

SZAKDOLGOZAT

Seiwerth Anna

2024.



Magyar Agrár- és Élettudományi Egyetem

Szent István Campus

**Vetőmag-gazdálkodási szaktanácsadó szakirányú
továbbképzés**

**Kender (*Cannabis sativa* L.) nemesítésben felhasznált
vetőmagok gépi detektálási folyamatának validálása**

Belső konzulens: Dr. Mikó Péter Pál
egyetemi docens

**Belső konzulens
intézete/tanszéke:** Növénytermesztési-tudományok
Intézet, Agronómia Tanszék

Külső konzulens: Dr. Vona Viktória Margit

Készítette: Seiwert Anna

Gödöllő

2024.

TARTALOMJEGYZÉK

Tartalomjegyzék	3
1. Bevezetés és célkitűzések	4
2. Szakirodalmi áttekintés.....	5
2.1. A kender ismertetése.....	5
2.1.1. A kender termesztése	8
2.1.2. A kendermag jellemzői.....	9
2.2. Gépi látás és neurális hálóak a mezőgazdaságban	11
3. Anyag és módszer.....	15
3.1. A vizsgálatban alkalmazott neurális hálózat.....	15
3.2. MSZ 6354-2:2001 szerinti magvizsgálat.....	18
3.3. Teljes tétel detektálása	20
4. Eredmények és értékelésük	23
5. Következtetések és javaslatok	29
6. Összefoglalás	30
7. Köszönetnyilvánítás.....	32
8. Irodalomjegyzék	33
9. Mellékletek	37
1. melléklet: Szabvány gépi EMT vizsgálat alapadatai.....	37
2. melléklet: Gépi látáson alapuló EMT vizsgálat alapadatai.....	40
3. melléklet: A növekvő magmennyiségből gépi látással detektált értékek adatsora	44
10. Nyilatkozat.....	47

1. BEVEZETÉS ÉS CÉLKITŰZÉSEK

A kender (*Cannabis sativa L.*) az egyik legkorábban domesztikált mezőgazdasági növény. Felhasználása élelmezési, ipari, rekreációs vagy gyógyászati célokra több ezer éves múltra tekint vissza. Gyógyszerként hatékonyan kezel és enyhít különféle betegségeket, mint például a migrént, a fáradtságot, az álmatlanságot, epilepsziát.

A XXI. században, köszönhetően az újszerű egészségügyi, ipari, karbongazdálkodási folyamatoknak, lassan visszatalálunk a kender, mint multifunkcionális növény mezőgazdasági hasznosításához. A kriminalizált növény termesztésére vonatkozó szabályok a legtöbb országban jelentősen módosulnak, egyszerűsítve a növény termelését és feldolgozását. Ez új lendületet ad a nemesítésének, vetőmag előállításnak egyaránt.

A Lajtamag Kft. hédervári telephelyén 3 éve kezdődött el egy kender nemesítési program. Ebben a munkában a manuális törzsanyag vetőmag értékelése kardinális jelentőségű. Néhány hónap alatt több ezer tétel átvizsgálása történik. A magszín, márványozottság, ezermagtömeg a legfontosabb paraméterek. Ugyanakkor a következő nemesítési ciklus kijelöléséhez az egy-egy növényről származó magok pontos darabszámának ismerete nélkülözhetetlen, ezen felül tartalékmaggal is rendelkezünk kell.

A roncsolásmentes, gyors, ugyanakkor könnyen hozzáférhető, olcsó vetőmagszámolás technikája, nagy jelentőségű ebben a folyamatban. Ehhez kapcsolódik az utóbbi években szintén előtérbe kerülő gépi látás és adatfeldolgozás. Szakdolgozatomban egy mesterséges intelligenciát alkalmazó, kendermag detektálására alkalmas modell validálását végeztem el. Az objektum detektáló modell alapján felismert és számlált magok mennyiségét összehasonlítottam a manuális vizsgálat eredményével. Így válik értékelhetővé a számítógépes modell jósága, megbízhatósága. A feltárt hibák, értékelési bizonytalanságok alapján javítható, finomítható az eljárás mindaddig, amíg különböző elemszámú, eltérő morfológiai megjelenésű, a környezeti megvilágítástól, háttértől független, nagy pontosságú detektálást tudunk biztosítani.

2. SZAKIRODALMI ÁTTEKINTÉS

2.1. A kender ismertetése

A kender (*Cannabis sativa* L.) a növények országába (*Plantae*), a zárvatermők törzsébe (*Angiospermae*), a valódi kétszikűek osztályába (*Eudicotyledoneae*), a rózsavirágúak rendjébe (*Rosales*), a kenderfélék családjába (*Cannabaceae*) és a *Cannabis* L. nemzetségbe tartozik (Borhidi, 1998).

A "Cannabis" nemzetség neve az ókori görög "kannabis" szóból ered, ami vélhetően az arab "kannab" szóból származik. A kenderfélék családjába csak két rokon nemzetség tartozik: a komló és a kender. A Cannabis nemzetség egyetlen faja a közönséges kender (*Cannabis sativa* L.) (De Candolle, 1894).

A kendert 4 földrajzi rasszra bonthatjuk:

Északi kender (*borealis*): Ide tartoznak az észak-orosz és finnországi fajták, amelyeket a 60. északi szélességi fok felett termesztnek. Jellemző rájuk az alacsony szár (1-1,2 m) és a korai érés.

Közép-orosz kender (*medioruthenica*): A legnagyobb területen termesztett alakkör. Jellemző rá a közepes tenyészidő (90-110 nap), a 1,5-3,0 m szárhosszúság, a kismértékű elágazás, a közepes méretű levél.

Déli, mediterrán kender (*australis*): Gazdasági jelentőségét tekintve a legfontosabb alakkör. Jellemző rá a hosszú tenyészidő (130-150 nap), a 3-4,5 m szárhosszúság, a tág térállásban való elágazódás.

Ázsiai kender (*asiatica*): Jellemző rá az alacsonyabb szár (2-3 m), a rendkívüli elágazódásra való hajlam, a nagy, világoszöld levelek, a hosszú tenyészidő (150-170 nap). Magyarországon gazdasági jelentőségük nincs, de a nemesítésben felhasználhatók (Bócsa, 2004; Iványi, 2012; Csajbók, 2019).

A kender egyéves növény, melynek szára 2-4 m magasra nőhet fajtától függően. A növény morfológiai tulajdonságait befolyásolják a termesztés körülményei.

