerák, műnyelv, elektronikus orr, akusztikus szenzorok) bővíthető. A ma használatos nagy és energiaigényes berendezéseket felválthatják az adott munkafolyamatot megosztó kisméretű berendezések. A térbeli teljesítménytényezőket és a fenntarthatósági szempontokat figyelembe véve a robotok együttműködnek egymással és "mester-szolga" kapcsolatban működnek. Az összegyűjtött adatok visszamenőleg is elérhetőek lesznek a "big data" adatsorok segítségével, amelyek a mesterséges intelligencia (AI) segítségével adaptívan alkalmazkodó

robotok adatbázisát alkotják majd, stabil mérőállomások adataival kiegészítve. A mezőgazdasági termelés korszerű ökológiai hatékonysága és termelékenysége csak olcsó, kicsi, intelligens és megbízható adatgyűjtő robotokkal növelhető. Ez jelentősen növeli a rovarok és mikroorganizmusok támadásainak előrejelzésének hatékonyságát.

7. TÉZISEK

1. Igazoltam, hogy a hibákkal terhelt képi információk esetében alkalmazott kalibrációs módszerek során meghatározott színszegmetációs intervallum az érett paradicsombogyók esetében pontos kijelölést eredményez, 3000 lx-nál nagyobb értékű megvilágítás esetében.
2. Bizonyítottam, hogy a kialakított pixel/metrika felhasználásával és az objektum távolságának LiDAR alapú mérésével az objektum távolságába állított párhuzamos síkra vetített objektum felületének nagyságának meghatározásával, valamint előzetes 3D szkennelésre alapozott 360° -ban letapogatott paradicsom fajták modellalkotásával szabadföldi és zárt természetstechnológia mellett is termésbecslés végezhető el.
3. Igazoltam, hogy a vizsgált körülmények között az alkalmazott 3D szkennelési technológiával készült paradicsom fajta korrekciós modellek átlagosan 3,73%-kal pontosabb termésbecslést tesznek lehetővé, mint a paradicsom termések gömbbel való alaktani közelítése.
4. Igazoltam, hogy a robot által gyűjtött képi információk esetében a paradicsom növényi részeinek klaszterezésére és számlálására kialakított 8 bites kvantálással rendelkező konvolúciós neurális 5 FPS adatfeldolgozási kapacitása mellett 23,18%-os relatív hibával on-the-go működtethető, valamint ugyanezen képi adatok gépi látás alapú termésszám

meghatározása a neurális hálózathoz képest kis, átlagosan 7,25 %-os eltéréssel működött.

5. Igazoltam, hogy azonos beállítások és gépi látás alapú feldolgozás mellett, a 12,2 Megapixeles 22,2×14,8 mm szenzorméretű digitális tükörreflexes fényképezőgép által készült képek a robot 1,3 Megapixeles 3,00×4,32 mm szenzorméretű kamerája által készült képekhez képest minden mérés esetében átlagosan 28,08%-kal jobb eredményt hoztak. Ezzel bizonyítottam, hogy a képfelvételezési eljárás nagymértékben befolyásolja a paradicsom termésszám és termésmennyiség becselő eljárásokat.

A GYAKORLATNAK ÁTADHATÓ EREDMÉNYEK

1. Hardveresen és szoftveresen továbbfejlesztettem, valamint szenzorokkal és aktuátorral kiegészítettem, egy a precíziós mezőgazdaságban alkalmazható kereskedelmi forgalomban is kapható nyílt forráskódú robotot.
2. A továbbfejlesztett robottal begyűjtött eredmények azt mutatják, hogy a rendszer alkalmazható szabadföldi és zárt termesztési technológia mellett is. A moduláris felépítés adta lehetőségek miatt, adatgyűjtésre és beavatkozásra is egyaránt alkalmazható és bővíthető. Az adatok felhőalapú tárolásának köszönhetően beilleszthető a modern precíziós technológiákba.
3. A nagy adatalapú növekedési és előrejelzési modellek mesterséges intelligencián alapulnak, ehhez nyújt támogatást a kifejlesztett robot.
4. A 3D szkennelési eljárás a terméselőrejelzés pontosításához alkalmas, akár más növények esetében is.
5. Kutatásaim során a precíziós növénytermesztésben alkalmazható távérzékelési, adatgyűjtési, szenzorálási és robotika témakörben olyan fejlesztést hajtottam végre, mely kertészeti kultúrákban bizonyítottan alkalmazható, és további K+F innovációk alapja lehet.

8. KÖSZÖNETNYILVÁNÍTÁS

Mindenekelőtt köszönetemet fejezem ki témavezetőimnek, **Dr. Nyéki Anikó** docens asszonynak, és **Dr. Teschner Gergely** adjunktus úrnak, akik szakmai tanácsaikkal és iránymutatásukkal segítették a disszertáció elkészítését, valamint doktori tanulmányaim során biztosították számomra a kutatási feltételeket fokozatom megszerzéséhez.

Köszönöm opponenseimnek, hogy a mindenre kiterjedő javaslataikkal, tanácsaikkal, értékes bírálatukkal segítették a dolgozat elkészítését.

Köszönettel tartozom a Biológiai Rendszerek és Precíziós Műszaki Tanszék minden munkatársának. Kiemelt köszönettel tartozom **Prof. Dr. Neményi Miklós** akadémikus és **Dr. Kovács Attila József** tanszékvezető docens úrnak munkám támogatásáért.

Köszönetemet szeretném kifejezni a Magyar Agrár- és Élettudományi Egyetem, Kertészettudományi Intézetének munkatársainak **Prof. Dr. Helyes Lajos** akadémikus, **Dr. Pék Zoltán** egyetemi tanár és **Dr. Takács Sándor** tudományos munkatárs úrnak a szabadföldi kísérletben nyújtott segítségükért.

Köszönetemet szeretném kifejezni a **Ranyák kertészetnek**, hogy biztosították a lehetőséget a növényházban történő vizsgálataimhoz.

Végül, de nem utolsósorban, hálával tartozom családomnak, szüleimnek, testvéremnek tanulmányaim során nyújtott önzetlen támogatásukért; valamint barátaimnak, akik bátorítottak doktori fokozatom megszerzése alatt.

9. IRODALOMJEGYZÉK

1. Adamchuk, V.I., Hummel, J.W., Morgan, M.T., Upadhyaya, S.K., (2004). On-the-go soil sensors for precision agriculture. *Computers and Electronics in Agriculture*, 44 (1), 71–91. <https://doi.org/10.1016/j.compag.2004.03.002>
2. Adisa, O. M., Botai, J. O., Adeola, A. M., Hassen, A., Botai, C. M., Darkey, D., Tesfamariam, E. (2019). Application of Artificial Neural Network for Predicting Maize Production in South Africa. *Sustainability*, 11(4). <https://doi.org/10.3390/su11041145>
3. Aghi, D., Mazzia, V. Chiaberge, M. (2020). Local Motion Planner for Autonomous Navigation in Vineyards with a RGB-D Camera-Based Algorithm and Deep Learning Synergy. *Machines*, 8 (2). <https://doi.org/10.3390/machines8020027>.
4. Ahmad, U., Nasirahmadi, A., Hensel, O., Marino, S. (2021). Technology and data fusion methods to enhance site-specific crop monitoring. *Agronomy*, 12, 555.
5. Ahmadi, A., Nardi, L., Chebrolu, N., Stachniss, C. (2020). Visual servoing-based navigation for monitoring row-crop fields. In: 2020 IEEE Int Conf on Robotics and Automation (ICRA). IEEE, pp.4920–4926.
6. Allegra, D., Gallo, G., Inzerillo, L., Stanco, F. (2016). Low Cost Handheld 3D Scanning for Architectural Elements Acquisition. Conference: Smart Tools and Apps in computer Graphics (STAG) At: Genova, Italy. DOI:10.2312/stag.20161372
7. Altena, van, F., W., Lee, T., J., Hoffleit, D., E. (1995). The general catalogue of trigonometric [stellar] parallaxes. 4th ed Yale University

8. Amershi, S., Begel, A., Bird, C., 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 - 27, 2019, Pages 291-300.
9. Amobi, O. (2019). Introduction to robotics. Unirobotica Inc., Pasadena
10. Angin, P., Anisi, M.H., Goksel, F., Gursoy, C., Büyükgülcü, A. (2020). AgriLoRa: A Digital Twin Framework for Smart Agriculture, Journal of Wireless Mobile Networks, Ubiquitous Computing, and Dependable Applications 11(4), pp. 77-96.
11. Angkawinitwong, U., Williams, G.R. (2021). Electrospun materials for wearable sensor applications in healthcare. In: Electrospun Polymers and Composites. Elsevier Ltd. <https://doi.org/10.1016/b978-0-12-819611-3.00013-3>
12. 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 DOI:10.1016/j.procs.2016.03.055
13. 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.
14. Asari, V. (1999). A new approach for nonlinear distortion correction in endoscopic images based on least squares estimation. IEEE Transactions on Medical Imaging, 18(4).
15. Assirelli, A., Liberati, P., Santangelo, E., Del Giudice, A., Civitarese, V., Pari, L. (2015). Evaluation of sensors for poplar cutting detection

- to be used in intra-row weed control machine. *Computers and Electronics in Agriculture*, 115, 161-170.
16. Ashfaq, Q., Akram, M. U. (2022). Convolutional Neural Network Based Thermal Image Classification. Conference: 2022 2nd International Conference on Digital Futures and Transformative Technologies (ICoDT2). DOI:10.1109/ICoDT255437.2022.9787443
17. Åstrand, B., Baerveldt A. (2002). An Agricultural Mobile Robot with Vision-Based Perception for Mechanical Weed Control, *Autonomous Robots* 13, pp. 21–35.
18. Azmi, H.N., Hajjaj, S.S.H., Gsangaya, K.R., Sultan, M.T.H., Mail, M.F., Hua, L.S. (2021). Design and fabrication of an agricultural robot for crop seeding. *Materials Today: Proceedings*. <https://doi.org/10.1016/j.matpr.2021.03.191>
19. Bar-On, L., Peradotto, S., Sanginario, A., Ros, P. M., Shacham-Diamand, Y., Demarchi, D. (2019). In-vivo monitoring for electrical expression of plant living parameters by an impedance lab system. In 2019 26th IEEE International Conference on Electronics, Circuits and Systems (ICECS) (pp. 178-180). IEEE.
20. Bártfai, Z., Blahunka, Z., Bognár, I., and Faust, D. (2018). Robotok a mezőgazdaságban. *MEZŐGAZDASÁGI TECHNIKA* 59, 10, 2–7.
21. Bechar, A., Vigneault, C. (2017). Agricultural robots for field operations. Part 2: Operations and systems. *Biosystems Engineering* 153:110-128 DOI: 10.1016/j.biosystemseng.2016.11.004
22. Becvarik, M., Devetsikiotis, M. (2016). Modeling of user quality of experience in location aware smart spaces. *Digital Media Industry & Academic Forum (DMIAF)*, 207–212.

23. Beraldin, J.A., Blais, F., Lohr, U. (2010). Three Dimensional Laser Scanning Technology. n book: Airborne and terrestrial laser scanningChapter: 1Publisher: Whittles Publishers (Scotland, UK)Editors: G. Vosselman, H.-G. Mass
24. Berge, T. W., Goldberg, S., Kaspersen, K., Netland, J. (2012). Towards machine vision based site-specific weed management in cereals. *Computers and electronics in agriculture*, 81, 79-86.
25. Bernacki, J. (2020). A survey on digital camera identification ethods. *Forensic Science International: Digital Investigation*, 34, 300983. <https://doi.org/10.1016/j.fsidi.2020.300983>
26. Bietresato M, Carabin G, Vidoni R, Gasparetto A, Mazzetto F (2016). Evaluation of a LiDARbased 3D-stereoscopic vision system for crop-monitoring applications. *Comput Electron Agric* 124:1–13. <https://doi.org/10.1016/j.compag.2016.03.017>
27. Bini, D., Pamela, D., Mary, T.B., Shamia, D., Prince, S. (2022). Intelligent Agrobots for Crop Yield Estimation using Computer Vision. *CAMES*, 29(1–2): 161–175.
28. Blackmore, S. (2013). *Robotic Agriculture; Designing systems for the farm of tomorrow*, Harper Adams University
29. Blackmore, S. (2017). Professor Simon Blackmore interview robotics in agriculture (Tharsus). *Landwards Volume 72*. (2).
30. Boada, J.,P., Maestre, B.,R., Genís, C.,T. (2021). The ethical issues of social assistive robotics: A critical literature review. *Technology in Society*, 67, 101726. <https://doi.org/10.1016/j.techsoc.2021.101726>
31. Bossu, J., Gée, C., Jones, G., Truchetet, F. (2009). Wavelet transform to discriminate between crop and weed in perspective agronomic images. *computers and electronics in agriculture*, 65(1), 133-143.

-
32. Botta, A., Cavallone, P., Baglieri, L., Colucci, G., Tagliavini, L., Quaglia, G. (2022). A Review of Robots, Perception, and Tasks in Precision Agriculture. *Applied Mechanics*, 3 (3), 830–854. <https://doi.org/10.3390/applmech3030049>
33. Bousbih, S., Zribi, M., Pelletier, C., Gorraab, A., Lili-Chabaane, Z., Baghdadi, N., Aissa, N. B., Mougnot, B. (2019). Soil Texture Estimation Using Radar and Optical Data from Sentinel-1 and Sentinel-2. *Remote Sensing*, 11 (13). <https://doi.org/10.3390/rs11131520>
34. Brand, P., Mohr, R., Bobet, P. (1993). Distorsions optiques: correction dans un modele projectif (Doctoral dissertation, INRIA).
35. Bryson, J.J. (2013). Modularity and Specialized Learning: Reexamining Behavior-Based Artificial Intelligence
36. Burd, N.C., Dorey, A.P., (1984). Intelligent transducers. *Journal of Microcomputer Applications*, 7(2), 87–97. [https://doi.org/10.1016/0745-7138\(84\)90093-9](https://doi.org/10.1016/0745-7138(84)90093-9)
37. Burton, L., Dave, N., Fernandez, R.E., Jayachandran, K., Bhansali, S. (2018). Smart gardening IoT soil sheets for real-time nutrient analysis. *J. Electrochem. Soc.* 165 (8), B3157–B3162. <https://doi.org/10.1149/2.0201808jes>.
38. Cai, J. (2011). Novel Image Segmentation Based on Machine Learning and Its Application to Plant Analysis *International Journal of Information and Electronics Engineering* DOI:10.7763/IJIEE.2011.V1.12
39. Cao, P. M., Hall, E. L., Zhang, E. (2003). Soil Sampling Sensor System on a Mobile Robot. *Proceedings of SPIE - The International Society for Optical Engineering* DOI:10.1117/12.516367
-

-
40. Castanedo, F. (2013). A Review of Data Fusion Techniques. Hindawi Publishing Corporation. The Scientific World Journal 2013(6):704504. DOI:10.1155/2013/704504
 41. Centin, M., Pezzotti, N., Signoroni, A. (2015). Poisson-driven seamless completion of triangular meshes. Computer Aided Geometric Design 35-36 DOI:10.1016/j.cagd.2015.03.006
 42. Chaitanya, P., Kotte, D., Srinath, A., Kalyan, K.B. (2020). Development of Smart Pesticide Spraying Robot, International Journal of Recent Technology and Engineering 8(5), pp. 2193-2202.
 43. Chamara, N., Islam, M. D., Bai, G. (Frank), Shi, Y., Ge, Y. (2022). Ag-IoT for crop and environment monitoring: Past, present, and future. Agricultural Systems, 203, 103497. <https://doi.org/10.1016/j.agry.2022.103497>
 44. Cheein, F. A., Steiner, G., Paina, G. P., Carelli, R. (2011). Optimized EIF-SLAM algorithm for precision agriculture mapping based on stems detection. Computers and electronics in agriculture, 78(2), 195-207.
 45. Chiang, C., Tran, D., Camps, C. (2023). ASPEN study case: real time in situ tomato detection and localization for yield estimation. Research Square Platform LLC. Research Square. Retrieved July 3, 2023, from <https://www.researchsquare.com/article/rs-2771756/v1>
 46. Cho, SI, Lee, D.S., Jeong, J.Y., (2002). AE—automation and emerging technologies:weed–plant discrimination by machine vision and artificial neural network. Biosyst Eng 83:275–280. <https://doi.org/10.1006/bioe.2002.0117>
 47. 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.
48. 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 DOI:10.5424/sjar/2012102-368-11
49. Cosman, S. I., Bilatiu, C. A., Marțiș, C. S. (2019). Development of an automated system to monitor and control a greenhouse. In 2019 15th International Conference on Engineering of Modern Electric Systems (EMES) (pp. 1-4). IEEE.
50. Cubero, S., Marco-Noales, E., Aleixos, N., Barbé, S., Blasco, J. (2020). RobHortic: A Field Robot to Detect Pests and Diseases in Horticultural Crops by Proximal Sensing. *Agriculture*, 10(7). <https://doi.org/10.3390/agriculture10070276>
51. Csiba, M. (2010). Mérési módszerek fejlesztése precíziós növénytermesztési technológiáknál. PhD disszertáció. Témavezető: Prof. Dr. Neményi Miklós és Dr. Kovács Attila József. Nyugat-magyarországi Egyetem, Mosonmagyaróvár.
52. Daosawang, W., Wongkalasin, K., Katewongsa, N. (2020). A study sound absorption for ripeness and unripe classification of watermelon. In: 2020 8th International Electrical Engineering Congress, 2020. IEECON, pp. 2020–2023. <https://doi.org/10.1109/IEECON48109.2020.229521>.
53. De Benedetto, D., Castrignano, A., Rinaldi, M., Ruggieri, S., Santoro, F., Figorito, B., Gualano, S., Diacono, M., Tamborrino, R. (2013). An approach for delineating homogeneous zones by using multi-sensor data. *Geoderma* 199, pp. 117–127.