Gyökérzet: A gyökérzet elenyésző a nagy vegetatív tömeghez képest. Fejlettségét meghatározza a művelési mód, a talaj minősége és a szexuális fenotípus. A főgyökér 2-2,5 m mélyre is hatolhat (Bócsa és Karus, 1998)

Levélzet: Tenyeresen összetett, 7-10 különböző méretű levélkéből áll. 10-30 centiméterenként átellenesen állnak a levelek. A levélké mindig páratlan számúak.

Szár: Dudvás, merev és felálló. A gazdasági növényeink közül a kender adja a legtöbb fás anyagot. A szár felülete korán elsimuló mirigyszőrökkel borított, alakja szögletes hosszirányban és bordázott a felülete. Magassága és vastagsága függ attól, hogy hol, hogyan és mire termesztik (Iványi, 2012).

Virágzat: A hímvirágok 5 lepellevélből állnak, melyek 5 szorosan álló porzót foglalnak magukba. A termős virágok a bogernyős füzér nővirágzatban foglalnak helyet. A nővirágoknak ugyancsak lepellevélből álló virágtakarója van, ez azonban mindössze 1 vagy 2 (Bócsa, 2004).

A kender (*Cannabis sativa L.*) az egyik legrégebben domesztikált mezőgazdasági növényünk, melynek felhasználása rekreációs, gyógyászati és ipari célokra is kiterjed. A növény rostjai kiváló alapanyagot nyújtanak a textilipar és az építőipar számára, magjai értékes olajforrást jelentenek magas telítetlen zsírsavtartalmuknak köszönhetően, míg a virágzatból kinyerhető kannabinoid hatóanyagok gyógyászati és rekreációs célokat szolgálnak (Kovalchuk et al., 2020). (1. ábra)

A kender hasznosítása a történelem során kulturális és földrajzi hatások mentén változatos formában alakult. Ennek következtében az alkalmazott agrotechnika és a szelekció iránya is eltérően formálódott, ami a XX. században a rostcélú, magtermesztési célú és pszichoaktív irányú fajták fejlődéséhez vezetett (Clarke és Merlin, 2016).

A kender évezredek szelekció eredményeként fenotípusos változásokon is átesett. A rosttípusú fajták hosszabb internódiummal és kevesebb elágazással rendelkeznek, míg a magtermesztő kenderök rövidebb szártagokkal és több oldalhajtással bírnak. A hagyományos, erősen pszichoaktív tájfajták akár 20% THC tartalommal is rendelkezhetnek, míg az európai fajták csupán 1%-kal (Small és Marcus, 2003). A vad és a nemesített egyedek között akár hússzoros különbség is megfigyelhető az ezermagtömeg tekintetében (Clarke és Merlin, 2016).

A morfológiai változások mellett hangsúlyosak a fiziológiai eltérések is. A kendermag olajtartalma és zsírsavösszetétele jelentősen módosult a domesztikáció hatására. A szár rosttartalma és rostminősége is jelentős változást mutat, néhány kivételes genetikai állományú

fajtában a rosttartalom akár 35% is lehet. A virágzat morfológiai változása is a tudatos szelekciónak köszönhető (Bócsa, 1994).

A kender alapvetően kétlaki növény, a nővirágú egyedeket számtalan hím egyed megporozhatja, ezért nagy kihívás a kontrollált körülmények között végrehajtott, irányított beporzás. Az egylaki fajták öntermékenyülésre is képesek. A mesterségesen kialakított, tisztán nőgyedekből álló populációk alkalmasak hibrid anyavonalak előállításra (Hoffmann, 1944).

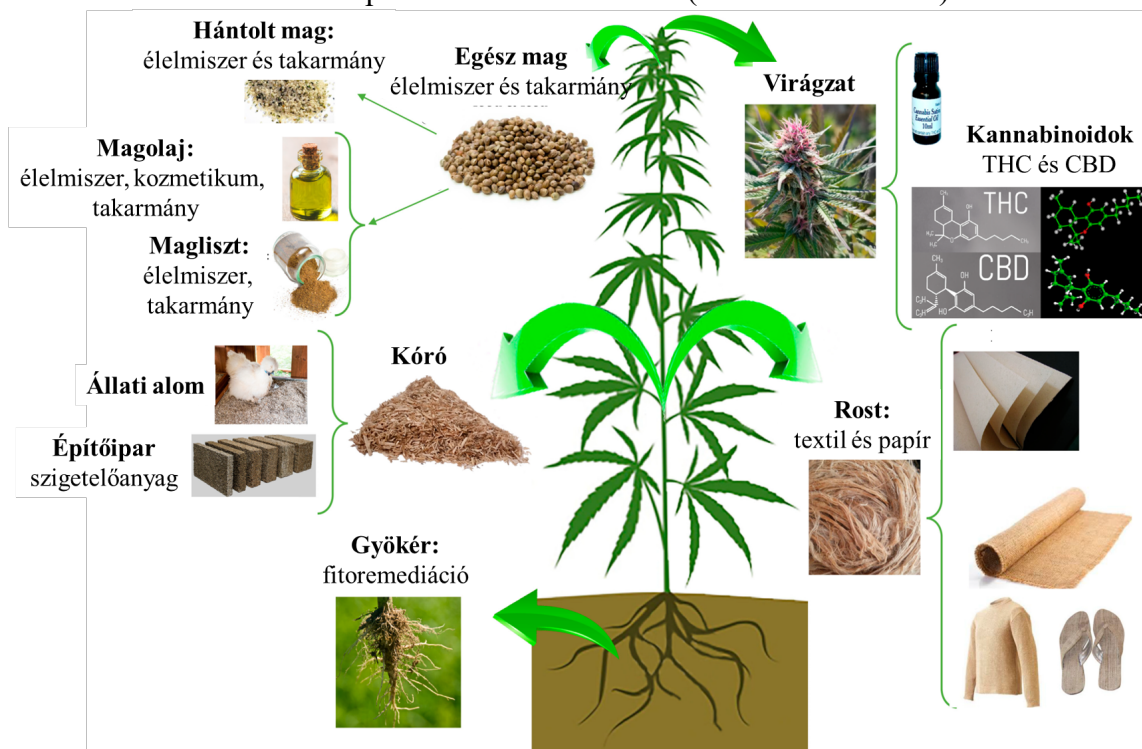
Napjainkban a legtöbb európai fajta egylaki (de Meijer 1995).

A magyar kendertermesztés is a kétlaki kenderformákat preferálta, lévén a rostelőállítás volt a mérvadó. A hazai nemesítés kiemelkedő eredményei közé tartozik a Kompolti Hibrid TC háromvonalas hibrid, a Kompolti sárgaszárú fajta, valamint az Uniko-B uniszexuális hibrid (Bócsa és Karus, 1998).

A kender nemesítése napjainkban is aktívan folyik, a cél a magasabb termés, a rost minőségének javítása, az alacsony THC tartalom, valamint a különleges kannabinoid profilú fajták előállítása (Mishchenko et al., 2021).

Az 1. ábrán összefoglaltam a kender hasznosítási formáit.

1. ábra: Az ipari kender hasznosítása (Farinon et al. 2020)



2.1.1. A kender termesztése

Szabadföldön, valamint fedett termesztő berendezésben meghatározott tevékenységek kivételével - kizárólag a Nemzeti vagy a Közösségi Fajtajegyzékben közzétett, alacsony THC tartalmú kender termeszthető. Kender vetéséhez kizárólag fémzárolt vetőmag használható fel. A termesztőnek a vetőmaggal kapcsolatos bizonylatokat és számlákat vagy másolatait legalább a vetési évet követő év végéig meg kell őriznie (162/2003. (X. 16.) Korm. rendelet).

A kender termesztése történhet a szár, a mag, vagy mindkettő hasznosítása céljából. Ez utóbbit kettős hasznosításnak nevezzük (Csajbók, 2019).

Magyarországon főként a déli rasszba tartozó fajtákat termesztjük, melyek hőösszegigénye 1800-2000 °C, de magtermesztéshez 2500-3000 °C-ra van szükség. A gyors és egyöntetű csírázáshoz 10 °C talajhőmérséklet szükséges. A fiatal növények jól tűrik a hideget, de az intenzív növekedés időszakában a 20-25 °C napi középhőmérséklet és a magas páratartalom ideális (Bócsa, 2004).

A kender igényes a talajjal szemben, a jó kultúrállapotú, mélyrétegű, csernozjom talajokat kedveli, melyek kiváló tápanyag-, víz- és hógazdálkodással rendelkeznek. Semleges pH-t igényel, nem viseli el az időszakos vízborítást, a mélyebb fekvésű területeket és a talajhibákat. Alacsony humusztartalmú és szikes homoktalajokon nem termesztendő. Hazánkban a dél-alföldi területek a legmegfelelőbb termesztési helyek.

Hagyományosan a kender monokultúrában, "kenderföldeken" termelt. A vetésváltásban optimális, ha két kalászos növény közé vetjük. Nem igényes az előveteményre, de a napraforgó, repce, cirokfélék és a későn lekerülő növények nem kedvezőek. A kender érzékeny a jó minőségű magágyra, melyet könnyebb megteremteni korán lekerülő elővetemény esetén. A kender mélyművelést igényel, alpművelése őszi mélyszántás. A kender jó előveteménynek számít, mert aránylag korán lekerül és jó talajállapotot hagy maga után. Víz- és tápanyagigénye magas. (Borsos et al., 1994)

A kender tápanyagigényes növény. A jó rostterméshez 120-150 kg nitrogént, 70-100 kg foszfort és 100-120 kg káliumot igényel. Meghálálja az istállótrágyát.

Tavasszal akkor vethető, ha a vetés mélységében a talaj hőmérséklete elérte a 8-10 °C-ot. A késői vetés természsökkenést eredményez. Az optimális vetésmélység 3-4 cm. Rostcélra gabona sortávolságra vetik, 2-2,5 millió csíra/ha normával. Textilipari hosszúrost termeléshez


3-4 millió tő/ha. Kézi előállítású magtermeléskor 30 000-60 000 tő/ha, gépi betakarításhoz 1-2 millió tő/ha.

A korai fajták betakarítási ideje július vége-augusztus eleje, a hosszabb tenyészidejű fajtáknál augusztus elsőfele. Betakarítás előtt 5-8 nappal lombtalanítást végeznek (Iványi, 2012; Csajbók, 2019).

2.1.2. A kendermag jellemzői

A kender termése a makkocskák, amelyek tojás vagy gömb alakúak, fajtától függően 3-5 mm hosszúak (2. ábra). Vetőmagjának ezermagtömege 14-21 g. A kemény burokban egy mag található, amely gyorsan veszít a csírázó képességéből, az első évben 95%, a másodikban 80%, utána vetésre alkalmatlanná válik (Bócsa, 2004).

2. ábra: A kender makkocskák termése



Magjának beltartalmi összetétele az emberi táplálkozás szempontjából igen kedvező. Olajtartalma 25–33%, melyben a többszörösen telítetlen zsírsavak elérik a 90%-ot. Ezek közül 50–70% linolsavat (LA), 15–20% a linolénsavat (LNA) tartalmaz, tehát az LA:LNA arány 3 : 1, amit az emberi táplálkozás szempontjából optimálisnak és kívánatosnak tartanak. Ilyen tekintetben a kenderolaj egyedülálló a természetett növények között. Az igen értékes és a természetben szintén ritkán előforduló gamma linolénsavat (GLA) 2–4%-ban tartalmazza.

A fehérjetartalma 20–25%. Fehérjéje a szójához hasonlóan tartalmazza az ember számára lényeges összes aminosavat. Kiváló összetétele miatt a kendermagot felhasználja a kozmetikaipar, gyógyszeripar és az élelmiszeripar. Ilyen termékeket jelenleg csak külföldön állítanak elő. Magja kiváló madáreleség és haleledel. A betakarítás naptári időpontja a rövid tenyészidejű fajtáknál július közepe-vége, a hosszabb tenyészidejűeknél augusztus eleje-közepe (Bócsa, 2004; Csajbók, 2019).

A kendermag színe és márványozottsága (3. ábra) fajtulajdonság, amely a CPVO vizsgálati módszertanban külön pontként szerepel (1. táblázat).

1. táblázat: A kender magjának morfológiai paraméterei

Mag színe	Példa fajták	Kategória
Világos szürke	Finola	1
Közepesen szürke	USO 31	2
Szürkés-barna	Fedora 17	3
Barna	Dioica 88	4
Mag márványozottsága	Példa fajták	Kategória
Gyenge	Finola	1
Közepes	Felina 32	2
Erős	Dioica 88	3

3. ábra: A CPVO módszertan szerinti mag márványozottság osztályai



1



2



3

Magyarországon a kender vetőmag minőségi paramétereit a 48/2004. (IV. 21.) FVM rendelet a szántóföldi növényfajok vetőmagvainak előállításáról és forgalomba hozataláról szabályozza (2. táblázat).