-
54. Defraeye, T., Blocken, B., Carmeliet, J. (2021). Analysis of convective heat and mass transfer coefficients for convective drying of a porous flat plate by conjugate modelling. (n.d.). *International Journal of Heat and Mass Transfer*, 55(1–3), 112–124. <https://doi.org/10.1016/j.ijheatmasstransfer.2011.08.047>
55. Dehghannya, J., Ngadi, M., Vigneault, C. (2010). Mathematical modeling procedures for airflow, heat and mass transfer during forced convection cooling of produce: a review. *Food Eng. Rev.* 2 (4), 227–243. <https://doi.org/10.1007/s12393-010-9027-z>
56. Delele, M. A., Verboven, P., Ho, Q. T., Nicolaï, B. (2010). Advances in mathematical modelling of postharvest refrigeration processes. *Stewart Postharvest Review* 6 (2):1-8 DOI:10.2212/spr.2010.2.1.
57. Dhall, S., Mehta, B. R., Tyagi, A. K., Sood, K. (2021). A review on environmental gas sensors: Materials and technologies. *Sensors International*, 2, 100116. <https://doi.org/10.1016/j.sintl.2021.100116>
58. Dharia M.D.S.P., Falcone M.D.T. (2005). Robotics in reproductive medicine. *Fertility and Sterility*, 84(1), pp. 1–11. <https://doi.org/10.1016/j.fertnstert.2005.02.015>
59. Dominic, I. (2000). Science fiction and technology scenarios: comparing Asimov's robots and Gibson's cyberspace, *Technology in Society*, pp. 255–272.
60. Duckett, T., Pearson, S., Blackmore, S., Grieve, B., Chen, W. H., Cielniak, G., et al. (2018). Agricultural robotics: the future of robotic agriculture. arXiv preprint arXiv: 806.06762.

-
61. Dumbs, A., Hesse, J., (1983). Sensor problem in robotics. *Sensors and Actuators*, 4, pp. 629–639. [https://doi.org/10.1016/0250-6874\(83\)85077-X](https://doi.org/10.1016/0250-6874(83)85077-X)
 62. 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>.
 63. Eizicovits, D., van Tuijl, B., Berman, S., Edan, Y. (2016). Integration of perception capabilities in gripper design using graspability maps. *Biosyst. Eng.*, 146, 98–113.
 64. Elamvazhuthi, K., Berman, S. (2015). Optimal control of stochastic coverage strategies for robotic swarms. In 2015 IEEE International Conference on Robotics and Automation (ICRA) (pp. 1822-1829). IEEE.
 65. Elmenreich, W. (2002). *An Introduction to Sensor Fusion*. Vienna University of Technology, Vienna, Austria.
 66. Elsayed, S., Rischbeck, P., Schmidhalter, U. (2015). Comparing the performance of active and passive reflectance sensors to assess the normalized relative canopy temperature and grain yield of drought-stressed barley cultivars.. *Field Crops Research*, 177, pp. 148–160. <https://doi.org/10.1016/j.fcr.2015.03.010>
 67. Escolà, A., Cheein, F.A., Rosell-Polo, J.R. (2021). Agricultural Robotic Sensors for Crop and Environmental Modelling. In book: *Innovation in Agricultural Robotics for Precision Agriculture* (pp.31-62) Chapter: 3 Publisher: Springer DOI:10.1007/978-3-030-77036-5_3

-
68. Escolà, A., Rosell-Polo, J.R., Planas, S., Gil, E., Pomar, J., Camp, F., Llorens, J., Solanelles, F. (2013). Variable rate sprayer. Part 1 – orchard prototype: design, implementation and validation. *Comput Electron Agric* 95:122–135. <https://doi.org/10.1016/j.compag.2013.02.004>
69. Esposito, M., Crimaldi, M., Cirillo, V., Sarghini, F., Maggio, A. (2021). Drone and sensor technology for sustainable weed management: A review. *Chem. Biol. Technol. Agric.*, 8, 18.
70. Farooq, M. S., Riaz, S., Abid, A., Umer, T., Zikria, Y. B. (2020). Role of IoT Technology in Agriculture: A Systematic Literature Review. *Electronics*, 9 (2). <https://doi.org/10.3390/electronics9020319>
71. Feng, L., Chen, S., Zhang, C., Zhang, Y., He, Y. (2021). A comprehensive review on recent applications of unmanned aerial vehicle remote sensing with various sensors for high-throughput plant phenotyping. *Comput. Electron. Agric.*, 182, 106033.
72. Feng, X., Yan, F., Liu, X. (2019). Study of Wireless Communication Technologies on Internet of Things for Precision Agriculture, *Wireless Personal Communications* 108(2), pp. 1785–1802.
73. Ferentinos, K. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture* 145:311-318 DOI: 10.1016/j.compag.2018.01.009.
74. Fitz-Rodríguez, E., Giacomelli, G. A. (2009). Yield prediction and growth mode characterization of greenhouse tomatoes with neural networks and fuzzy logic. *Transactions of the ASABE*, 52(6), 2115-2128. <https://doi.org/10.13031/2013.29200>.

-
75. Fountas, S., Mylonas, N., Malounas, I., Rodias, E., Santos, C.H., Pekkeriet, E. (2020). Agricultural Robotics for Field Operations, *Sensors* 20(9), 2672.
 76. Fracapane, G, Koster, R.B.M.D., Sgarbossa, F., Strandhagen, J. O. (2021). Planning and control of autonomous mobile robots for intralogistics: Literature review and research agenda. *European Journal of Operational Research* 294 (5) DOI:10.1016/j.ejor.2021.01.019.
 77. Furukawa, S., Wakimoto, S., Kanda, T., Hagihara, H. (2019). A Soft Master-Slave Robot Mimicking Octopus Arm Structure Using Thin Artificial Muscles and Wire Encoders. *Actuators*, 8, 40.
 78. Gai, J., Xiang, L., Tang, L. (2021). Using a depth camera for crop row detection and mapping for under-canopy navigation of agricultural robotic vehicle. *Comput. Electron. Agric.*, 188, 106301.
 79. Gao, D., Yi, F., Fin, F., (2013). Computing a complete camera lens distortion model by planar homography. (2017). *Optics & Laser Technology*, 49, 95–107. <https://doi.org/10.1016/j.optlastec.2012.12.004>
 80. Gliever, C., Slaughter, D.C., (2001). Crop versus Weed Recognition Artificial neural networks: Neural Network Plant Recognition for Vision Based Robotics Weed Control. *Proceeding of the ASAE conference “Real-Time Image Applications”*, Sacramento.
 81. Gmur, S.; Vogt, D.; Zabowski, D.; Moskal, L.M. (2012). Hyperspectral Analysis of Soil Nitrogen, Carbon, Carbonate, and Organic Matter Using Regression Trees. *Sensors*, 12, 10639–10658.
 82. Gomes, A., Pinto, A., Soares, C., Torres, J.M., Sobral, P., Moreira, R.S. (2018). Indoor Location Using Bluetooth Low Energy Beacons.

-
- Trends and Advances in Information Systems and Technologies. 565-580.
83. 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>.
84. Goñi, I., Brenes, A., Centeno, C., Estevez, R. (2007). Effect of Dietary Grape Pomace and Vitamin E on Growth Performance, Nutrient Digestibility, and... Oxford University Press (OUP). *Poultry Science* 86(3):508-16 DOI:10.1093/ps/86.3.508
85. Gorjian, S.; Ebadi, H.; Trommsdorff, M.; Sharon, H.; Demant, M.; Schindele, S. (2021). The advent of modern solar-powered electric agricultural machinery: A solution for sustainable farm operations. *J. Clean. Prod.*, 292, 126030.
86. Grimstad, L., From, P. J. (2017). The Thorvald II Agricultural Robotic System. *Robotics*, 6 (4). <https://doi.org/10.3390/robotics6040024>
87. Grinblat, G. L., Uzal, L. C., Larese, M. G., Granitto, P. M. (2016). Deep learning for plant identification using vein morphological patterns. *Computers and electronics in agriculture*, 127, 418-424.
88. Grunwald, S., Vasques, G.M., Rivero, R.G. (2015). Fusion of soil and remote sensing data to model soil properties. In: Sparks, D.L. (Ed.), *Advances in Agronomy*, vol. 131. pp. 1–109.
89. 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. *arXiv.Org*. <https://arxiv.org/abs/1512.07108>
90. Gutierrez-Osuna, R., Janet, J. A., Luo, R. C. (1998). Modeling of Ultrasonic Range Sensors for Localization of Autonomous Mobile
-

Robots. Industrial Electronics 45(4):654 – 662
DOI:10.1109/41.704895

91. Hagen, N.A., Kudenov, M.W., (2013). Review of snapshot spectral imaging technologies. *Opt. Eng.* 52, 090901.
92. Halal, W.E. (2003). Artificial intelligence is almost here, *On the Horizon - The Strategic Planning Resource for Education Professionals*, Vol. 11, No. 2.
93. Haneishi, H., Yagihashi, Y., bMiyake, Y. (1995). A New Method for Distortion Correction of Electronic Endoscope Images. Institute of Electrical and Electronics Engineers.
94. Hanif, A. S., Han, X., Yu, S.-H. (2022). Independent Control Spraying System for UAV-Based Precise Variable Sprayer: A Review. *Drones*, 6(12). <https://doi.org/10.3390/drones6120383>
95. Haque, M.A., Haque, S., Sonal, D., Kumar, K., Shakeb, E. (2021). Security Enhancement for IoT Enabled Agriculture. *Mater. Today*. <https://doi.org/10.1016/j.matpr.2020.12.452>
96. Harper, N. L., McKerrow, P. J. (2001). Recognising plants with ultrasonic sensing for mobile robot navigation. *Robotics and Autonomous Systems* 34 (2-3): 71-82 DOI: 10.1016/S0921-8890(00)00112-3.
97. Heikkila, J., (2000). Geometric camera calibration using circular control points. *IEEE Trans. Pattern Anal. Machine Intell.* 22 (10), 1066–1077.
98. Hemmat, A., Adamchuk, V.I., Sensor systems for measuring soil compaction: Review and analysis. (2008). *Computers and Electronics in Agriculture*, 63 (2), 89–103. <https://doi.org/10.1016/j.compag.2008.03.001>

-
99. Hemming, J., Rath, T. (2002). Image processing for plant determination using the Hough transform and clustering methods. *Gartenbauwissenschaft*, 67(1), 1-10.
100. Herrero-Huerta, M., González-Aguilera, D., Rodríguez-González, P., Hernandez, D. (2015). Vineyard yield estimation by automatic 3D bunch modelling in field conditions. *Computers and Electronics in Agriculture* 110 DOI:10.1016/j.compag.2014.10.003
101. Hiremath, S., Heijden, G. van der, van Evert, F. K. Braak, C. ter. (2014). Laser range finder model for autonomous navigation of a robot in a maize field using a particle filter. *Computers and Electronics in Agriculture* 100:41–50 DOI: 10.1016/j.compag.2013.10.005
102. Hong, G., Luo, M. R., Rhodes, P. A. (2001). A study of digital camera colorimetric characterization based on polynomial modeling. *Color Research & Application: Endorsed by Inter-Society Color Council, The Colour Group (Great Britain), Canadian Society for Color, Color Science Association of Japan, Dutch Society for the Study of Color, The Swedish Colour Centre Foundation, Colour Society of Australia, Centre Français de la Couleur*, 26(1), 76-84..
103. Hou, A.L., Cui, X., Geng, Y., Yuan, W J., Hou, J. (2011). Measurement of safe driving distance based on stereo vision. In 2011 Sixth International Conference on Image and Graphics (pp. 902-907). IEEE.
104. Huang, L., Yang, S., He, D. (2012). Abscission Point Extraction for Ripe Tomato Harvesting Robots. *Intell. Autom. Soft Comput.*, 18, 751–763.
105. Huang, Z.-Y., Huang, J.T., Hsu, C.M. (2013). A Case Study of Object Identification Using a Kinect Sensor. *Konferencia kiadvány*
-

-
- Proceedings of the 2013 IEEE International Conference on Systems, Man, and Cybernetics DOI:10.1109/SMC.2013.300
- 106.Hurst, W., Mendoza, F.R., Tekinerdogan, B. (2021). Augmented reality in precision farming: concepts and applications. *Smart Cities* 4 (4), 1454–1468. <https://doi.org/10.3390/smartcities4040077>
- 107.Hurtado, J.P.V., Kantor, G.A., Cheein, F.A. (2019). Human-robot interaction in agriculture: A survey and current challenges, *Biosystems Engineering* 179(2), pp. 35-48.
- 108.Husti, I. (2018). Gondolatok és vélemények a precíziós mezőgazdálkodásról. *Mezőgazdasági Technika*. LIX, július. p 2-6.
- 109.Iida, M., Burks, T. (2002). Ultrasonic Sensor Development for Automatic Steering Control of Orchard Tractor. *Automation Technology for Off-Road Equipment, Proceedings of the July 26-27, 2002 Conference (Chicago, Illinois, USA)* pp. 221-229 . doi:10.13031/2013.10010)
- 110.Ishimwe, R., Abutaleb, K., Ahmed, F., (2014). Applications of thermal imaging in agriculture – a review. *Advances in Remote Sensing* 3, 128–140.
- 111.Ivanova, N., Gugleva, V., Dobрева, M., Pehlivanov, I., Stefanov, S., Andonova, V. (2016). The Internet of Things Space Infrastructure. *Current State and Development Prospects. Intech, (tourism)*, p. 13.
- 112.Jafarbiglu, H., Pourreza, A. (2022). A comprehensive review of remote sensing platforms, sensors, and applications in nut crops. *Computers and Electronics in Agriculture*, 197, 106844. <https://doi.org/10.1016/j.compag.2022.106844>