2. táblázat: A kender vetőmag vizsgálati határértékei

Faj	Alapminta legalább (kg)	Laboratóriumi minta legalább (g)	Tisztaság-vizsgálati minta legalább (g)	Idegenmagvizsgálati minta (g)			
Kender (<i>Cannabis sativa</i>)	5	600	60	600			
		Idegenmag-tartalom legfeljebb (db/minta)					
Faj	Csírázóképesség legalább %	Tisztaság legalább %	Idegenmag-tartalom legfeljebb (tömeg%)	Idegenmag-tartalom legfeljebb	Avena fatua, Avena ludoviciana, Avena sterilis	Cuscuta spp.	Nedvességtartalom legfeljebb (%)
Kender (<i>Cannabis sativa</i>)	75	98	–	30	0	0	12,0

2.2. Gépi látás és neurális hálók a mezőgazdaságban

A gépi látás egy interdiszciplináris tudományterület, amely lehetővé teszi a számítógépek számára, hogy "lássák" és értelmezzék a képeket és videókat. Két fő ága van. Az első a Machine Vision (MV): ipari környezetben használják mérésre, értékelésre, vezérlésre. A második a Computer Vision (CV): komplexebb feladatokra használják, mint az objektumfelismerés, azonosítás, nyomkövetés. A CV múltja messzire nyúlik vissza, de mostanában lett igazán népszerű. Ennek oka a matematikai elmélet fejlődése, a jobb teljesítmény és az olcsóbb számítási kapacitás. A gépi látás az 1990-es évek végén nagy szintet lépett. A kezdeti cél a 3D-s modellezés volt, de a hangsúly áthelyeződött az objektumok felismerésére. 2006-ban létrejött a Pascal VOC projekt, amely szabványosította a képeket az objektumok osztályozásához, és versenyeket szervezett a legjobb módszerek megtalálására. 2010-ben az ImageNet nevű verseny még nagyobb lökést adott a fejlődésnek, hatalmas mennyiségű képpel és fejlettebb technikákkal. Ennek eredményeként a hibaszázalék jelentősen csökkent, és a konvolúciós neurális hálózatok (CNN) dominánsá váltak az objektumfelismerés terén. A mesterséges neurális hálózatok olyan hálózatok, amelyek egyszerű elemekből, úgynevezett neuronokból épülnek fel. Ezek a neuronok tanulnak az adatokból, és bonyolult összefüggéseket tudnak felismerni. A tanulás során a hálózat beállítja a belső súlyokat, hogy a bemenet alapján a megfelelő kimenetet tudja adni. A neurális hálózatok előnye, hogy olyan problémákra is

használhatók, amelyeket nehéz lenne hagyományos módszerekkel megoldani, például zajos vagy nehezen értelmezhető bemeneti adatok esetén. Így váltak a neurális hálózatok az egyik legfontosabb eszközzé a gépi látás területén (Kollár és Nagy, 2021).

A hálózatok képessége az elemek (neuronok) térbeli helyzetétől, tulajdonságaitól, a belső súlyok értékétől függ. Olyan feladatokra alkalmasak, amelyeknek a megoldása nehezen algoritmizálható. A mesterséges neurális hálózatok tanítása lehet felügyelt, amennyiben a bemeneti és elvárt kimeneti értékek is rendelkezésre állnak, a tanítás célja a hálózat válaszáinak illesztése az elvárt válaszhoz. Ehhez nagy mennyiségű bemenet-kimenet páros szükséges. A nem felügyelt tanítás esetén csak bemeneti értékek állnak rendelkezésre, a bemeneti mintákra vonatkozó megkötések alapján tanítjuk a hálót és a hálózat absztrakciós képességének fejlesztése a cél. A hálózat belső paramétereit (súlyokat) módosítjuk a tanítópontok ismételt felhasználásával, amíg a kívánt eredményt fokozatosan elérjük. A tanítás minősége meghatározza a hálózat hatékonyságát. A gépi látás fontos hasznosítása a képosztályozás, melynek során egy osztályt rendelünk a bemeneti képhez. Kimenetként egy vektort kapunk, amelynek elemei egy osztályhoz tartoznak, értéke alapján definiálható, hogy az adott kép milyen valószínűséggel sorolható az adott osztályba. Az objektum lokalizáció során a hálózat az objektum helyét határozza meg a képen. Az objektum detektálás nem csupán lokalizálja a helyet, de azonosítja is azokat. Jellemzően egyszerre több objektum azonosítását végzi egyszerre. Az első alkalmazások csúsztatott ablakokat használtak, téglalapokkal pásztázták a bemeneti képet. A két lépéses megoldások pl. a Region-CNN (R-CNN) modell, amelyet 2014-ben a Kaliforniai Egyetem, a Berkeley kutatói javasoltak. Az R-CNN három kulcsfontosságú komponensből áll. Először is, egy régióválasztó a "szelektív keresés" algoritmust használja, amely olyan pixelrégiókat talál a képen, amelyek objektumokat ábrázolhatnak, ezeket "érdeklődési körzetnek" (region of interest, RoI) is nevezik. A régióválasztó körülbelül 2000 RoI-t generál minden egyes képhez. Ezután a RoI-kat előre meghatározott méretre torzítják, és továbbítják egy konvolúciós neuronhálózatnak. A Fast R-CNN már nem pásztázza a képet, hanem potenciális régiókat hoz létre, második lépésben a kép klasszifikáció következik. Ennél gyorsabb az egylépéses megoldás, mint az SSD (Single Shot Detection) és a YOLO (You Only Look Once) (Kollár és Nagy, 2021).

A magvak detektálása elengedhetetlen a mezőgazdaságban a minőség, a tisztaság és a genetikai diverzitás biztosítása érdekében. Korábbi tanulmányok számos mesterséges intelligencián alapuló módszert alkalmaztak a kender termesztés különböző területein. Sieracka és mtsai. mesterséges neuronhálókat használt az ipari kendermag-hozam előrejelzésére a termesztési

adatok alapján (Sieracka et al, 2023). Továbbá, leírtak egy mélytanulási rendszert, amely transzfertanulást alkalmaz a betegségek, kártevők és tápelem hiányok azonosítására a kender növények képein (Ferentinos et al., 2019). Boonsri és Limpiyakorn mélytanuláson alapuló objektumdetektáló modelleket alkalmazott a hím- és nőivarú kendermagok detektálására (Boonsri és Limpiyakorn, 2023). Találunk példát 17 fajta kendermag osztályozására és detektálására is (Sarker et al., 2024).

A magvak osztályozására Phan és mtsai. kifejlesztettek egy automatizált osztályozási rendszert a rizsváltozatok megkülönböztetésére, ami kulcsfontosságú a rizstermesztésben a vetőmag tisztaságának biztosításához (Phan et al., 2019). Egy másik kutatásban a szerzők modelleket képeztek ki 6 kukoricafajta osztályozására (Ali et al., 2020).