-
- 113.Jahne, B. (2004). Practical Handbook on Image Processing for Scientific and Technical Applications. <https://doi.org/10.1201/9780849390302>
- 114.Janardhanan, P.S. (2020). Project repositories for machine learning with TensorFlow. *Procedia Computer Science* 171:188-196 DOI: 10.1016/j.procs.2020.04.020
- 115.Javaid M, Haleem A, Pratap Singh R, Suman R. (2021a). Industrial perspectives of 3D scanning: Features, roles and it's analytical applications. *Sensors International* 2021;2:100114. <https://doi.org/10.1016/j.sintl.2021.100114>.
- 116.Javaid, M., Haleem, A., Rab, S., Pratap Singh, R., Suman, R. (2021b). Sensors for daily life: A review. *Sensors International*, 2, 100121. <https://doi.org/10.1016/j.sintl.2021.100121>
- 117.Jayakumari, R., Nidamanuri, R. R., Ramiya, A. M. (2021). Object-level classification of vegetable crops in 3D LiDAR point cloud using deep learning convolutional neural networks. *Precision Agriculture*, 22, 1617-1633. <https://doi.org/10.1007/s11119-021-09803-0>.
- 118.Jha, K., Doshi, A., Patel, P., Shah, M. (2019). A comprehensive review on automation in agriculture using artificial intelligence, *Artificial Intelligence in Agriculture*. 2, 1-12.
- 119.Jhavar, 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>
- 120.Ji, W., Shi, Z., Huang, J., Shuo, L. (2014). In Situ Measurement of Some Soil Properties in Paddy Soil Using Visible and Near-Infrared Spectroscopy. *Public Library of Science*.
-

-
121. Kalnicky, D.J., Singhvi, R. (2001). Field portable XRF analysis of environmental samples. *Journal of Hazardous Materials*, 83(1–2), 93–122. [https://doi.org/10.1016/S0304-3894\(00\)00330-7](https://doi.org/10.1016/S0304-3894(00)00330-7)
122. Kameoka, S., Isoda, S., Hashimoto, A., Ito, R., Miyamoto, S., Wada, G., Watanabe, N., Yamakami, T., Suzuki, K., Kameoka, T. (2017). A wireless sensor network for growth environment measurement and multi-band optical sensing to diagnose tree vigor. *Sensors* 17 (5), 966. <https://doi.org/10.3390/s17050966>.
123. Kamilaris, A., Prenafeta-Boldú, F. X. (2018). A review of the use of convolutional neural networks in agriculture. *The Journal of Agricultural Science*, 156 (3), 312–322. <https://doi.org/10.1017/S0021859618000436>
124. Kaya, M. D., Okcu, G., Atak, M., Kolsarici, Ö. (2006). Seed treatments to overcome salt and drought stress during germination in sunflower (*Helianthus annuus* L.). *European Journal of Agronomy* 24(4):291-295 DOI:10.1016/j.eja.2005.08.001
125. Kelly, J., Sukhatme, G. S. (2014). A general framework for temporal calibration of multiple proprioceptive and exteroceptive sensors. In *Experimental Robotics: The 12th International Symposium on Experimental Robotics* (pp. 195-209). Springer Berlin Heidelberg.
126. Khadatkar, A., Mathur, S. M., Dubey, K. BhusanaBabu, V. (2021). Development of embedded automatic transplanting system in seedling transplanters for precision agriculture. *Artificial Intelligence in Agriculture* 5 (4) DOI: 10.1016/j.aiia.2021.08.001.
127. Khan, I.A., Al-Habsi, S. (2020). Machine Learning in Computer Vision. (n.d.). *Procedia Computer Science*, 167, 1444–1451. <https://doi.org/10.1016/j.procs.2020.03.355>
-

-
- 128.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>
- 129.Kim, H., Lin, C. S., Song, J., Chae, H. (2005). Distance measurement using a single camera with a rotating mirror. *International Journal of Control, Automation, and Systems*, 3(4), 542-551.
- 130.Kim, J., Pyo, H., Jang, I., Kang, J., Ju, B., Ko, K. (2022). Tomato harvesting robotic system based on Deep-ToMaToS: Deep learning network using transformation loss for 6D pose estimation of maturity classified tomatoes with side-stem. *Computers and Electronics in Agriculture*, 201, 107300. <https://doi.org/10.1016/j.compag.2022.107300>
- 131.Kise, M., Zhang, Q., Rovira Maïs, F. (2005). A stereovision-based crop row detection method for tractor-automated guidance. *Biosystems Engineering*. 90 (4), 357–367.
- 132.Kour, K., Gupta, D., Gupta, K., Anand, D., Elkamchouchi, D. H., Pérez-Oleaga, C. M., Ibrahim, M., Goyal, N. (2022). Monitoring Ambient Parameters in the IoT Precision Agriculture Scenario: An Approach to Sensor Selection and Hydroponic Saffron Cultivation. *Sensors*, 22 (22). <https://doi.org/10.3390/s22228905>
- 133.Kuang, B., Mouazen, A. M. (2011). Calibration of visible and near infrared spectroscopy for soil analysis at the field scale on three European farms. *European Journal of Soil Science*, 62(4), 629–636. <https://doi.org/10.1111/j.1365-2389.2011.01358>

-
- 134.Kujawa, S., Niedbała, G. (2021). Artificial Neural Networks in Agriculture. *Agriculture*, 11 (6).
<https://doi.org/10.3390/agriculture11060497>
- 135.Kumar, S.D., Esakkirajan, S., Bama, S., Keerthiveena, B. (2020). A microcontroller based machine vision approach for tomato grading and sorting using SVM classifier. *Microprocessors and Microsystems*, 76, 103090. <https://doi.org/10.1016/j.micpro.2020.103090>
- 136.Kuwata, K., Shibasaki, R. (2015). Estimating crop yields with deep learning and remotely sensed data. In 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS) (pp. 858-861). IEEE.
- 137.Kwan, C. (2018). Remote Sensing Performance Enhancement in Hyperspectral Images. *Sensors*, 18 (11).
<https://doi.org/10.3390/s18113598>.
- 138.Lameski, P., Zdravevski, E., Kulakov, A. (2018). Review of Automated Weed Control Approaches: An Environmental Impact Perspective. In *Proceedings of the ICT Innovations 2018 Engineering and Life Sciences*; Kalajdziski, S., Ackovska, N., Eds.; Springer International Publishing: Cham, Switzerland, pp. 132–147.
- 139.Láng I. (2001). Lesz-e új a nap alatt a környezetvédelemben? *Magyar Tudomány*. 162, (12) 1415–1422.
- 140.LeCun, Y., Bengio, Y., (1995). Convolutional networks for images, speech, and time series. In *Arbib MA (ed.), The Handbook of Brain Theory and Neural Networks*. Cambridge, MA, USA: MIT Press, pp. 255–258
- 141.Li, C., Cao, Q., Guo, F. (2009). A method for color classification of fruits based on machine vision. *World Scientific and Engineering*
-

-
- Academy and Society. WSEAS Transactions on Systems 8(2):312-321
- 142.Li, H.Y., Shi, Z., Webster, R., Triantafyllis, J. (2008). Mapping the three-dimensional variation of soil salinity in a rice-paddy soil. *Geoderma*, 195–196, 31–41. <https://doi.org/10.1016/j.geoderma.2012.11.005>
- 143.Li, J., Guo, M.R., Gao, L.L., (2015). Application and innovation strategy of agricultural internet of things. *Trans. Chin. Soc. Agric. Eng.* 31 (S2), 200–209. <https://doi.org/10.11975/j.issn.1002-6819.2015.z2.031>
- 144.Li, S., Hao, G. (2021). Current Trends and Prospects in Compliant Continuum Robots: A Survey. *Actuators*, 10, 145.
- 145.Lillo-Saavedra, M., Espinoza-Salgado, A., García-Pedrero, A., Souto, C., Holzapfel, E., Gonzalo-Martín, C., Rivera, D. (2022). Early Estimation of Tomato Yield by Decision Tree Ensembles. *Agriculture*, 12(10), 1655. <https://doi.org/10.3390/agriculture12101655>.
- 146.Liu, J. (2018). Tomato yield estimation based on object detection. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 22 (7), 1120-1125.
- 147.Liu, L., Li, Z., Lan, Y., Cui, Y. (2019). Design of a tomato classifier based on machine vision. *Public Library of Science. PLoS ONE* 14 (7):e0219803 DOI:10.1371/journal.pone.0219803
- 148.Loganathan, A., Ahmad, N. S. (2023). A systematic review on recent advances in autonomous mobile robot navigation. *Engineering Science and Technology, an International Journal*, 40, 101343. <https://doi.org/10.1016/j.jestch.2023.101343>
-

-
149. Longchamps, L., Tremblay, N., Panneton, B. (2018). Observational studies in agriculture: paradigm shift required. A paper from the Proceedings of the 14th International Conference on Precision Agriculture, Canada.
150. Lopez, A., Keresztes, J., Goodarzi, M., Saeys, W. (2016). Non-destructive detection of blackspot in potatoes by Vis-NIR and SWIR hyperspectral imaging. *Food Control* 70. DOI:10.1016/j.foodcont.2016.06.001
151. Lowenberg-DeBoer, J., Erickson, B. (2019). Setting the Record Straight on Precision Agriculture Adoption. *American Society of Agronomy Journal* 111 (4), 1552–1569. DOI:10.2134/agronj2018.12.0779
152. Lucchese, L., Mitra, S.K. (2002). Using saddle points for subpixel feature detection in camera calibration targets. In: *Asia-Pacific Conference on Circuits and Systems*, vol. 2. pp. 191–195.
153. Mahmud, M.S.A., Abidin, M.S.Z., Emmanuel, A.A., Hasan, H.S. (2020). Robotics and Automation in Agriculture: Present and Future Applications, *Applications of Modelling and Simulation* 4, pp. 130-140.
154. Maier, H.R.. - Dandy, G.C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications. *Environmental Modeling & Software*. 15, (1) 101–124.
155. 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.

- 156.Mao, S., Li, Y., Ma, Y., Zhang, B., Zhou, J., Kai Wang. (2020). Automatic cucumber recognition algorithm for harvesting robots in the natural environment using deep learning and multi-feature fusion. *Computers and Electronics in Agriculture*, 170, 105254. <https://doi.org/10.1016/j.compag.2020.105254>
- 157.Marchant, J.A., Brivot, R. (1995). Real-time tracking of plant rows using a Hough transform. *Real-time Imaging* 1, pp. 363–371.
- 158.Marchant, J.A., Onyango, C.M. (2000). Shadow invariant classification for scenes illuminated by daylight. *Journal of the Optical Society of America*. 17, (11) 1952-1961.
- 159.Martinelli, A., Pont, F., Siegwart, R. (2005). Multi-Robot Localization Using Relative Observations. Unknown. https://www.researchgate.net/publication/221072829_Multi-Robot_Localization_Using_Relative_Observations.
- 160.Mavridis, N. A review of verbal and non-verbal human–robot interactive communication. (2015). *Robotics and Autonomous Systems*, 63, 22–35. <https://doi.org/10.1016/j.robot.2014.09.031>
- 161.McBratney, A.B., Whelan, B.M., Ancev, T., Bouma, J. (2005). Future Directions of Precision Agriculture. *Precis. Agric.* 6, 7–23.
- 162.Meshram, V., Patil, K., Meshram, V., Hanchate, D.B., Ramkteke, S.D. (2021). Machine learning in agriculture domain: A state-of-art Survey, *Artificial Intelligence in the Life Sciences* 1.
- 163.Mesterházi, P. Á. (2004). Development of measurement technique for GPS-aided plant production. PhD disszertáció. Témavezető: Prof. Dr. Neményi Miklós. Nyugat-magyarországi Egyetem, Mosonmagyaróvár.

-
164. Mike-Hegedűs, F. (2006). A fuzzy logika és a neurális háló alkalmazása a precíziós növénytermelés adatbázisának értékelésében. PhD disszertáció. Témavezető: Prof. Dr. Neményi Miklós. Nyugat-magyarországi Egyetem, Mosonmagyaróvár.
165. Milella, A., Reina, G., Nielsen, M. A. (2018). A multi-sensor robotic platform for ground mapping and estimation beyond the visible spectrum, *Precision Agriculture*, 20(2), pp. 423–444.
166. Milics, G. (2008). A térinformatika és a távérzékelés alkalmazása a precíziós (helyspecifikus) növénytermesztésben. PhD disszertáció. Témavezetők: Dr. Nagyváradi László és Prof. Dr. Neményi Miklós. Pécsi Tudományegyetem, Pécs.
167. Millikan, R.A. - Nobel Lecture: The Electron and the Light-Quant from the Experimental Point of View, Nobelprize.org, PDF, 30 http://www.nobelprize.org/nobel_prizes/physics/laureates/1923/millikan-lecture.pdf
168. 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
169. Mohanta, B.K., Jena, D., Satapathy, U., Patnaik, S. (2020). Survey on IoT Security: Challenges and Solution using Machine Learning, Artificial Intelligence and Blockchain Technology, *Internet of Things* 11.
170. Monteiro, A., Santos, S., Gonçalves, P. (2021). Precision Agriculture for Crop and Livestock Farming—Brief Review. *Animals : An Open Access Journal from MDPI*, 11(8). <https://doi.org/10.3390/ani11082345>

-
171. Moustakides, G. V., Briassoulis, D., Psarakis, E., Dimas, E. (2000). 3D image acquisition and NURBS based geometry modelling of natural objects. *Advances in Engineering Software* 31(12):955-969. DOI:10.1016/S0965-9978(00)00060-0
172. Moysiadis, V., Tsolakis, N., Katikaridis, D., Sørensen, C.G., Pearson, S., Bochtis, D. (2020). Mobile Robotics in Agricultural Operations: A Narrative Review on Planning Aspects. *Appl. Sci.*, 10, 3453.
173. Mu, Y., Chen, T. S., Ninomiya, S., Guo, W. (2020). Intact detection of highly occluded immature tomatoes on plants using deep learning techniques. *Sensors*, 20(10), 2984. <https://doi.org/10.3390/s20102984>.
174. Mueller, T., Hartsock, N. J., Stombaugh, T., Barnhisel, R. I. (2003). Soil Electrical Conductivity Map Variability in Limestone Soils Overlain by Loess. *American Society of Agronomy*.
175. Mukupa, W., Roberts, G. W., Hancock, C. M., Al-Manasir, K. (2017). A review of the use of terrestrial laser scanning application for change detection and deformation monitoring of structures. *Survey review*, 49(353), 99-116.
176. Mustafa, I. B., Khairul, S. F. B. M. (2017). Identification of fruit size and maturity through fruit images using OpenCV-Python and Raspberry Pi. 2017 International Conference on Robotics, Automation and Sciences (ICORAS) DOI:10.1109/ICORAS.2017.8308068
177. Müller, F. D. P. (2017). Survey on Ranging Sensors and Cooperative Techniques for Relative Positioning of Vehicles. *Sensors*, 17 (2). <https://doi.org/10.3390/s17020271>
178. Neményi M. (2017). Thoughts and questions about the sustainability of agriculture in the modern digital age: theoretical and practical approach. pp. 11-40.
-

-
- 179.Neményi M. (2020). Az agrárium és az ökológiai fenntarthatóság I. rész: globális megközelítés, a gazdagok felelőssége. Magyar Tudomány. 181, (129) 1665–1673.
- 180.Neményi, M., Nyeki, A. (2022). Crop Yield Prediction in Precision Agriculture. Agronomy 12 DOI:10.3390/agronomy12102460
- 181.Nemeskéri E, Neményi A, Böcs 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>.
- 182.Nijland, W., De Jong, R., De Jong, S. M., Wulder, M. A., Bater, C. W., Coops, N. C. (2014). Monitoring plant condition and phenology using infrared sensitive consumer grade digital cameras. Agricultural and Forest Meteorology, 184, 98-106.
- 183.Nikiforov, A., Kuchumov, A., Terentev, S., Karamulina, I., Romanova, I., Glushakov, S. (2020). Neural network method as means of processing experimental data on grain crop yields. E3S Web of Conferences, 161. <https://doi.org/10.1051/e3sconf/202016101031>
- 184.Nyéki, A. (2016). A precíziós növénytermesztés és a fenntartható mezőgazdaság kapcsolata. PhD disszertáció. Témavezető: Prof. Dr. Neményi Miklós. Szechenyi István Egyetem, Mosonmagyaróvár.
- 185.Nyéki, A., Kerepesi, C., Daróczy, B., Benczúr, A., Milics, G., Nagy, J., Harsányi, E., Kovács, A.J., Neményi, M. (2021). Application of spatio-temporal data in site-specific maize yield prediction with machine learning methods. *Precis. Agric*, 22, 1397–1415. <https://doi.org/10.1007/s11119-021-09833-8>
- 186.Nyéki, A., Neményi, M. (2022). Crop Yield Prediction in Precision Agriculture. *Agronomy*, 2022,(12) 2460.
-

-
- 187.Obaideen, K., Yousef, B.A.A., AlMallahi, M.N., Tan, Y.C., Mahmoud, M., Jaber, H., Ramadan, M. (2022). An overview of smart irrigation systems using IoT, *Energy Nexus* 7, 100124.
- 188.Ohashi, Y., Ishigami, Y., Goto, E. (2020). Monitoring the growth and yield of fruit vegetables in a greenhouse using a three-dimensional scanner. *Sensors*, 20 (18), 5270. <https://doi.org/10.3390/s20185270>.
- 189.Oliveira, L.F.P., Moreira, A.P., Silva, M.F. (2021). Advances in Agriculture Robotics: A State-of-the-Art Review and Challenges Ahead. *Robotics*, 10 (2). <https://doi.org/10.3390/robotics10020052>
- 190.Omia, E., Bae, H., Park, E., Kim, M. S., Baek, I., Kabenge, I., Cho, B.-K. (2023). Remote Sensing in Field Crop Monitoring: A Comprehensive Review of Sensor Systems, Data Analyses and Recent Advances. *Remote Sensing*, 15(2). <https://doi.org/10.3390/rs15020354>
- 191.Omran, E.E. (2012). On-the-go digital soil mapping for precision agriculture. *International Journal of Remote Sensing Applications*, 2, 20–38.
- 192.Ota, T., Iwasaki, Y., Nakano, A., Higashide, T. (2018). Development of yield and harvesting time monitoring system for tomato greenhouse production. *Engineering in Agriculture* 12(1) DOI:10.1016/j.eaef.2018.09.003
- 193.Ouyang, Y., Sun, C., Dong, L. (2022). Actor–critic learning based coordinated control for a dual-arm robot with prescribed performance and unknown backlash-like hysteresis. *ISA transactions*, 126, 1-13.
- 194.Pan, B., Yu, L., Wu, D. (2013). High-accuracy 2D digital image correlation measurements with bilateral telecentric lenses: error analysis and experimental verification. *Experimental Mechanics*, 53,
-

-
- 1719-1733. 2013;53:1719–33. <https://doi.org/10.1007/s11340-013-9774-x>.
195. Patel, V. R. (Ed.). (2012). *Robotic urologic surgery*. 1st ed. London: Springer, p. 2
196. Piekutowska, M., Niedbala, G., Piskier, T., Lenartowicz, T., Pilarski, K., Wojciechowski, T., Pilarska, A.A., Czechowska-Kosacka, A. (2021). The application of multiple linear regression and artificial neural network models for yield prediction of very early potato cultivars before harvest. *Agronomy*, 11, 885.
197. Pierzchala, M., Giguere, P., Astrup, R. (2018). Mapping forests using an unmanned ground vehicle with 3D LiDAR and graph-SLAM. *Comput. Electron. Agric.*, 145, 217–225.
198. Polder, G., Heijden, G. van der, G.W.A.M. (2010). Measuring Ripening of Tomatoes Using Imaging Spectrometry. *Hyperspectral Imaging for Food Quality Analysis and Control*, Pages 369-402.
199. Pramod, A.S., Jithinmon, T.V. (2019). Development of mobile dual PR arm agricultural robot. *Journal of Physics Conference Series* 1240(1):012034 DOI:10.1088/1742-6596/1240/1/012034
200. Qaddoum, K., Hines, E. L., Iliescu, D. D. (2013). Yield prediction for tomato greenhouse using EFuNN. *International Scholarly Research Notices*, 2013.. <https://doi.org/10.1155/2013/430986>.
201. Qingchun, F., Wei, C., Jianjun, Z., Xiu, W. (2014). Design of structured-light vision system for tomato harvesting robot. *International Journal of Agricultural and Biological Engineering*, 7 (2), 19-26.
202. 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.
- 203.Rahman, C.R., Arko, P.S., Ali, M.E., Khan, M.A.I., Apon, S.H., Nowrin, F., Wasif, A., (2020). Identification and recognition of rice diseases and pests using convolutional neural networks. (n.d.). *Biosystems Engineering*, 194, 112–120. <https://doi.org/10.1016/j.biosystemseng.2020.03.020>
- 204.Rahman, K. A., Hossain, M. S., Bhuiyan, M. A. A., Zhang, T., Hasanuzzaman, M., Ueno, H. (2009). Person to camera distance measurement based on eye-distance. In 2009 Third International Conference on Multimedia and Ubiquitous Engineering (pp. 137-141). IEEE.
- 205.Rahnemoonfar, M., Sheppard, C. (2017). Deep count: fruit counting based on deep simulated learning. *Sensors*, 17(4), 905. <https://doi.org/10.3390/s17040905>.
- 206.Rajagopal, S., Venusamy, K., Sathish, S., Poongodi, J., Suriyan, K., Alagarsamy, M. (2022). Machine to machine communication enabled internet of things: a review, *International Journal of Reconfigurable and Embedded Systems (IJRES)* 11(2), pp. 126-134.
- 207.Ramirez, W. A., Mishra, G., Panda, B. K., Jung, H. W., Lee, S. H., Lee, I., Singh, C. B. (2022). Multispectral camera system design for replacement of hyperspectral cameras for detection of aflatoxin B1. *Computers and Electronics in Agriculture*, 198, 107078.
- 208.Rasp, S., Pritchard, M. S., Gentine, P. (2018). Deep learning to represent subgrid processes in climate models. *Proceedings of the National Academy of Sciences*, 115 (39), 9684-9689.

- 209.Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195-204.
- 210.Riba, J.-R. (2022). Application of Image Sensors to Detect and Locate Electrical Discharges: A Review. *Sensors*, 22(15).
<https://doi.org/10.3390/s22155886>
- 211.Rincon, D. R., Henten, E. J. V., Kootstra, G. (2022). Development and evaluation of automated localization and reconstruction of all fruits on tomato plants in a greenhouse based on multi-view perception and 3D multi-object tracking. *Biosystems Engineering*, 231, 78–91.
<https://doi.org/10.1016/j.biosystemseng.2023.06.003>
- 212.Rovira-Más, F., Chatterjee, I. Saiz-Rubio, V. (2015). The role of GNSS in the navigation strategies of cost-effective agricultural robots. *Computers and Electronics in Agriculture* 112 DOI: 10.1016/j.compag.2014.12.017.
- 213.Rutkin, A., (2014). The robot’s dilemma. *New Scientist*, Volume 223, Issue 2986, Page 22 [https://doi.org/10.1016/S0262-4079\(14\)61761-9](https://doi.org/10.1016/S0262-4079(14)61761-9)
- 214.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.
- 215.Saiz-Rubio, V., Rovira-Más, F. (2020). From Smart Farming towards Agriculture 5.0: A Review on Crop Data Management, *Agronomy* 10(2).
- 216.Sangwine, S.J., (2013). *Advances in Imaging and Electron Physics*, Volume 175, pp .283-307 <https://doi.org/10.1016/B978-0-12-407670-9.00006-8>

- 217.Santos, D.F.N., Sobreira, H.M.P., Campos, D.F.B., Morais, R., Moreira, A.P.G.M., Contente, O.M.S. (2015). Towards a reliable monitoring robot for mountain vineyards. In: 2015 IEEE International Conference on Autonomous Robot Systems and Competitions. Vila Real, Portugal: IEEE, pp.37–43.
- 218.Santos, dos, Silva, da, Zerbato, Menezes, de, Kazama, Paixão, Voltarelli. (2019). Use of real-time extend GNSS for planting and inverting peanuts. *Precision Agriculture*, 20 (4), 840–856. <https://doi.org/10.1007/s11119-018-9616-z>
- 219.Saxena, L., Armstrong, L., (2014). A survey of image processing techniques for agriculture. In *Proceedings of Asian Federation for Information Technology in Agriculture*. Perth, Australia: Australian Society of Information and Communication Technologies in Agriculture, pp. 401–413
- 220.Schmidhuber, J. (2015). Deep learning in neural networks: an overview. *Neural Networks* 61, 85–117
- 221.Scudiero, E.; Berti, A.; Teatini, P.; Morari, F. (2012). Simultaneous Monitoring of Soil Water Content and Salinity with a Low-Cost Capacitance-Resistance Probe. *Sensors*, 12, 17588–17607
- 222.Sebastian, B., Ben-Tzvi, P. (2018). Physics Based Path Planning for Autonomous Tracked Vehicle in Challenging Terrain. *J. Intell. Robot. Syst.*, 95, 511–526.
- 223.Selvaraj, A., Shebiah, N., Ananthi, S., Varthini, S. V. (2013). Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. *Agricultural Engineering International : The CIGR e-journal* 15(1):211-217

-
- 224.Senthilnath, J., Dokania, A., Kandukuri, M., Ramesh, K. N., Anand, G., Omkar, S. N. (2016). Detection of tomatoes using spectral-spatial methods in remotely sensed RGB images captured by UAV. *Biosystems engineering*, 146, 16-32.
- 225.Seo, D., Cho, B.H., Kim, K.C. (2021). Development of Monitoring Robot System for Tomato Fruits in Hydroponic Greenhouses. *Agronomy*, 11(11). <https://doi.org/10.3390/agronomy11112211>
- 226.Sethuramasamyraja, B., Adamchuk, V. I., Marx, D., Jones, D. D. (2007). Analysis of an Ion-Selective Electrode Based Methodology for Integrated On-The-Go Mapping of Soil pH, Potassium, and Nitrate Contents. (*American Society of Agricultural and Biological Engineers*) 50(6):1927-1935 DOI:10.13031/2013.24088
- 227.Shafi, U., Mumtaz, R., García-Nieto, J., Iqbal, N. (2019). Precision Agriculture Techniques and Practices: From Considerations to Applications. MDPI.
- 228.Shalal, N., Low, T., McCarthy, C., Hancock, N. (2013). A review of autonomous navigation systems in agricultural environments. *SEAg 2013: Innovative Agricultural Technologies for a Sustainable Future*.
- 229.Shi, Z., Ji, W., Rossel, R. A. V., Chen, S., Zhou, Y. (2015). Prediction of soil organic matter using a spatially constrained local partial least squares regression and the Chinese vis–NIR spectral library. *European Journal of Soil Science*, 66 (4), 679–687. <https://doi.org/10.1111/ejss.12272>
- 230.Skierucha, W.; Wilczek, A.; Szyplowska, A.; Sławiński, C.; Lamorski, K. (2012). A TDR-Based Soil Moisture Monitoring System with Simultaneous Measurement of Soil Temperature and Electrical Conductivity. *Sensors*, 12, 13545–13566.
-

-
231. Skoczeń, M., Ochman, M., Spyra, K., Nikodem, M., Krata, D., Panek, M., Pawłowski, A. (2021). Obstacle Detection System for Agricultural Mobile Robot Application Using RGB-D Cameras. *Sensors* (Basel, Switzerland), 21(16). <https://doi.org/10.3390/s21165292>.
232. Slaughter, D.C., Ruiz, M. P., Fathallah, F., Upadhyaya, S., Gliever, C. J., Miller, B. (2012). GPS-Based Intra-Row Weed Control System: Performance and Labor Savings. *Automation Technology for Off-Road Equipment. proceedings of the 2012 ATOE Conference 10-11 July, 2012 Valencia, Spain.*
233. Slaughter, D.C., Chen, P., Curley, R.G. (1997). Computer vision guidance system for precision cultivation. *American Society of Agricultural Engineers paper 97*, p 1079.
234. Soares, A., Soares, T. W. de L. (2016). An Evolutionary Algorithm for Autonomous Robot Navigation. *Procedia Computer Science* 80:2261-2265 DOI: 10.1016/j.procs.2016.05.404.
235. Søggaard, H. T. and Lund I. (2006). Investigation of the accuracy of a machine vision based robotic micro spray system. *5th European conference, Precision Agriculture*, 8-11.
236. Søggaard, H.T., Olsen, H.J. (2003). Determination of crop rows by image analysis without segmentation, *Computers and Electronics in Agriculture* 38, pp. 141-158.
237. Song, C., Ma, W., Li, J., Qi, B., Liu, B. (2022). Development Trends in Precision Agriculture and Its Management in China Based on Data Visualization. *Agronomy*, 12(11). <https://doi.org/10.3390/agronomy12112905>
-

-
- 238.Soter, G., Conn, A. T., Hauser, H., Rossiter, J. (2018). Bodily aware soft robots: integration of proprioceptive and exteroceptive sensors. 2018 IEEE International Conference on Robotics and Automation (ICRA)
- 239.Stankiewicz, O., Lafruit, G., Domański, M. (2018). Multiview video: Acquisition, processing, compression, and virtual view rendering. In Academic Press Library in Signal Processing, Volume 6 (pp. 3-74). Academic Press.
- 240.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, 6
- 241.Stein, G.P. (1997). Lens distortion calibration using point correspondences. In Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition (pp. 602-608). IEEE..
- 242.Steinmetz, V., Bellon, V. (1995). Sensor Fusion for Quality Control of Agricultural Products. *IFAC Proceedings Volumes*, 28 (4), 237–243. [https://doi.org/10.1016/S1474-6670\(17\)45570-4](https://doi.org/10.1016/S1474-6670(17)45570-4)
- 243.Stevenson, A., Hartemink, A. E., Zhang, Y. (2023). Measuring sand content using sedimentation, spectroscopy, and laser diffraction. *Geoderma*, 429, 116268. <https://doi.org/10.1016/j.geoderma.2022.116268>
- 244.Subeesh, A., Bhole, S., Singh, K., Chandel, N.S., .Rajwade, A.A., Rao, K.V.R., Kumar, S.P., Jat, D., (2022). Deep convolutional neural network models for weed detection in polyhouse grown bell peppers. (n.d.). *Artificial Intelligence in Agriculture*, 6, 47–54. <https://doi.org/10.1016/j.aiia.2022.01.002>
-

- 245.Sun, J., He, X., Wu, M., Lu, B. (2020). Detection of tomato organs based on convolutional neural network under the overlap and occlusion backgrounds. *Machine Vision and Applications* 31(5) DOI:10.1007/s00138-020-01081-6
- 246.Sun, J., Zhao, J., Hu, X., Gao, H., Yu, J. (2023). Autonomous Navigation System of Indoor Mobile Robots Using 2D Lidar. *Mathematics*, 11 (6). <https://doi.org/10.3390/math11061455>.
- 247.Sun, L., Suo, X., Liu, Y., Han, L. (2016). 3D Modeling of Transformer Substation Based on Mapping and 2D Images. Hindawi Publishing Corporation.
- 248.Sun, Q., Hou, Y., Chen, J. (2015). Lens distortion correction for improving measurement accuracy of digital image correlation. *Optik*, 126 (21), 3153-3157. <https://doi.org/10.1016/j.ijleo.2015.07.068>.
- 249.Suzuki, A., Vettori, S., Giorgi, S., Carretti, E., Di Benedetto, F., Dei, L., Benvenuti, M., Moretti, S., Pecchioni, E., Costagliola, P. (2018). Laboratory study of the sulfation of carbonate stones through swir hyperspectral investigation. *J. Cultural Heritage* 32, 30–37.
- 250.Szulc, P., Bocianowski, J., Nowosad, K., Bujak, H., Zielewicz, W., Stachowiak, B. (2021). Effects of NP fertilizer placement depth by year interaction on the number of maize (*Zea mays* L.) plants after emergence using the additive main effects and multiplicative interaction model. *Agronomy*, 11, 1543.
- 251.Taha, F. M., Osman, A. A., Awadalkareem, S. D., Omer, M. S., Saadaldeen, R. S. (2018). A design of a remote greenhouse monitoring and controlling system based on internet of things. In 2018