A képeken lévő csírázott és nem csírázott parazita növényi magok pontos detektálására, megszámlálására és megkülönböztetésére is találunk példát (Braguy et al., 2021). Egy másik tanulmányban a kutatók egy valós idejű, nagy áteresztőképességű válogató rendszert mutattak be, amely ResNet-18 képosztályozót használ, hogy nagy sebességet és magas pontosságot érjen el (Heo et al., 2018).

A YOLO (You Only Look Once) algoritmust 2016-ban publikálták (Redmon et al. 2016). A YOLO egy gyors és hatékony modell a képeken lévő tárgyak detektálására. A tárgyak felismerésének lépései a következők:

1. Bemeneti kép: A YOLO egy képet kap bemenetként.
2. Rácsokra osztás: A képet cellákból álló rácstra osztja. Minden cella a benne lévő tárgyak detektálásáért felelős.
3. Jellemzők kinyerése: Minden cellát átvezetünk egy előre betanított konvolúciós neurális hálón (CNN) a jellemzők kinyerése érdekében.
4. Tárgy jelenléte: Minden cellánál a rendszer megállapítja, hogy van-e benne tárgy.
5. Osztály valószínűsége: Minden olyan cellánál, ahol tárgyat jelez a rendszer, a YOLO megjósolja a tárgy osztályát és annak valószínűségét.
6. Határoló keret: Minden olyan cellánál, ahol tárgyat jelez a rendszer, a YOLO megjósol egy határoló keretet is, amely körülveszi a tárgyat. A határoló keretet a cella méretéhez viszonyítva becsüli meg, és a középpont koordinátaival, szélességével és magasságával írja le.

7. Non-Maximum Supression (NMS) A redundáns határoló keretek eltávolítása és a detektálás pontosságának javítása érdekében a YOLO NMS-t hajt végre a jóslott határoló kereteken. Az NMS eltávolítja az összes olyan átfedő határoló keretet, amelynek alacsonyabb az elfogadási szintje.

8. Kimenet: A YOLO végső eredménye a határoló keretek listája a kapcsolódó osztállyal és bizalmi pontszámmal. Ezek a keretek a bemeneti képként megadott képen talált tárgyakat ábrázolják.

A YOLO lényegesen gyorsabb, mint más tárgyfelismerő algoritmusok, amelyek többször is áthaladnak a bemeneti képen, mert a bemeneti képet cellákból álló rácsra osztja, és megjósolja a cellákban lévő tárgyakat, képes kis méretű és zsúfolt jelenetekben lévő tárgyakat is érzékelni.

Repcebecők detektálására és elemzésére használták a YOLO neurális hálózatot (Wang et al., 2023). Zhao et al. (2023) tervezett egy YOLO-r hálózatot annak érdekében, hogy a rizs csírázását detektálja. Kundu et al. (2021) egy továbbfejlesztett YOLOv5 rendszert alkalmazott a mag osztályozottság és minőség-ellenőrzés érdekében. Jiang és mtsai. a borsó csírázóképességéből következtetett szárazságtűrésének értékelésére kifejlesztették a YOLOv8-Peas neurális hálózatot (Jiang et al., 2023).

3. ANYAG ÉS MÓDSZER

3.1. A vizsgálatban alkalmazott neurális hálózat

A vizsgált kendermagok a Lajtamag Kft. saját nemesítéséből származó anyatövekről, növényenként gyűjtött vetőmag tételek. Ezermagtömegük 8-17 g között változik, színük döntően barna (4), márványozottságuk közepes (2).

A modell tanításához felhasznált képek elkészítéséhez egy Android alkalmazás került kifejlesztésre, amely a fehér lapon különböző mennyiségű (10-300 db) kendermag képét rögzíti egy Xiaomi Redmi Note 9 mobiltelefonnal (Google Android 10 (Q), Qualcomm Snapdragon 720G SM7125 (Atoll), 6 GiB RAM, 64 GB ROM, 6.7 hüvelyk, 1080x2400, 63.7 MP) 640x640 px. méretben, majd kiexportálja felhő alapú tárhelyre (Google Drive). A képek elkészítéséhez szándékosan nem befolyásoltuk sem a megvilágítást, sem a fókusz távolságot. Mindössze annyi megkötést alkalmaztunk, hogy a későbbi feldolgozás érdekében a magok egyenletesen kerültek szétterítésre a lapon. Kis mértékű átfedést megengedtünk (4. ábra).

4. ábra: Néhány példa a YOLOv8 modell betanítására használt képanyagból



Első lépésben 50 képen jelöltük (annotáltuk) a kendermagokat, poligonokat képezve, annak érdekében, hogy a körülhatárolások alapján ún. szegmentációs modellt készítsünk, megkönnyítve a későbbi, nagy mennyiségű képen történő annotációs munkát. A képanyag címkézését a Roboflow (<https://www.roboflow.com>) online alkalmazással végeztük (5. ábra).

5. ábra: A poligonokkal körülhatárolt, címkézett eredeti képanyag




Az így nyert adatbázist 70-20-10% arányban felosztottuk tanító, validációs és tesztelő könyvtárakba. A YOLOv8 modell betanítást a Google Colaboratory (<https://colab.research.google.com/>) felületén végeztük Python3 futtatókörnyezetben, Nvidia T4 Tensor Core GPU felhasználásával. Az átlagos elért precizitás (mAP) 97,6% lett.

A YOLOv8-at az Ultralytics cég, a YOLOv5 fejlesztője jelentette meg 2023 januárjában (Jocher et al., 2023). Ezenkívül a YOLOv8 mozaik augmentációt használ a tanítás során, amit azonban a folyamat teljes ideje alatt történő alkalmazása esetén hátrányosnak találtak, ezért az utolsó tíz „epochban” letiltásra kerül. Ezenkívül számos integrációt tartalmaz a címkézéshez, tanuláshoz és telepítéshez. A YOLOv8 öt verziót biztosít: YOLOv8n (nano), YOLOv8s (kicsi), YOLOv8m (közepes), YOLOv8l (nagy) és YOLOv8x (extra nagy).

Az így elkészült szegmentációs modellt csak az objektum detektálásra alkalmas neurális háló elkészítéséhez használtuk fel. Ezzel a módszerrel a nagyszámú felvétel rendkívül gyorsan címkézhető.

326 db képet annotáltunk a fenti módszerrel. A fotókat szintén a már ismertetett Android alkalmazással készítettük. Azonban ez esetben szempont volt a célkörnyezet szerinti több száz kendermag egyidejű rögzítése (6. ábra).