-
- International Conference on Computer, Control, Electrical, and Electronics Engineering (ICCCEEE) (pp. 1-6). IEEE.
252. Talaviya, T., Shah, D., Patel, N. Shah, M. (2020). Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides *Artificial Intelligence in Agriculture* 4(1) DOI: 10.1016/j.aiia.2020.04.002.
253. Tamás J. (2001). *Precíziós mezőgazdaság elmélete és gyakorlata. Mezőgazdasági szaktudás Kiadó, Budapest.*
254. Tarr, M. J., Kersten, D., Bühlhoff, H. H. (1998). Why the visual recognition system might encode the effects of illumination - PubMed. *Vision Research*, 38(15–16). [https://doi.org/10.1016/s0042-6989\(98\)00041-8](https://doi.org/10.1016/s0042-6989(98)00041-8)
255. 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), 1-17.
256. Taye, M.M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation*, 11 (3). <https://doi.org/10.3390/computation11030052>
257. 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
-

-
258. Thakur, D., Kumar, Y., Kumar, A., Singh, P.K. (2019). Applicability of Wireless Sensor Networks in Precision Agriculture: A Review, *Wireless Personal Communications* 107(12), pp. 471–512.
259. Tillett, N.D., Hague, T. (1999). Computer-Vision-based hoe guidance for cereals - an initial trial. *Journal of Agricultural Engineering Research* 74, (3) 225-236. <https://doi.org/10.1006/jaer.1999.0458>
260. Tillett, N.D., Hague, T., Grundy, A.C., Dedousis, A.P. (2008). Mechanical within-row weed control for transplanted crops using computer vision *Biosyst. Eng.*, 99, pp. 171-178.
261. Tillett, N.D., Hague, T., Miles, S.J. (2001). A field assessment of a potential method for weed and crop mapping on the basis of crop planting geometry *Computers and Electronics in Agriculture*, 32 (3), pp. 229-246.
262. Tillett, N.D., Hague, T., Miles, S.J. (2002). Inter-row vision guidance for mechanical weed control in sugar beet *Computers and Electronics in Agriculture*, 33 (3), pp. 163-177.
263. Tilman, D. (1998). The greening of the green revolution. *Nature*. 396, 211-212.
264. Toda, M., Kitani, O., Okamoto, T., Torii, T., (1999). Navigation Method for a Mobile Robot via Sonar-based Crop Row Mapping and Fuzzy Logic Control. (n.d.). *Journal of Agricultural Engineering Research*, 72(4), 299–309. <https://doi.org/10.1006/jaer.1998.0371>
265. Tzafestas, S.G. (2014). *Mobile Robot Control IV. Introduction to Mobile Robot Control*, Elsevier, p. 269–317.
266. Tzounis, A., Katsoulas, N., Bartzanas, T., Kittas, C. (2017). Internet of Things in agriculture, recent advances and future challenges.

-
- Biosystems Engineering, 164, 31–48.
<https://doi.org/10.1016/j.biosystemseng.2017.09.007>
267. Utstumo, T., Urdala, F., Brevika, A., Netland, J., Overskeida, Ø., Bergec, T.W., Gravdahl, J.T. (2018). Robotic in-row weed control in vegetables. *Computers and Electronics in Agriculture* 154, 36–45.
268. Valera, D.L., Gil, J., Agüera, J. (2012). Design of a New Sensor for Determination of the Effects of Tractor Field Usage in Southern Spain: Soil Sinkage and Alterations in the Cone Index and Dry Bulk Density. *Sensors*, 12, 13480–13490.
269. Verl, A., Valente, A., Melkote, S., Brecher, C., Ozturk, E., Tunc, L.T., Robots in machining. (2019). *CIRP Annals*, 68 (2), 799–822.
<https://doi.org/10.1016/j.cirp.2019.05.009>
270. Veum, K.S., Sudduth, K.A., Kremer, R.J., Kitchen, N.R. (2017). Sensor data fusion for soil health assessment. *Geoderma* 305, 53–61.
271. Viscarra, V.R., McGlynn, R.n., McBratney, A.B. (2006). Determining the composition of mineral-organic mixes using UV–vis–NIR diffuse reflectance spectroscopy. *Geoderma*, 137(1–2), 70–82.
<https://doi.org/10.1016/j.geoderma.2006.07.004>
272. Wahab, M. N. A., Sivadev, N., Sundaraj, K. (2011). Target distance estimation using monocular vision system for mobile robot. In 2011 IEEE Conference on Open Systems (pp. 11-15). IEEE.
273. Wan, P., Toudeshki, A., Tan, H., Ehsani, R. (2018). A methodology for fresh tomato maturity detection using computer vision. *Computers and Electronics in Agriculture* 146:43-50
DOI:10.1016/j.compag.2018.01.011
-

-
274. Wang Y, Hu S, Ren H, Yang W, Zhai R. (2022). 3DPhenoMVS: A Low-Cost 3D Tomato Phenotyping Pipeline Using 3D Reconstruction Point Cloud Based on Multiview Images. *Agronomy* ;12:1865.
275. Wang Y, Xiao R, Yin Y, Liu T. (2021). Prediction of Tomato Yield in Chinese-Style Solar Greenhouses Based on Wavelet Neural Networks and Genetic Algorithms. *Information*;12:336. <https://doi.org/10.3390/info12080336>.
276. 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) DOI:10.1016/j.ijleo.2016.05.119
277. Wang, J., Yuan, L., Xu, H., Xie, G., Wen, X., (2021). Channel exchanged feature representations for person re-identification. n.d.). *Information Sciences*, 562, 370–384. <https://doi.org/10.1016/j.ins.2021.03.028>
278. Wang, P., Tian, J., Niu, H., Chen, Y. (2019). Smart Agricultural in-Field Service Robot: From toy to Tool. ASME 2019 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference, Anaheim, CA, USA.
279. Wang, X. V., Wang, L. (2021). A literature survey of the robotic technologies during the COVID-19 pandemic. *Journal of Manufacturing Systems*, 60, 823–836. <https://doi.org/10.1016/j.jmsy.2021.02.0>
280. Wei, J., Salyani, M. (2004). Development of a laser scanner for measuring tree canopy characteristics: Phase 1. Prototype development. *Transactions of the ASAE*, 47(6), 2101.
281. Weng, J., Cohen, M. P., Herniou, M. (1992). Camera calibration with distortion models and accuracy evaluation. *IEEE Transactions on*
-

- Pattern Analysis and Machine Intelligence. 14 (10), 965–980.
<https://doi.org/10.1109/34.159901>.
282. White, R.M., (1987). A sensor classification scheme. IEEE Trans. Ultrason. Ferroelectr. Freq. Control UFFC-34 (2), 124–126.
283. Widianto, M. H., Hermanus, D. R., Ardimansyah, M. I., Pohan, H. I. (2022). A Systematic Review of Current Trends in Artificial Intelligence for Smart Farming to Enhance Crop Yield. Journal of Robotics and Control (JRC) Volume 3, Issue 3. DOI: 0.18196/jrc.v3i3.13760
284. Wilczek, A.; Szypłowska, A.; Skierucha, W.; Cieśla, J.; Pichler, V.; Janik, G. (2012). Determination of Soil Pore Water Salinity Using an FDR Sensor Working at Various Frequencies up to 500 MHz. Sensors, 12, 10890–10905.
285. Xaud, M. F. dos S., Leite, A. C., Barbosa, E. S., From, P. J. (2018). Robotic tankette for intelligent bioenergy agriculture: design, development and field tests, XXII Congresso Brasileiro de Automatica (CBA2018). Joao Pessoa, Brazil, 1357.
286. Xiang, R. (2018). Image segmentation for whole tomato plant recognition at night. Computers and Electronics in Agriculture, 154, 434-442.. <https://doi.org/10.1016/j.compag.2018.09.034>.
287. Xing, X., Song, J., Lin, L., Tian, M., Lei, Z. (2017). Development of intelligent information monitoring system in greenhouse based on wireless sensor network. In 2017 4th International Conference on Information Science and Control Engineering (ICISCE) (pp. 970-974). IEEE.

-
288. Xu, H. (2012). Application of GPS-RTK Technology in the Land Change Survey. (n.d.). *Procedia Engineering*, 29, 3454–3459. <https://doi.org/10.1016/j.proeng.2012.01.511>
289. Xu, J., Gu, B., Tiann, G. (2022). Review of agricultural IoT technology. *Artificial Intelligence in Agriculture*, 6, 10–22. <https://doi.org/10.1016/j.aiia.2022.01.001>
290. 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. pp. 12191–206. <https://doi.org/10.3390/s140712191>.
291. Yao, H., Qin, R., Chen, X. (2019). Unmanned Aerial Vehicle for Remote Sensing Applications—A Review. *Remote Sensing*, 11(12). <https://doi.org/10.3390/rs11121443>
292. Yossy, E., Pranata, J., Wijaya, T. B., Budiharto, W. (2017). *Mango Fruit Sortation System using Neural Network and Computer Vision*. Elsevier.
293. You, W.J., Tang, S.Y., (2013). Research on the related techniques of precision agriculture electronic system. *J. Chin. Agric. Mech.* 34 (3), 233–236. <https://doi.org/10.3969/j.issn.2095-5553.2013.03.057>
294. Yuan, W., Li, J., Bhatta, M., Shi, Y., Baenziger, P.S., Ge, Y. (2018). Wheat height estimation using LiDAR in comparison to ultrasonic sensor and UAS. *Sensors* 18 (11), pp. 3731 <https://doi.org/10.3390/s18113731>.
295. Zang, J., Jin, S., Zhang, S., Li, Q., Mu, Y., Li, Z., Li, S., Wang, X., Su, Y., Jiang, D. (2023). Field-measured canopy height may not be as accurate and heritable as believed: evidence from advanced 3D

- sensing. *Plant Methods*, 19(1), 1–24. <https://doi.org/10.1186/s13007-023-01012-2>
- 296.Zatserkovnyy, A., Nurminski, E. (2022). Identification of Location and Camera Parameters for Public Live Streaming Web Cameras. *Mathematics*, 10 (19). <https://doi.org/10.3390/math10193601>
- 297.Zhai, Z., Zhu, Z., Du, Y., Song, Z., Mao, E. (2016). Multi-crop-row detection algorithm based on binocular vision. *Biosyst Eng* 150:89–103. <https://doi.org/10.1016/j.biosystemseng.2016.07.009>
- 298.Zhang Z. (1996). On the epipolar geometry between two images with lens distortion. In: *Proceedings of the 13th international conference on pattern recognition*. Vol. 1: Vienna, Austria, pp. 407–411.
- 299.Zhang Z. (1999). Flexible camera calibration by viewing a plane from unknown orientations. In: *Seventh international conference on computer vision (ICCV'99)*. Vol. 1: Kerkyra, Greece; pp. 666.
- 300.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.
- 301.Zhang, Z. (2000). A flexible new technique for camera calibration. *IEEE Trans. Pattern Anal. Machine Intell.* 22 (11), 1330–1334
- 302.Zhang, Z.B., Li, P., Zhao, S.L., Lv, Z.M., Du, F., An, Y.J. (2021). An Adaptive Vision Navigation Algorithm in Agricultural IoT System for Smart Agricultural Robots. *CMC Comput. Mater. Continua*, 66, 1043–1056. [CrossRef]
- 303.Zhao, J.Q., Zeng, P., Pan, B., Lei, L.P., Du, H.F., He, W.B., Xu, Y.J. (2012). Improved Hermite finite element smoothing method for full-field strain measurement over arbitrary region of interest in digital

-
- image correlation. *Optics and Lasers in Engineering*, 50(11), 1662-1671. <https://doi.org/10.1016/j.optlaseng.2012.04.008>.
- 304.Zhou, Y., Xu, T., Zheng, W., Deng, H. (2017). Classification and recognition approaches of tomato main organs based on DCNN. *Transactions of the Chinese Society of Agricultural Engineering*, 33(15), 219-226.
- 305.Zsomné, M.V. (2008). Dinamikus módszerek kertészeti termények jellemzésére. PhD disszertáció. Témavezető: Dr. Felföldi József. Budapesti Corvinus Egyetem, Budapest.
- 306.URL¹:<https://wyss.harvard.edu/technology/robobees-utonomous-flying-microrobots/>
- 307.URL²: <https://www.irrometer.com/sensors.html>
- 308.URL³: <https://www.tensorflow.org>
- 309.URL⁴: <https://blog.tensorflow.org/2021/06/how-tensorflow-helps-edge-impulse-make-ml-accessible.html>.
- 310.URL⁵: <https://www.elektrobot.hu/>
- 311.URL⁶:<https://components101.com/sensors/melexis-mlx90614-contact-less-ir-temperature-sensor>
- 312.URL⁷:https://cdn.sparkfun.com/assets/e/7/3/b/1/BME280_Datasheet.pdf
- 313.URL⁸:<https://pdf1.alldatasheet.com/datasheet-pdf/view/338083/ROHM/BH1750FVI.html>
- 314.URL⁹:<https://5.imimg.com/data5/SELLER/Doc/2022/6/OQ/AZ/IL/391686/7-in-1-soil-sensor.pdf>
- 315.URL¹⁰: <https://www.edgeimpulse.com/>
- 316.URL¹¹: <https://www.tensorflow.org/>
-

317.URL¹²:<https://helpx.adobe.com/x-productkb/multi/lens-profile-support.html>

318.URL¹³: <https://reprap.org/wiki/Ciclop>

319.URL¹⁴: <https://github.com/LibreScanner/horus>

320.URL¹⁵: <https://appinventor.mit.edu/>

321.URL¹⁶: <https://programming-surgeon.com/en/sphere-fit-python>

10. JELMAGYARÁZAT

R^2 – korrelációs együttható

a, b – korrelációs konstansok a tömegmeghatározás esetében (-)

c, d – korrelációs konstansok a termésszám meghatározás esetében (-)

\bar{M} – kézi módszerrel meghatározott paradicsom tömegek átlaga (kg)

M – kézi módszerrel meghatározott paradicsom tömegek átlaga (kg)

\bar{N} – kézi módszerrel meghatározott paradicsom termésszám átlaga (db)

N – kézi módszerrel meghatározott paradicsom termésszám átlaga (db)

\overline{m}_x – számítással meghatározott paradicsom tömegek átlaga (kg)

m_x – számítással meghatározott paradicsom tömegek (kg)

H_x – kézi módszerrel meghatározott paradicsom tömegek abszolút hibája (kg)

h_x – számítással meghatározott paradicsom tömegek abszolút hibája (%)

x – adott kísérlet sorszáma a paradicsom tömeg meghatározásakor (-)

\overline{n}_y – számítással meghatározott paradicsom termésszám átlaga (kg)

H_y – számítással meghatározott paradicsom termésszám abszolút hibája (kg)

h_y – számítással meghatározott paradicsom termésszám relatív hibája (%)

y – adott kísérlet sorszáma a paradicsom termésszám meghatározásakor (-)

\bar{x} – átlag

σ – szórás

Adjusted R^2 – Magyarázóerő nagysága (-)

Unstandardized coefficients β – a regressziós egyenes képlete

Standardized coefficients β – a regressziós egyenes meredeksége

11. MELLÉKLETEK

1. Melléklet – A CNN tréning Python program

```

import os
import tensorflow as tf
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.applications import MobileNetV2
from tensorflow.keras.layers import BatchNormalization,
Conv2D, Softmax, Reshape
from tensorflow.keras.models import Model
from tensorflow.keras.constraints import MaxNorm
import tensorflow.keras.metrics as metrics
import tensorflow.keras.preprocessing as util
import tensorflow.keras.preprocessing.image as image
from tensorflow.keras.callbacks import ModelCheckpoint
from pathlib import Path
import requests

def build_model(input_shape: tuple, weights: str, alpha:
float,
                num_classes: int) -> tf.keras.Model:

    mobile_net_v2 = MobileNetV2(input_shape=input_shape,
                                weights=weights,
                                alpha=alpha,
                                include_top=True)

    for layer in mobile_net_v2.layers:
        if type(layer) == BatchNormalization:
            layer.momentum = 0.9

    cut_point =
mobile_net_v2.get_layer('block_6_expand_relu')
    model = Conv2D(filters=32, kernel_size=1, strides=1,
                    activation='relu',
name='head')(cut_point.output)
    logits = Conv2D(filters=num_classes, kernel_size=1,
strides=1,
                    activation=None,
name='logits')(model)
    return Model(inputs=mobile_net_v2.input,
outputs=logits)

def train(num_classes: int, learning_rate: float,
num_epochs: int,
          alpha: float, object_weight: float,
          train_dataset: tf.data.Dataset,
          validation_dataset: tf.data.Dataset,
          best_model_path: str,
          input_shape: tuple,
          lr_finder: bool = False) -> tf.keras.Model:
    nonlocal callbacks
    num_classes_with_background = num_classes + 1

```

```

input_width_height = None
width, height, input_num_channels = input_shape
if width != height:
    raise Exception(f"Only square inputs are
supported; not {input_shape}")
input_width_height = width
weights = None
if input_num_channels == 1:
    if alpha == 0.1:
        weights = "./transfer-learning-
weights/edgeimpulse/MobileNetV2.0_1.96x96.grayscale.bsiz
e_64.lr_0_05.epoch_441.val_loss_4.13.val_accuracy_0.2.hd
f5"
        elif alpha == 0.35:
            weights = "./transfer-learning-
weights/edgeimpulse/MobileNetV2.0_35.96x96.grayscale.bsi
ze_64.lr_0_005.epoch_260.val_loss_3.10.val_accuracy_0.35
.hdf5"
        elif input_num_channels == 3:
            if alpha == 0.1:
                weights = "./transfer-learning-
weights/edgeimpulse/MobileNetV2.0_1.96x96.color.bsize_64
.lr_0_05.epoch_498.val_loss_3.85.hdf5"
            elif alpha == 0.35:
                weights = "./transfer-learning-
weights/keras/mobilenet_v2_weights_tf_dim_ordering_tf_ke
rnels_0.35_96.h5"
            if (weights and not os.path.exists(weights)):
                print(f"Pretrained weights {weights}
unavailable; downloading...")
                p = Path(weights)
                if not p.exists():
                    if not p.parent.exists():
                        p.parent.mkdir(parents=True)
                    root_url = 'https://cdn.edgeimpulse.com/'
                    weights_data = requests.get(root_url +
weights[2:]).content
                    with open(weights, 'wb') as f:
                        f.write(weights_data)
                print(f"Pretrained weights {weights}
unavailable; downloading OK\n")
            model = build_model(
                input_shape=input_shape,
                weights=weights,
                alpha=alpha,
                num_classes=num_classes_with_background
            )
model_output_shape = model.layers[-1].output.shape
_batch, width, height, num_classes =

```

```

model_output_shape
    if width != height:
        raise Exception(f"Only square outputs are
supported; not {model_output_shape}")
        output_width_height = width
        weighted_xent =
models.construct_weighted_xent_fn(model.output.shape,
object_weight)
        train_segmentation_dataset =
train_dataset.map(dataset.bbox_to_segmentation(
            output_width_height,
            num_classes_with_background)).batch(32,
            drop_remainder=False).prefetch(1)
        validation_segmentation_dataset =
validation_dataset.map(dataset.bbox_to_segmentation(
            output_width_height,
            num_classes_with_background, validation=True)).batch(32,
            drop_remainder=False).prefetch(1)
        util.set_classifier_biases_from_dataset(
            model, train_segmentation_dataset)
        if lr_finder:
            learning_rate =
ei_tensorflow.lr_finder.find_lr(model,
train_segmentation_dataset, weighted_xent)
            model.compile(loss=weighted_xent,
optimizer=Adam(learning_rate=learning_rate))
            callbacks = callbacks if callbacks else []
            callbacks.append(metrics.CentroidScoring(validation_segmen
tation_dataset,
output_width_height, num_classes_with_background))
            callbacks.append(metrics.PrintPercentageTrained(num_epoc
hs))
            callbacks.append(
tf.keras.callbacks.ModelCheckpoint(best_model_path,
monitor='val_f1', save_best_only=True,
mode='max',
save_weights_only=True, verbose=0))
            model.fit(train_segmentation_dataset,
validation_data=validation_segmentation_dataset,
epochs=num_epochs, callbacks=callbacks,
verbose=0)
            model.load_weights(best_model_path)
            softmax_layer = Softmax()(model.layers[-1].output)
            model = Model(model.input, softmax_layer)
            return model
EPOCHS = args.epochs or 60
LEARNING_RATE = args.learning_rate or 0.001
model = train(num_classes=classes,
learning_rate=LEARNING_RATE,

```

```
        num_epochs=EPOCHS,  
        alpha=0.35,  
        object_weight=100,  
        train_dataset=train_dataset,  
        validation_dataset=validation_dataset,  
        best_model_path=BEST_MODEL_PATH,  
        input_shape=MODEL_INPUT_SHAPE,  
        lr_finder=False)  
override_mode = 'segmentation'  
disable_per_channel_quantization = False
```

2. Melléklet – A szegmentáció Python programja

```

#könyvtárak importálása
import cv2
import numpy as np
import imutils
import math
import csv
from scipy import ndimage
from skimage.feature import peak_local_max
from skimage.morphology import watershed
#változók megadása
cnt = 0
full_weight = 0
density = 1.0649 # paradicsom átlagsűrűség
distance = 100 # LiDAT távolságadatok
coef = 162.99 * math.exp(-0.029 * distance)
#képek megnyitása
img = cv2.imread('T1-1.jpg')
#újráméretezés
img = imutils.resize(img, width=640)
img2 = img.copy()
#HSV konverzió
hsv = cv2.cvtColor(img, cv2.COLOR_BGR2HSV)
#HSV kép mentése
cv2.imwrite('/home/hsv.jpg', cv2.cvtColor(hsv,
cv2.COLOR_RGB2BGR))
#szegmenetációs hatáértékek megadása
lower_red = np.array([0.62,0])
upper_red = np.array([15.255,255])
mask = cv2.inRange(hsv, lower_red, upper_red)
gray = mask
kernel = np.ones((2,2), np.uint8)
gray = cv2.erode(gray, kernel, iterations = 1)
#konvertálása bináris képpé
red_mask = cv2.dilate(gray, kernel)
res_red = cv2.bitwise_and(img, img, mask = gray)
thresh = cv2.threshold(gray, 0, 255, cv2.THRESH_BINARY |
cv2.THRESH_OTSU)[1]
# watershed algoritmus
D = ndimage.distance_transform_edt(thresh)
localMax = peak_local_max(D, indices=False, min_distance=2,
labels=thresh)
markers = ndimage.label(localMax, structure=np.ones((3,
3)))[0]
labels = watershed(-D, markers, mask=thresh)
print("Found segments".format(len(np.unique(labels)) - 1))
# .csv file beállítása
file = open("mass_data.csv", "a")
file.write("No.Radous.Area.Volume.Mass.\n")
while True:
    for label in np.unique(labels):
        if label == 0:

```

```

        continue
mask = np.zeros(gray.shape, dtype="uint8")
mask[labels == label] = 255
# kontúrok keresése
cnts = cv2.findContours(mask.copy(),
cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)
cnts = imutils.grab_contours(cnts)
c = max(cnts, key=cv2.contourArea)
((x, y), r) = cv2.minEnclosingCircle(c)
if r > 13 and r < 100: # körök illesztése
    cv2.circle(img, (int(x), int(y)), int(r),
(0, 255, 0), 2)
    cv2.circle(thresh, (int(x), int(y)),
int(r), (100, 100, 100), 2)
    # felület, térfogat, tömeg meghatározása
    area = r**2 * math.pi
    real_area = area / coef
    volume = (4/3) * ((real_area) **
(3/2))/(math.sqrt(math.pi))
    weight = volume * density / 1000
    full_weight += weight
    # adatok kiírása
    print(str(cnt + 1) + "; radius: " +
str(r) + "; area:" + str(area) + ";
real_area:" + str(real_area) + "; volume: "
+ str(volume) + "; weigh: " + str(weight))
    cv2.putText(img, "{}".format(round(cnt +
1)), (int(x) - 10, int(y)),
cv2.FONT_HERSHEY_SIMPLEX, 0.6, (0,
0, 255), 2)
    cnt += 1
    # adatok mentése
    file.write(str(cnt)+";" +str(r)+";" +str(are
a)+";" +str(volume) + ";" +str(weight)+"\n")
    file.flush()
contours, hierarchy = cv2.findContours(red_mask,
cv2.RETR_TREE, cv2.CHAIN_APPROX_SIMPLE)
# kontúrok illesztése
for pic, contour in enumerate(contours):
    area = cv2.contourArea(contour)
    if(area > 5):
        x, y, w, h = cv2.boundingRect(contour)
        cv2.drawContours(img2, contour, -1, (255,
0, 0), 2)
        area = cv2.contourArea(contour)
        cv2.drawContours(img2, [contour], -
1, (255, 0, 0), 2)
    # képek mentése
    cv2.imwrite('/home/thresh.jpg', cv2.cvtColor(thresh,
cv2.COLOR_RGB2BGR))
    cv2.imwrite('/home/gray.jpg', cv2.cvtColor(gray,
cv2.COLOR_RGB2BGR))
    cv2.imwrite('/home/circle.jpg',
cv2.cvtColor(img, cv2.COLOR_RGB2BGR))

```

```
    cv2.imwrite('/home/contour.jpg'.  
cv2.cvtColor(img2.v2.COLOR_RGB2BGR))  
    # adatok kiírása terminálba  
    print("{} tomato_found".format(cnt))  
    print("{} weight".format(full_weight))  
    cv2.destroyAllWindows()  
    break
```

3. melléklet – A megvilágítás mérő Arduino program

```
#include <BH1750.h>
#include <Wire.h>
BH1750 lightMeter(0x23);
void setup() {
  Serial.begin(9600);
  Wire.begin();
  if
(lightMeter.begin(BH1750::CONTINUOUS_HIGH_RES_MODE_2)) {
    Serial.println(F("BH1750 Advanced begin"));
  } else {
    Serial.println(F("Error initialising BH1750"));
  }
}

void loop() {
  if (lightMeter.measurementReady()) {
    float lux = lightMeter.readLightLevel();
    Serial.print("Light: ");
    Serial.print(lux);
    Serial.println(" lx");
  }
}
```

4. melléklet – A robot navigációs Python alprogramja

```

from adafruit_rplidar import RPLidar
from math import floor
import RPi.GPIO as GPIO
from time import sleep
from _XiaoRGEEEK_MOTOR_ import Robot_Direction
rob = Robot_Direction()

class Tomato_Detection_Robot:
    def __init__(self):
        PORT_NAME = '/dev/ttyUSB0'
        self.lidar = RPLidar(None, PORT_NAME,
timeout=30)
        self.con_scan = True
        GPIO.setmode(GPIO.BCM)
    def get_data_from_LIDAR(self):
        if(self.con_scan):
            try:
                print(self.lidar.info)
                for scan in self.lidar.iter_scans():
                    self.scan_data = [0]*360
                    for (_, angle, distance) in scan:
                        self.scan_data[min([359,
floor(angle)]]] = distance
                    self.process_lidar_data(211, 60,
300, 339, 350, 10)
            except KeyboardInterrupt:
                self.con_scan = False
                print("\nLIDAR Stopped!")
                self.lidar.stop()
                self.lidar.disconnect()
                GPIO.cleanup()
    def process_lidar_data(self, r_ang_s, r_ang_e,
l_ang_s, l_ang_e, f_ang_s, f_ang_e, t=400, t2=600,
_range=20, _front_range=10):
        r_start = r_end = l_start = l_end = f_start =
f_end = 3000
        for i in range(_range):
            _angle = r_ang_s + i
            if(self.scan_data[_angle] > 1):
                r_start = self.scan_data[_angle]
                break
        for i in range(_range):
            _angle = r_ang_e - i
            if(self.scan_data[_angle] > 1):
                r_end = self.scan_data[_angle]

```

```

        break
    for i in range(_range):
        _angle = l_ang_s + i
        if(self.scan_data[_angle] > 1):
            l_start = self.scan_data[_angle]
            break
    for i in range(_range):
        _angle = l_ang_e - i
        if(self.scan_data[_angle] > 1):
            l_end = self.scan_data[_angle]
            break
    for i in range(_front_range):
        _angle = f_ang_s + i
        if(self.scan_data[_angle] > 1):
            f_start = self.scan_data[_angle]
            print("Front Dis. Start = " +
str(f_start))
            break
    for i in range(_front_range):
        _angle = f_ang_e - i
        if(self.scan_data[_angle] > 1):
            f_end = self.scan_data[_angle]
            print("Front Dis. End = " + str(f_end))
            break
    if((f_start < t2) or (f_end < t2)):
        print("\nStop!")
        rob.stop()
        print("Front!", f_start, f_end)
    elif((r_start < t) or (r_end < t)) and
((l_start < t) or (l_end < t)):
        rob.stop()
        print("Jobb!")
        rob.forward()
    elif((r_start < t) or (r_end < t)):
        rob.stop()
        print("Jobb!")
        rob.left()
    elif((l_start < t) or (l_end < t)):
        rob.stop()
        print("Bal!")
        rob.right()
    else:
        rob.forward()
        print("Go!")
robot = Tomato_Detection_Robot()
while True:
    robot.get_data_from_LIDAR()

```

5. melléklet – A robot kamera lencsokorrekciós fileja

```

<?xpacket begin="" id="W5M0MpCehiHzreSzNTczkc9d"?>
<x:xmpmeta xmlns:x="adobe:ns:meta/" x:xmp:tk="Adobe XMP Core 5.3-c007
1.136881. 2010/06/10-18:11:35 "">
  <rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#"
  <rdf:Description rdf:about=""
    xmlns:photoshop="http://ns.adobe.com/photoshop/1.0/"
    xmlns:stCamera="http://ns.adobe.com/photoshop/1.0/camera-
profile">
  <photoshop:CameraProfiles>
  <rdf:Seq>
    <rdf:li rdf:parseType="Resource">
      <stCamera:ProfileName>Robot</stCamera:ProfileName>

<stCamera:ImageWidth>640.000000</stCamera:ImageWidth>
<stCamera:ImageLength>480.000000</stCamera:ImageLength>
<stCamera:XResolution>72.000000</stCamera:XResolution>
<stCamera:YResolution>72.000000</stCamera:YResolution>
  <stCamera:LensPrettyName>1</stCamera:LensPrettyName>
<stCamera:CameraPrettyName>1</stCamera:CameraPrettyName>
<stCamera:CameraRawProfile>False</stCamera:CameraRawProfile>
<stCamera:FocusDistance>1.000132</stCamera:FocusDistance>
<stCamera:SensorFormatFactor>0.999143</stCamera:SensorFormatFactor>
  <stCamera:FisheyeModel rdf:parseType="Resource">
    <stCamera:Version>2</stCamera:Version>
<stCamera:FocalLengthX>0.809882</stCamera:FocalLengthX>
<stCamera:FocalLengthY>0.809882</stCamera:FocalLengthY>
<stCamera:ImageXCenter>0.552475</stCamera:ImageXCenter>
<stCamera:ImageYCenter>0.530187</stCamera:ImageYCenter>
  <stCamera:RadialDistortParam1>-
0.048326</stCamera:RadialDistortParam1>
  <stCamera:RadialDistortParam2>-
0.122998</stCamera:RadialDistortParam2>
<stCamera:ResidualMeanError>0.000217</stCamera:ResidualMeanError>
<stCamera:ResidualStandardDeviation>0.000119</stCamera:ResidualStandar
dDeviation>
  <stCamera:ChromaticGreenModel
rdf:parseType="Resource">
<stCamera:FocalLengthX>0.807074</stCamera:FocalLengthX>
<stCamera:FocalLengthY>0.807074</stCamera:FocalLengthY>
<stCamera:ImageXCenter>0.550254</stCamera:ImageXCenter>
<stCamera:ImageYCenter>0.533350</stCamera:ImageYCenter>
  <stCamera:RadialDistortParam1>-
0.038116</stCamera:RadialDistortParam1>
  <stCamera:RadialDistortParam2>-
0.137124</stCamera:RadialDistortParam2>
<stCamera:ResidualMeanError>0.000206</stCamera:ResidualMeanError>
<stCamera:ResidualStandardDeviation>0.000108</stCamera:ResidualStandar
dDeviation>
  </stCamera:ChromaticGreenModel>
  <stCamera:ChromaticRedGreenModel
rdf:parseType="Resource">
<stCamera:ScaleFactor>1.000160</stCamera:ScaleFactor>
<stCamera:FocalLengthX>0.807074</stCamera:FocalLengthX>
<stCamera:FocalLengthY>0.807074</stCamera:FocalLengthY>
<stCamera:ImageXCenter>0.550254</stCamera:ImageXCenter>
<stCamera:ImageYCenter>0.533350</stCamera:ImageYCenter>
<stCamera:RadialDistortParam1>0.001066</stCamera:RadialDistortParam1>
  <stCamera:RadialDistortParam2>-