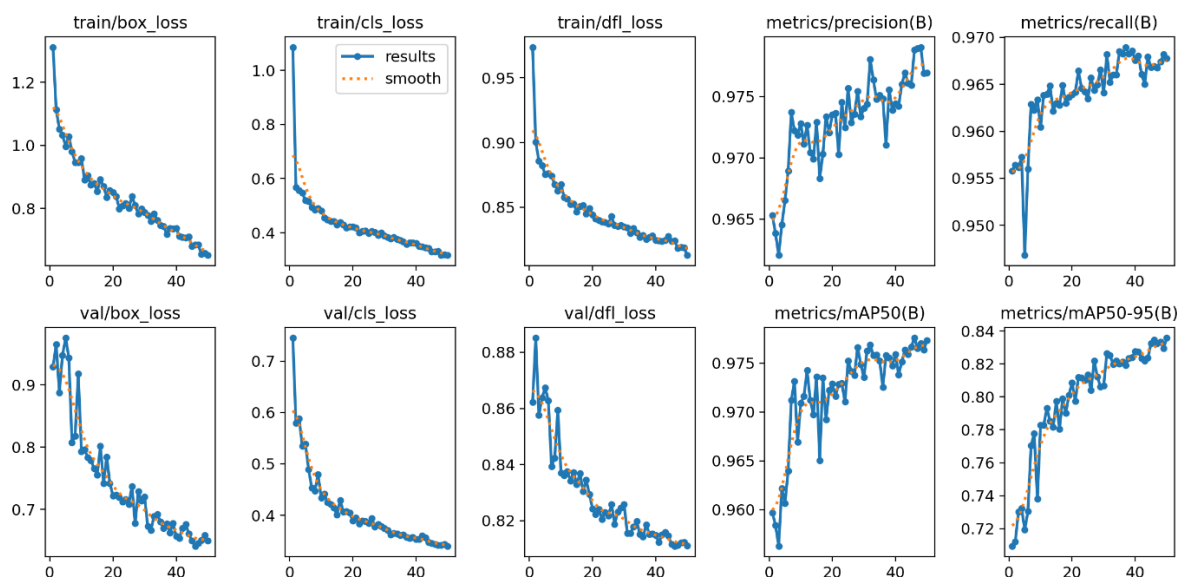
6. ábra: Az objektum detektálási modell betanításához felhasznált képanyag



A képanyagot mesterségesen növeltük 779 elemre oly módon, hogy módosítottuk a fényerőt, homályosítottuk a felvételt, valamint csökkentettük és növeltük a színtelítettséget. Ezután 70-20-10% arányban létrehoztuk a tanító, validációs és tesztelő könyvtárakat.

A tanítás a Google Colaboratory felületén történt, Python3 futtatókörnyezetben, Nvidia T4 Tensor Core GPU felhasználásával. A 100 lefuttatott „epoch” után a modell átlagos elért precizitása (mAP) 97,7%-ot ért el (7. ábra).

7. ábra: A YOLOv8 kendermag detektáló modell mérőszám grafikonjai



3.2. MSZ 6354-2:2001 szerinti magvizsgálat

A tényleges ezermagtömeg meghatározásához végzett magszámolást az ISTA (International Seed Testing Association), valamint az MSZ 6354-2:2001 módszertana alapján hajtottam végre.

100 tétel esetén 8 ismétlésben leszámoltam 100 db kendermagot géppel, majd manuálisan ellenőriztem a leszámolt mennyiséget. A Sadkiewich Instruments (SI) magszámláló készülék alkalmas mindenféle szemes termény, mint pl. mák, mustár, búza, árpa, borsó, kukorica, valamint egyéb granulátumok, szemcsék számlálására. A magcsészébe betöltött számlálandó anyag spirális pályán, vibrációs úton jut el az ejtő csatornához. Az ejtő csatornában elhelyezett optikai érzékelő számlálja az áthaladó szemeket. A számlálás sebessége állítható. Az így leszámolt magmennyiséget Radwag WLC 0,6/B1 precíziós mérlegre helyeztem. (8. ábra)

8. ábra: A vizsgálatban alkalmazott SI laboratóriumi magszámláló



Az MSZ 6354-2:2001 alapján, mivel géppel az egész vizsgálati mintából számoltattam 8 ismétlésben a 100 db mag tömegét, ezért a variációs együttható számítása szükségtelen. Azonban a nemesítési törzsanyag magtétel heterogenitására való tekintettel a kalkulációkat az alábbi képletek segítségével elvégeztem:

$$\text{Variancia} = \frac{n(\sum x^2) - (\sum x)^2}{n(n-1)}$$

ahol x = az ismétlések ezermagtömege (g)

n = az ismétlések száma

$$\text{Standard eltérés} = \sqrt{\text{Variancia}}$$

$$\text{Variációs együttható} = \frac{s}{\bar{x}} 100$$

ahol \bar{x} = a magok átlagos ezermagtömege

$$\text{Ezermagtömeg} = \frac{\text{Tömeg}}{\text{Darabszám}} 1000$$

A szabvány alapján amennyiben a variációs együttható értéke 4-nél nagyobbak bizonyul, akkor újabb 8 ismétlést kell leszámolni és együtt a 16 eredmény variációs együtthatóját újra meg kell határozni és azt az ismétlést, amely az átlagtól az így kapott standard eltérés kétszeresével eltér, azt ki kell hagyni a számításból.

A berendezés összeállításánál az egyszerűsége törekedtünk. A detektálást olyan felvételeken végeztük, amit a Xiaomi Redmi Note 9 mobiltelefon kamerája rögzített (9. ábra), majd vezeték nélküli IP kameraként továbbította az 1920x1080px, 96dpi felbontású képet egy számítógépre

(11th Gen Intel(R) Core(TM) i5-11300H @ 3.10GHz; 16 GB RAM), amelyen Python3 felületen futott a YOLOv8 modell, amit előzetesen módosítottunk a kendermag objektum detektálás súlyfájljával. Az ezermagtömeg meghatározásnál a magtétel egyenesen a mérlegre került, a detektáláshoz használt képanyag elkészítését az e fölé helyezett állványon a mobiltelefon végezte.

3.3. Teljes tétel detektálása

Egy anyanövényről kicsépett magok száma 253-999 között alakult. Ezért a kevert vetőmagtételből leszámoltam 25 ismétlésben 200 db, 300 db, 400 db, 500 db és 1000 db kendermagot annak eldöntésére, hogy a növekvő elemszám által okozott nagyobb mértékű átfedés mennyire rontja a becslést. Ezermagtömeg meghatározás ez esetben nem történt.