```



```
0.024643</stCamera:RadialDistortParam2>
<stCamera:RadialDistortParam3>0.082441</stCamera:RadialDistortParam3>
<stCamera:ResidualMeanError>0.000240</stCamera:ResidualMeanError>
<stCamera:ResidualStandardDeviation>0.000129</stCamera:ResidualStandardDeviation>
    </stCamera:ChromaticRedGreenModel>
    <stCamera:ChromaticBlueGreenModel
rdf:parseType="Resource">
<stCamera:ScaleFactor>1.000806</stCamera:ScaleFactor>
<stCamera:FocalLengthX>0.807074</stCamera:FocalLengthX>
<stCamera:FocalLengthY>0.807074</stCamera:FocalLengthY>
<stCamera:ImageXCenter>0.550254</stCamera:ImageXCenter>
<stCamera:ImageYCenter>0.533350</stCamera:ImageYCenter>
    <stCamera:RadialDistortParam1>-
0.013061</stCamera:RadialDistortParam1>
<stCamera:RadialDistortParam2>0.087903</stCamera:RadialDistortParam2>
    <stCamera:RadialDistortParam3>-
0.173090</stCamera:RadialDistortParam3>
<stCamera:ResidualMeanError>0.000207</stCamera:ResidualMeanError>
<stCamera:ResidualStandardDeviation>0.000112</stCamera:ResidualStandardDeviation>
    </stCamera:ChromaticBlueGreenModel>
    </stCamera:FisheyeModel>
  </rdf:li>
</rdf:Seq>
</photoshop:CameraProfiles>
</rdf:Description>
</rdf:RDF>
</x:xmpmeta>
```

6. melléklet – A megvilágítás HSV értékei az egyes képeken a jellemző színek alapján

No	Megvilágítás (lx)	Szín 1			Szín 2		
		h	s	v	h	s	v
1	11935,42	3	186	196	1	131	109
2	10366,56	3	196	180	2	145	97
3	9023,33	3	204	166	2	158	87
4	7388,58	3	210	152	2	168	79
5	5130,5	3	196	144	2	185	87
6	4010,42	3	202	134	3	186	78
7	2970,67	3	207	118	3	190	67
8	2218,17	3	208	107	3	193	58
9	1635,83	3	214	88	4	197	48
10	1635,83	3	220	72	4	203	39
11	1132,67	3	217	40	4	215	39
12	744,17	5	217	20	3	229	39
13	475,25	1	234	24	5	234	12
14	282,67	2	255	13	6	213	6
15	123,08	15	255	2	0	255	6

 7. Melléklet – A CNN klaszterező Python alprogram

```

import cv2
import os
import sys, getopt
import signal
import time
from datetime import datetime
from edge_impulse_linux.image import ImageImpulseRunner
from piezo import Piezo
piezo = Piezo()
from PIL import Image
import PIL
runner = None
show_camera = True
if (sys.platform == 'linux' and not
os.environ.get('DISPLAY')):
    show_camera = False
def now():
    return round(time.time() * 1000)
def get_webcams():
    port_ids = []
    for port in range(5):
        print("Looking for a camera in port %s:" %port)
        camera = cv2.VideoCapture(port)
        if camera.isOpened():
            ret, frame = camera.read()
            if ret:
                backendName =camera.getBackendName()
                w = camera.get(3)
                h = camera.get(4)
                print("Camera %s (%s x %s) found in port
%s " %(backendName,h,w, port))
                port_ids.append(port)
                camera.release()
    return port_ids
def sigint_handler(sig, frame):
    print('Interrupted')
    if (runner):
        runner.stop()
    sys.exit(0)
signal.signal(signal.SIGINT, sigint_handler)
def help():
    print('python classify.py <path_to_model.eim>
<Camera port ID, only required when more than 1 camera
is present>')
def main(argv=['leafunhealthy.eim']):
    print('argv', argv)

```

```

    try:
        opts, args = getopt.getopt(argv, "h", ["--
help"])
        print('args', args)
    except getopt.GetoptError:
        help()
        sys.exit(2)
    for opt, arg in opts:
        if opt in ('-h', '--help'):
            help()
            sys.exit()

    if len(args) == 0:
        help()
        sys.exit(2)

    model = args[0]
    print('args0', args[0])
    dir_path =
os.path.dirname(os.path.realpath(__file__))
    modelfile =
os.path.join('/home/pi/work/wifirobots/python_src',
model)
    print('MODEL: ' + modelfile)
    with ImageImpulseRunner(modelfile) as runner:
        x = 1
        y = 1
        try:
            model_info = runner.init()
            print('Loaded runner for "' +
model_info['project']['owner'] + ' / ' +
model_info['project']['name'] + '"')
            labels =
model_info['model_parameters']['labels']
            if len(args) >= 2:
                videoCaptureDeviceId = int(args[1])
            else:
                port_ids = get_webcams()
                if len(port_ids) == 0:
                    raise Exception('Cannot find any
webcams')

                if len(args) <= 1 and len(port_ids) > 1:
                    raise Exception("Multiple cameras
found. Add the camera port ID as a second argument to
use to this script")
                videoCaptureDeviceId = int(port_ids[0])

            camera =
cv2.VideoCapture(videoCaptureDeviceId)

```

```

        ret, frame = camera.read()
        y = y + 1
        if ret:
            backendName = camera.getBackendName()
            w = camera.get(3)
            h = camera.get(4)
            print("Camera %s (%s x %s) in port %s
selected." %(backendName,h,w, videoCaptureDeviceId))
            camera.release()
        else:
            raise Exception("Couldn't initialize
selected camera.")

        next_frame = 0 # limit to ~10 fps here

        for res, img, big in
runner.classifier(videoCaptureDeviceId):
            if (next_frame > now()):
                time.sleep((next_frame - now()) /
1000)
                if "classification" in
res["result"].keys():
                    print('Result (%d ms.) ' %
(res['timing']['dsp'] +
res['timing']['classification']), end='')
                    for label in labels:
                        score =
res['result']['classification'][label]
                        print('%s: %.2f\t' % (label,
score), end='')
                        print('', flush=True)

                    elif "bounding_boxes" in
res["result"].keys():
                        print('Found %d bounding boxes (%d
ms.)' % (len(res["result"]["bounding_boxes"]),
res['timing']['dsp'] + res['timing']['classification']))
                        for bb in
res["result"]["bounding_boxes"]:
                            with
open("/home/pi/pics_data.csv", "a") as file:
                                date =
datetime.now().strftime("%Y_%m_%d;%I:%M:%S")
                                print('\t%s (%.2f): x=%d
y=%d w=%d h=%d' % (bb['label'], bb['value'], bb['x'],
bb['y'], bb['width'], bb['height']))
                                img = cv2.rectangle(img,
(bb['x'], bb['y']), (bb['x'] + bb['width'], bb['y'] +
bb['height']), (255, 0, 0), 1)

```

```
        piezo.talalat()
        file.write(str(x) + ";" +
str(date) + ";" + '\t%s; %.2f; %d; %d; %d; %d' %
(bb['label'], bb['value'], bb['x'], bb['y'],
bb['width'], bb['height']))+ '\n')
        file.flush()
cv2.imwrite("/home/pi/kepek/kep" + str(x) + ".jpg" ,
img)

cv2.imwrite("/home/pi/kepek/k" + str(x) + ".jpg" , big)
        x = x+1
print(camera.get(cv2.CAP_PROP_FRAME_WIDTH))


        if (show_camera):
            cv2.imshow('edgeimpulse', img)
            if cv2.waitKey(1) == ord('q'):
                break
        next_frame = now() + 100
    finally:
        if (runner):
            runner.stop()

if __name__ == "__main__":
    main()
```


8. Melléklet – A DSLR kamera alapján meghatározott tömeg és természet adatok összehasonlítása és eltéréseik

Kezelések	Ismétlések	(mm)	M (kg)	m₁ (kg)	H_{m1} (kg)	h_{m1} (%)	m₂ (kg)	H_{m2} (kg)	h_{m2} (%)	N (db)	n₁ (db)	H_{n1} (db)	H_{n1} (%)
T1	T1-1	109.8	2.48	2.99	0.51	20.56	3.61	1.1379	45.88	128	112	16.00	12.50
	T1-2	109.8	1.17	0.91	0.26	22.22	1.10	0.0689	5.89	67	54	13.00	19.40
	T1-3	109.8	2.43	2.43	0.00	0.00	2.94	0.5103	21.00	98	81	17.00	17.35
	T1-4	109.8	3.34	4.48	1.14	34.13	5.42	2.0808	62.30	115	97	18.00	15.65
T2	T2-1	276.1	4.10	3.74	0.36	8.78	4.52	0.4254	10.38	143	121	22.00	15.38
	T2-2	276.1	2.82	2.51	0.31	10.99	3.03	0.2171	7.70	114	104	10.00	8.77
	T2-3	276.1	4.20	4.26	0.06	1.43	5.15	0.9546	22.73	149	124	25.00	16.78
	T2-4	276.1	7.14	4.72	2.42	33.89	5.71	1.4288	20.01	232	186	46.00	19.83
T3	T3-1	360.8	10.31	8.43	1.88	18.23	10.20	0.1097	1.06	197	150	47.00	23.86
	T3-2	360.8	5.63	4.66	0.97	17.23	5.63	0.0086	0.15	170	125	45.00	26.47
	T3-3	360.8	17.96	12.49	5.47	30.46	15.11	2.8471	15.85	337	180	157.00	46.59
	T3-4	360.8	13.46	9.72	3.74	27.79	11.76	1.6988	12.62	228	143	85.00	37.28
T4	T4-1	442.4	16.63	7.76	8.87	53.34	9.38	7.2404	43.54	297	162	135.00	45.45
	T4-2	442.4	16.8	7.23	9.57	56.96	8.74	8.0517	47.93	317	170	147.00	46.37
	T4-3	442.4	15.54	7.47	8.07	51.93	9.03	6.5013	41.84	242	116	126.00	52.07
	T4-4	442.4	14.48	11.18	3.30	22.79	13.52	0.9522	6.58	228	112	116.00	50.88
T0	T0-1	442.4	29.00	18.99	10.01	34.52	22.97	6.0221	20.77	388	204	184.00	47.42
	T0-2	442.4	21.65	11.83	9.82	45.36	14.31	7.3357	33.88	360	188	172.00	47.78
	T0-3	442.4	9.60	8.27	1.33	13.85	10.00	0.4067	4.24	169	157	12.00	7.10
	T0-4	442.4	8.43	7.93	0.50	5.93	9.59	1.1653	13.82	172	147	25.00	14.53
AVERAGE		326.3	10.35	7.1	3.42	25.52	8.59	2.45	21.90	207.55	136.65	70.90	28.57
STANDARD DEVIATION		127.7670	7.59	4.33	3.74	17.03	5.24	2.82	17.96	92.46	38.88	62.11	16.02

9. melléklet – A kézi mérésrel és a becsült paradicsomtömegek korrelációja a gömb modellel minden kezelésnél a DSLR kamerás képekről.



10. melléklet – A kézi mérésrel és a program által becsült paradicsomtömegek korrelációja a 3D-s modellel minden kezelésnél a DSLR kamerás képekről.




11. melléklet – A DSLR kamera alapján meghatározott tömeg és termés adatok összehasonlítása és eltéréseik a növényházás első mérésnél

Mintanövény sorszáma	M (kg)	m ₃ (kg)	m ₄ (kg)	N (db)	n ₂ (db)
1	2,71	2,54	2,72	15	16
2	3,31	3,32	3,55	21	21
3	4,25	3,88	4,15	24	24
4	5,49	4,96	5,31	38	38
5	1,96	1,83	1,95	13	13
6	2,95	2,12	2,27	19	21
7	2,29	2,15	2,30	9	10
8	3,4	3,33	3,56	18	19
9	3,17	2,92	3,12	21	20
10	3,11	2,93	3,13	18	17
11	4,41	4,23	4,53	26	26
12	3,17	2,42	2,59	17	19
13	3,13	3,42	3,66	19	16
14	2,27	2,24	2,40	12	12
15	2,12	2,13	2,28	13	10
16	2,69	1,84	1,96	15	12
17	1,83	1,18	1,26	10	13
18	2,87	2,87	3,07	15	13
19	1,32	0,95	1,02	8	7
20	2,23	2,21	2,36	11	11
21	1,23	0,97	1,04	7	7
22	1,39	1,01	1,08	8	6
23	1,54	1,21	1,29	9	10
24	2,4	1,83	1,95	13	13
25	0,91	0,54	0,58	6	7
26	1,21	1,38	1,47	12	11
27	0,89	1,01	1,08	6	7
Átlag	2,53	2,27	2,43	14,93	14,78
Szórás	1,11	1,11	1,18	7,14	7,19


12. melléklet – A DSLR kamera alapján meghatározott tömeg és termés adatok összehasonlítása és eltéréseik a növényházas második mérésnél

Mintanövény sorszáma	M (kg)	m ₅ (kg)	m ₆ (kg)	N (db)	n ₃ (db)
1	1,19	0,92	0,98	17	15
2	0,98	0,84	0,90	15	12
3	0,97	0,86	0,92	17	19
4	0,9	0,86	0,92	15	14
5	0,63	0,54	0,58	7	7
6	0,94	0,81	0,87	13	11
7	1,7	1,76	1,88	28	26
8	1,17	1,03	1,10	17	13
9	0,96	0,74	0,79	16	17
10	1,58	1,14	1,22	28	21
11	1,27	0,84	0,90	21	22
12	1,01	0,89	0,95	15	14
13	1,25	1,12	1,20	27	26
14	1,45	1,51	1,62	22	21
15	0,86	0,82	0,88	15	14
16	1,48	1,34	1,43	26	24
17	1,24	1,11	1,19	26	25
18	1,48	1,23	1,32	19	15
19	1,38	1,31	1,40	26	24
20	1,19	0,98	1,05	15	11
21	1,4	0,89	0,95	25	18
22	1,04	0,94	1,01	14	16
23	1,65	1,23	1,32	29	19
24	1,16	1,06	1,13	20	18
25	0,95	0,82	0,88	17	15
26	2,04	1,98	2,12	49	42
27	1,51	1,54	1,65	24	26
Átlag	1,24	1,08	1,15	20,85	18,70
Szórás	0,31	0,33	0,35	8,00	6,99


13. melléklet – A kézi méréssel és a program által becsült paradicsomtömegek korrelációja a gömb modellel a DSLR kamerás képekről a növényház első mérésnél




14. melléklet – A kézi méréssel és a program által becsült paradicsomtömegek korrelációja a 3D modellel a DSLR kamerás képekről a növényház első mérésnél dslr



15. melléklet – A kézi méréssel és a program által becsült paradicsomtömegek korrelációja a gömb modellel a DSLR kamerás képekről a növényházas második mérésnél




16. melléklet – A kézi méréssel és a program által becsült paradicsomtömegek korrelációja a 3D modellel a DSLR kamerás képekről a növényházas második mérésnél




17. Melléklet – A robot kamera alapján meghatározott tömeg és termékszám adatok összehasonlítása és eltéréseik

Kezelések	Ismétlések	(mm)	M (kg)	m ₇ (kg)	H _{m7} (kg)	h _{m7} (%)	m ₈ (kg)	H _{m8} (kg)	h _{m8} (%)	N (db)	n ₄ (db)	H _{n4} (db)	h _{n4} (%)	n ₅ (db)	H _{n5} (db)	H _{n5} (%)
T1	T1-1	109.8	2.48	0.45	2.03	81.85	0.54	1.13	45.88	128	32	96.00	75.00	41	32	87
	T1-2	109.8	1.17	0.11	1.06	90.60	0.13	0.06	5.89	67	15	52.00	77.61	11	15	56
	T1-3	109.8	2.43	0.32	2.11	86.83	0.38	0.51	21.00	98	14	84.00	85.71	16	14	82
	T1-4	109.8	3.34	NA	NA	NA	NA	NA	NA	115	NA	NA	NA	NA	NA	115
T2	T2-1	276.1	4.10	0.83	3.27	79.76	1.00	0.42	10.38	143	37	106.00	74.13	32	37	111
	T2-2	276.1	2.82	NA	NA	NA	NA	NA	NA	114	NA	NA	NA	NA	NA	114
	T2-3	276.1	4.20	0.46	3.74	89.05	0.55	0.95	22.73	149	28	121.00	81.21	20	28	129
	T2-4	276.1	7.14	1.67	5.47	76.61	2.02	1.42	20.01	232	57	175.00	75.43	42	57	190
T3	T3-1	360.8	10.31	1.62	8.69	84.29	1.96	0.10	1.06	197	54	143.00	72.59	39	54	158
	T3-2	360.8	5.63	1.14	4.49	79.75	1.37	0.01	0.15	170	38	132.00	77.65	45	38	125
	T3-3	360.8	17.96	3.67	14.29	79.57	4.44	2.84	15.85	337	59	278.00	82.49	40	59	297
	T3-4	360.8	13.46	NA	NA	NA	NA	NA	NA	228	NA	NA	NA	NA	NA	228
T4	T4-1	442.4	16.63	3.12	13.51	81.24	3.77	7.24	43.54	297	57	240.00	80.81	62	57	235
	T4-2	442.4	16.8	3.17	13.63	81.13	3.83	8.05	47.93	317	66	251.00	79.18	42	66	275
	T4-3	442.4	15.54	3.23	12.31	79.21	3.90	6.50	41.84	242	55	187.00	77.27	31	55	211
	T4-4	442.4	14.48	4.57	9.91	68.44	5.52	0.95	6.58	228	30	198.00	86.84	43	30	185
T0	T0-1	442.4	29	6.09	22.91	79.00	7.36	6.02	20.77	388	76	312.00	80.41	72	76	316
	T0-2	442.4	21.65	6.23	15.42	71.22	7.53	7.33	33.88	360	58	302.00	83.89	51	58	309
	T0-3	442.4	9.60	NA	NA	NA	NA	NA	NA	169	NA	NA	NA	NA	NA	169
	T0-4	442.4	8.43	2.10	6.33	75.09	2.54	1.16	13.82	172	41	131.00	76.16	69	41	103
AVERAGE		326.3	10.35	2.42	8.69	80.22	2.93	8.18	76.07	207.55	44.81	175.5	79.15	41	175	84,23
STANDARD DEVIATION		127.7670	7.59	1.98	6.18	5.84	2.39	5.80	7.07	92.46	18.08	80.95	4.17	17,24	80,4	10,55

18. melléklet – A mért és számított paradicsomtömeg-közelítés korrelációja a gömbmodellel való közelítéskor minden kezelésnél a kis robotkamerás képekből



19. melléklet – A mért és számított paradicsomtömeg közelítés korrelációja a 3D modellel való közelítéskor minden kezelésnél a kis robotkamerás képekből




20. melléklet – A robot kamera alapján meghatározott tömeg és termés adatok összehasonlítása és eltérései a növényházas első mérésnél

Mintanövény sorszáma	M (kg)	m₉ (kg)	m₁₀ (kg)	N (db)	n₆ (db)	n₇ (db)
1	2,71	2,41	2,58	15	10	13
2	3,31	2,7	2,89	21	13	22
3	4,25	3	3,21	24	17	17
4	5,49	4,86	5,20	38	24	32
5	1,96	1,31	1,40	13	13	14
6	2,95	2,06	2,20	19	18	15
7	2,29	1,96	2,10	9	6	9
8	3,4	2,84	3,04	18	14	16
9	3,17	2,84	3,04	21	17	20
10	3,11	2,57	2,75	18	19	15
11	4,41	2,75	2,94	26	20	21
12	3,17	2,34	2,50	17	12	17
13	3,13	2,88	3,08	19	14	15
14	2,27	1,86	1,99	12	8	13
15	2,12	2,21	2,36	13	13	14
16	2,69	2,42	2,59	15	9	12
17	1,83	1,72	1,84	10	7	9
18	2,87	2,23	2,39	15	12	12
19	1,32	1,36	1,46	8	5	7
20	2,23	1,98	2,12	11	11	10
21	1,23	0,81	0,87	7	7	5
22	1,39	0,94	1,01	8	5	6
23	1,54	0,95	1,02	9	5	6
24	2,4	1,86	1,99	13	10	9
25	0,91	0,62	0,66	6	6	4
26	1,21	0,86	0,92	12	9	8
27	0,89	0,42	0,45	6	4	3
Átlag	2,53	2,03	2,17	14,93	11,41	12,74
Szórás	1,11	0,95	1,02	7,14	5,26	6,42


21. melléklet – A robot kamera alapján meghatározott tömeg és termés adatok összehasonlítása és eltéréseik a növényházas második mérésnél

Mintanövény sorszáma	M (kg)	m₁₁ (kg)	m₁₂ (kg)	N (db)	n₈ (db)	n₉ (db)
1	1,19	0,86	0,92	17	11	13
2	0,98	0,81	0,87	15	13	12
3	0,97	0,78	0,83	17	11	13
4	0,9	0,65	0,70	15	9	11
5	0,63	0,42	0,45	7	3	5
6	0,94	0,72	0,77	13	8	10
7	1,7	1,13	1,21	28	17	23
8	1,17	0,9	0,96	17	11	12
9	0,96	0,84	0,90	16	14	16
10	1,58	1,18	1,26	28	14	19
11	1,27	0,76	0,81	21	9	16
12	1,01	0,87	0,93	15	9	11
13	1,25	0,96	1,03	27	18	22
14	1,45	1,23	1,32	22	16	17
15	0,86	0,54	0,58	15	9	9
16	1,48	1,09	1,17	26	19	19
17	1,24	0,89	0,95	26	18	18
18	1,48	0,96	1,03	19	12	11
19	1,38	0,86	0,92	26	21	16
20	1,19	0,76	0,81	15	11	12
21	1,4	0,97	1,04	25	17	18
22	1,04	0,64	0,68	14	11	8
23	1,65	1,18	1,26	29	21	19
24	1,16	0,86	0,92	20	12	12
25	0,95	0,65	0,70	17	17	11
26	2,04	1,52	1,63	49	31	28
27	1,51	0,96	1,03	24	19	18
Átlag	1,24	0,89	0,95	20,85	14,11	14,78
Szórás	0,31	0,23	0,25	8,00	5,58	5,12


22. melléklet – A kézi méréssel és a program által becsült paradicsomtömegek korrelációja a gömb modellel a robot képekből a növényházas első mérésnél




23. melléklet – A kézi méréssel és a program által becsült paradicsomtömegek korrelációja a 3D modellel a robot képekből a növényházas első mérésnél




24. melléklet – A kézi méréssel és a program által becsült paradicsomtömegek korrelációja a gömb modellel a robot képekből a növényházas második mérésnél




25. melléklet – A kézi méréssel és a program által becsült paradicsomtömegek korrelációja a gömb modellel a robot képekből a növényházas második mérésnél




26. melléklet – A DSLR fényképezőgép képeiből származó paradicsomtermés számának kézi mérése és becsült értékének korrelációja minden kezelésre nézve




27. melléklet – A DSLR fényképezőgép képeiből származó paradicsomtermés számának kézi mérése és becsült értékének korrelációja az első növényházas kísérletnél




28. melléklet – A DSLR fényképezőgép képeiből származó paradicsomtermés számának kézi mérése és becült értékének korrelációja a második növényházas kísérletnél




29. melléklet – A robot képeiből származó paradicsomtermés számának kézi mérése és CNN által becült értékének korrelációja minden kezelésre nézve




30. melléklet – A robot képeiből származó paradicsomtermés számának kézi mérése és szegmentáció által becsült értékének korrelációja minden kezelésre nézve




31. melléklet – A robot képeiből származó paradicsomtermés számának kézi mérése és CNN által becsült értékének korrelációja a növényház első mérésnél




32. melléklet – A robot képeiből származó paradicsomtermés számának kézi mérése és szegmentáció által becsült értékének korrelációja a növényházas első mérésnél



33. melléklet – A robot képeiből származó paradicsomtermés számának kézi mérése és CNN által becsült értékének korrelációja a növényházas második mérésnél



34. melléklet – A robot képeiből származó paradicsomtermés számának kézi mérése és szegmentáció által becsült értékének korrelációja a növényházas második mérésnél



12. ÁBRAJEGYZÉK

1. ábra – Egy mezőgazdasági robot általános részei (UTSTUMOA, 2018).	13
2. ábra – Biológia inspirálta mikrorobot (URL ¹)	19
3. ábra – Robotirányítási módszerek (FRAGAPANE, 2021)	32
4. ábra – Mezőgazdasági mobil robotok autonóm navigációs rendszerének alapelemei (Forrás: SHALAL et al., 2013)	33
5. ábra – A növények kézzel mért (kék kereszt) és számított helyzete (zöld kereszt) (TILLET et al., 2008)	42
6. ábra – A felismert növények soraira illesztett vonalak (ÅSTRAND és BAERVELDT, 2002)	43
7. ábra – A növény leveleinek felismerése morfológiai jellemzők alapján (ÅSTRAND és BAERVELDT, 2002)	43
8. ábra – A növényi sorok helyzetének on-the-go meghatározása (SØGAARD és OLSEN, 2003)	44
9. ábra – Lencsetorzítási hibák szemléltetése	53
10. ábra – A Ciclops 3D szkener	58
11. ábra – Az eredeti robotplatform kinézete és főbb részei	61
12. ábra – Módosított vázszerkezet 3D terve	62
13. ábra – A hajtómotorok geometriai és elektromos tulajdonságai (URL ⁵)	63
14. ábra – A robot kapcsolási rajza és részei (Forrás: Fritzing program által generált saját diagram)	68
15. ábra – RPLIDAR A1 típusú Lidar érzékelő	69
16. ábra – A szántóföldi kísérleti hely	70
17. ábra – A növényházas kísérleti helyszín	72
18. ábra – Szabadföldi kísérlet DSLR panoráma képe a T2-es kezelésről	74
19. ábra – Növényházas kísérlet DSLR képe a 24-es mintanövényről	75
20. ábra – Szabadföldi kísérlet robot általi panorámaképe a T2-es kezelésről	76
21. ábra – Növényházas kísérlet robot általi képei a 24-es mintanövényről	77
22. ábra – A CNN betanítása során kialakított két osztály grafikus kijelölése	78
23. ábra – A képklaszterező CNN beállításai	79
24. ábra – A CNN tréning folyamata	80
25. ábra – A képelemzési módszer átfogó folyamatábrája	82

26. ábra – Az alkalmazott saktábla mintájú kalibrációs tábla	84
27. ábra – A saktáblaminta méreteinek meghatározása a lencsekalibrációs programban.....	85
28. ábra – 3D scanner kamerakalibrációs eredményei	89
29. ábra – 3D scanner lézerkalibrációs eredményei	89
30. ábra – A 3D szkennelés módszertani folyamatábrája és modellépítés a paradicsom gyümölcséhez.....	90
31. ábra – 3D szkennelés folyamata.....	91
32. ábra – A 3D pontfelhő normálisainak vektorai (kék nyílsohaság)....	92
33. ábra – A saját fejlesztésű robot fő komponenseivel	94
34. ábra – A navigáció által vizsgált irányok	95
35. ábra – A navigációs logika	96
36. ábra – GPS adatok grafikus megjelenítése (fehér körök) és a valós nyomvonal (piros vonal)	97
37. ábra – A robot környezeti érzékelőit tartalmazó részek 3D tervei	98
38. ábra – A talajérezkelő elhelyezkedése (a) és a mozgató mechanizmus (b)	101
39. ábra – A robot által készített képek szabadföldi természetéről és növényházból	103
40. ábra – Adatküldő Python alprogram részlete	104
41. ábra – A robot által gyűjtött adatok idősoros grafikonjai a ThingSpeak szerveren	105
42. ábra – A levélmintavevő aktuátor felépítése és működése	106
43. ábra – Levélminták gyűjtése	107
44. ábra – A távirányító grafikus interfész alkalmazás és részei	108
45. ábra – A felületrekonstrukció grafikus eredményei mindkét vizsgált paradicsomfajtánál	109
46. ábra – A legjobban illeszkedő gömbök grafikus eredményei mindkét vizsgált fajtánál	110
47. ábra – A korrekció során a kalibrációs tábla rácspontjaira illesztett egyenesek egy kalibrációs kép esetében	112
48. ábra – Kamera torzítási együtthatók.....	113
49. ábra – Képkalibrálás kalibrációs mintával a kis robot kameráján...	114
50. ábra – Az érett paradicsomra jellemző első szín és HSV értékeik..	115
51. ábra – Az érett paradicsomra jellemző második szín és HSV értékeik	115
52. ábra – A megvilágítás, a kijelölt felületelemek és az illesztett körök kapcsolata	116
53. ábra – A szegmentációs eljárás folyamán kijelölt terület nagysága a megvilágítás függvényében.....	117

54. ábra – Távolság kalibrálása referencia objektummal különböző távolságokból a robotkamera felvételén.....	118
55. ábra – DSLR és robotkamera távolságkalibráció	119
56. ábra – A CNN tréning grafikus eredményei.....	120
57. ábra – Igazság mátrix (érvényesítési készlettel).....	121
58. ábra – A CNN tesztelése a betanítása osztályok és a klaszterezés eredménye és helyzete a tesztkészlet egy képén	122
59. ábra – Észlelt paradicsombogyók különböző felbontású képeken..	123
60. ábra – Növény levelek elváltozásainak érzékelése különböző felbontású képeken.....	125
61. ábra – A DSLR fényképezőgép képi adatainak kiértékelése a szabadföldi kísérletnél.....	128
62. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján.....	130
63. ábra – A DSLR fényképezőgép képi adatainak kiértékelése a növényházas kísérletnél.....	131
64. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján az első méréskor.....	132
65. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján a második méréskor	133
66. ábra – A robot kamera képi adatainak kiértékelése a szabadföldes kísérletnél	135
67. ábra – Paradicsombogyó tömegének összehasonlítása különböző módszerek alapján az egyes kezelések növekvő hozama alapján	136
68. ábra – A robot kamera képi adatainak kiértékelése a növényházas kísérletnél	137
69. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján az első méréskor.....	139
70. ábra – A paradicsombogyó tömegének összehasonlítása az egyes kezelések növekvő hozama alapján a második méréskor	139
71. ábra – A paradicsom termésszám összehasonlítása az egyes kezelések növekvő hozama alapján.	144
72. ábra – A paradicsom termésszám összehasonlítása az egyes mintanövények növekvő hozama alapján az első méréskor.....	146
73. ábra – A paradicsom termésszám összehasonlítása az egyes mintanövények növekvő hozama alapján a második méréskor	146
74. ábra – A paradicsom termésszám összehasonlítása CNN elemzés alapján a kis robotkamerás képekből	149
75. ábra – A paradicsom termésszám összehasonlítása szegmentáció alapján a kis robotkamerás képekből	149

76. ábra – A paradicsom termésszám összehasonlítása az egyes mintanövények növekvő hozama alapján az első méréskor CNN elemzés alapján	152
77. ábra – A paradicsom termésszám összehasonlítása az egyes mintanövények növekvő hozama alapján az első méréskor szegmentáció alapján	152
78. ábra – A paradicsom termésszám összehasonlítása az egyes mintanövények növekvő hozama alapján a második méréskor CNN elemzés alapján	153
79. ábra – A paradicsom termésszám összehasonlítása az egyes mintanövények növekvő hozama alapján a második méréskor szegmentáció alapján.....	153