9. ábra: A gépi objektum detektálás felvételeihez használt állvány



Végezetül a teljes tételt is értékeltem a gépi látáson alapuló magvizsgáló berendezéssel, 8 ismétlésben, ezermagtömeg értékeléssel, a kapott eredményt összehasonlítottam a szabvány szerinti vizsgálattal. A feldolgozás során csak az 50% feletti valószínűséggel kendermagnak detektált objektumokkal kalkuláltunk (10. ábra).

$$\text{Ezermagtömeg (EMT)} = \frac{\text{Magtétel tömege}}{\text{Detektált darabszám}} 1000$$

10. ábra: A detektált kendermagok, a kiírt valószínűségi értékkel



A statisztikai elemzéseket Microsoft Excel 2016 programmal végeztem el. A bővített párosított t-próba számítását az alábbi képletekkel végeztem el:

$$t \text{ számított érték} = \frac{\bar{x} - 0}{\frac{s}{\sqrt{n}}}$$

$$\text{Két mérési sor különbségeinek legkisebb értéke } \bar{x}_{\min} = \bar{x} - t_{\text{számított}} \times \frac{s}{\sqrt{n}}$$

ahol \bar{x} = adatsor különbségeinek átlaga

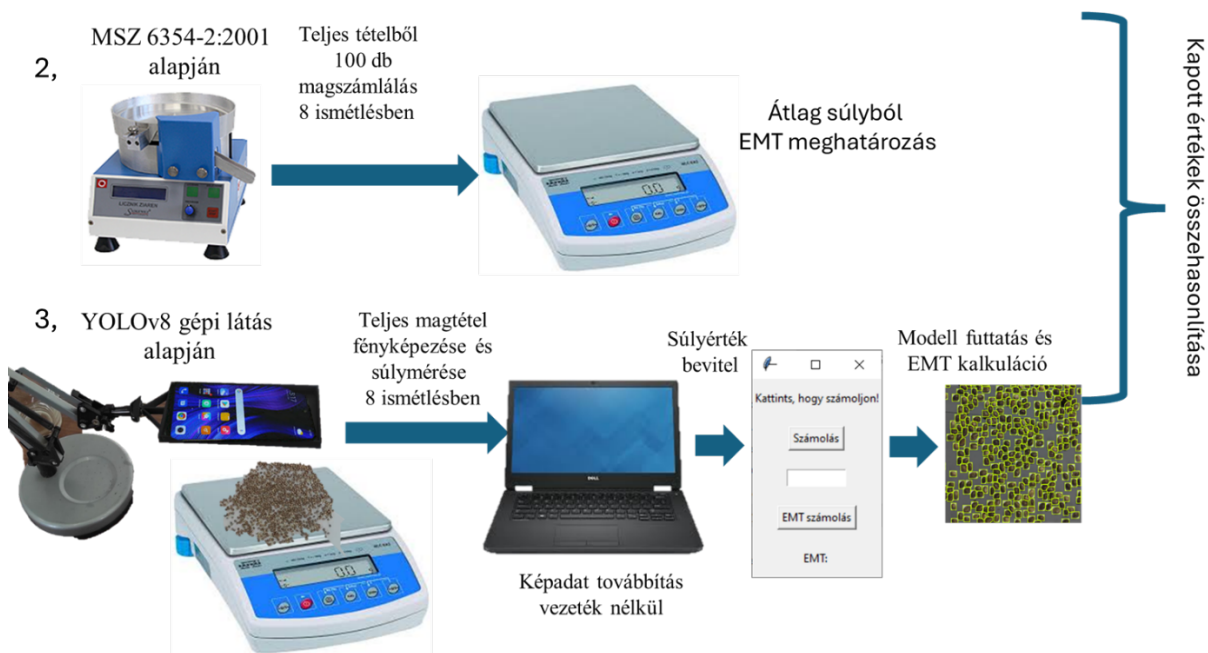
s = adatsor különbségeinek szórása

n = elemszám

A könnyebb értelmezés miatt a 11. ábrán összefoglaltam a validálási folyamat elemeit.

11. ábra: A YOLOv8 modell alapján végzett EMT kalkuláció validálásának folyamata

1, PONTOS MAGTÉTEL DARABSZÁM ÉS ANNAK TÖMEGÉBŐL SZÁMOLT EMT

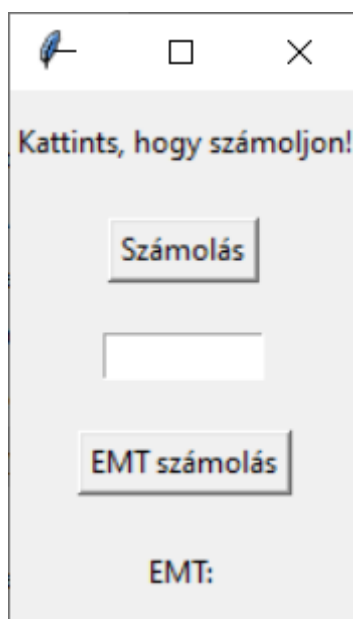


4. EREDMÉNYEK ÉS ÉRTÉKELÉSÜK

A szabvány szerinti gépi magszámlálás során 8 ismétlésben vizsgáltam 100 db kendermagot, a súlyt 3 tizedes pontossággal jegyeztem fel. A variációs együttható nem haladta meg a 4%-ot egyetlen esetben sem (min.: 0,76; max.: 3,82), így a továbbiakban az ismétlések átlagából számoltam az ezermagtömeget (nyers adatokat az 1. melléklet tartalmazza).

A neurális hálózaton alapuló vizsgálat során a teljes magtétel a mérlegen lévő fehér papírtálcára került, a 12. ábrán látható Python nyelven fejlesztett programba gépeltem 3 tizedes pontossággal a mért súlyt. A detektálás (12. ábra) és a kalkuláció automatikusan elindult. A feldolgozott képek későbbi elemzésre egy könyvtárba kerültek. A variációs együttható ebben az esetben sem haladta meg a 4%-ot (min.: 0,27; max.: 1,47). Az alapadatsort a 2. melléklet tartalmazza.

12. ábra: Az adatbevitelt és detektálást megkönnyítő Python alkalmazás



13. ábra: A YOLOv8 modell által detektált kendermagok



Első lépésben, hiszen a két mérésorozat összetartozik, ugyanazt az alapmintát értékeljük, párosított t próbát (3. táblázat) alkalmaztam a várható értékre.

3. táblázat: Párosított t-próba a szabvány EMT vizsgálat és a neurális hálózat modell összehasonlítására

Kétmintás párosított t-próba a várható értékre		
	Szabvány EMT	Gépi látás EMT
Várható érték	11.74136	11.83686375
Variancia	4.212291	4.298980945
Megfigyelések	100	100
Pearson-féle korreláció	0.998421	
Feltételezett átlagos eltérés	0	
df	99	
t érték	-8.10528	
P(T<=t) egyszélű	7.14E-13	
t kritikus egyszélű	1.660391	
P(T<=t) kétszélű	1.43E-12	
t kritikus kétszélű	1.984217	

A párosított t próba eredménye alapján a két mérésorozat eredménye nem azonos. Azonban az elemzés felhívja a figyelmet a rendkívül magas korrelációra a két adatsor között (0.99).

4. táblázat: Az excel párosított t-próba eredményeinek manuális bővítése a minimális statisztikai különbség kiszámítása érdekében

Különbség átlaga	0.095504
Különbség szórása	0.117829
t számított	8.10528
t kritikus	1.660391
Számított min. különbség	0.07594

A 4. táblázatban az Excel párosított t-próba által nem közölt értékeket ismertetem. Ehhez a két adatsor különbségeit kiszámoltam. A számított t érték és a kritikus t érték megegyezik az adatelemzésben látottal, a különbség átlagának, az elemszám és a kritikus t ismeretében megállapítható a minimális különbség értéke, ami már statisztikai eltérést okoz. Ez a két mérési sor különbségének az a legkisebb értéke, amit még felvehetne úgy, hogy a nullhipotézist (a két mérés azonos) elfogadjuk (0,07).

A hiba kiderítése érdekében a teljes tételt megszámláltam, ez így kapott teljesen pontos ezermagtömeg számítás párosával is összehasonlítottam a szabvány szerinti gépi és a neurális hálózattal kapott eredményekkel.

5. táblázat: A tényleges EMT és a szabvány szerinti EMT értékek összehasonlítása

Kétmintás párosított t-próba a várható értékre		
	Szabvány EMT	Tényleges EMT
Várható érték	11.74136	11.73580379
Variancia	4.212291283	4.24106033
Megfigyelések	100	100
Pearson-féle korreláció	0.998897803	
Feltételezett átlagos eltérés	0	
df	99	
t érték	0.574113848	
P(T<=t) egyszélű	0.283596452	
t kritikus egyszélű	1.660391156	
P(T<=t) kétszélű	0.567192905	
t kritikus kétszélű	1.984216952	

Az 5. táblázat alapján a párosított t-próba egyezést mutatott, tehát a két adatsor között statisztikai különbség nem mutatkozik.

6. táblázat: A tényleges EMT és a gépi látás szerinti EMT értékek összehasonlítása

Kétmintás párosított t-próba a várható értékre		
	Gépi látás EMT	Tényleges EMT
Várható érték	11.83686375	11.73580379
Variancia	4.298980945	4.24106033
Megfigyelések	100	100
Pearson-féle korreláció	0.999709206	
Feltételezett átlagos eltérés	0	
df	99	
t érték	19.52233441	
P(T<=t) egyszélű	5.10608E-36	
t kritikus egyszélű	1.660391156	
P(T<=t) kétszélű	1.02122E-35	
t kritikus kétszélű	1.984216952	

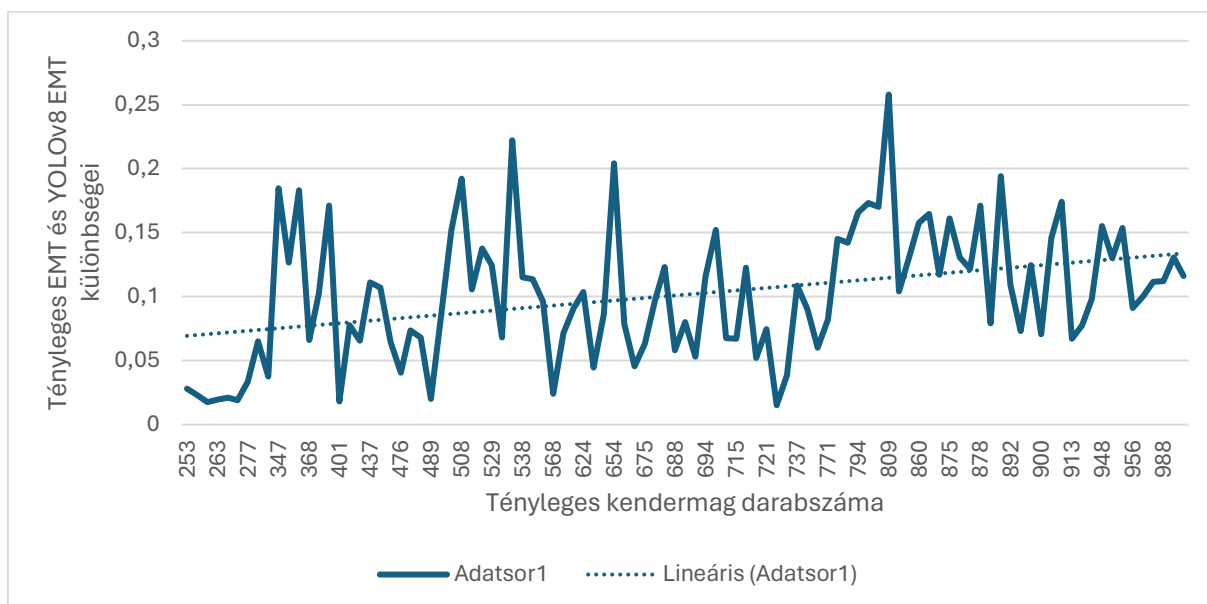
A 6. táblázat párosított t-próba adatai alapján a ténylegesen mért EMT értékek és a YOLOv8 modell alapján meghatározott adatsor különbözik. A 7. táblázatban felderítettem a különbség átlagát (0,1) és a minimális különbség mértékét, (0,09). Ez alapján kijelenthető, hogy a 6. táblázatban látható erős korreláció és a rendkívül alacsony különbség alapján a modell minimális finomítására van szükség ahhoz, hogy a szabványos EMT vizsgálat jóságát elérjük.

7. táblázat: Az excel párosított t-próba eredményeinek manuális bővítése a minimális statisztikai különbség kiszámítása érdekében

Különbség átlaga	0.101059963
Különbség szórása	0.051766331
t számított	19.52233441
t kritikus	1.660391156
Számított min. különbség	0.092464727

A 14. ábra szemléletesen mutatja a hiba mértékében bekövetkező növekvő trendet a vizsgált magmennyiség függvényében. A különbség abszolút átlaga 500 db magmennyiségig 0,07; 750 db magnál 0,096; e felett már 0,13. Hasonló trend a szabvány szerinti számolásnál nem figyelhető meg (0,071; 0,082; 0,076).

14. ábra: A tényleges EMT és a gépi látás EMT adatsorának különbségei a növekvő magtétel mennyiségek függvényében



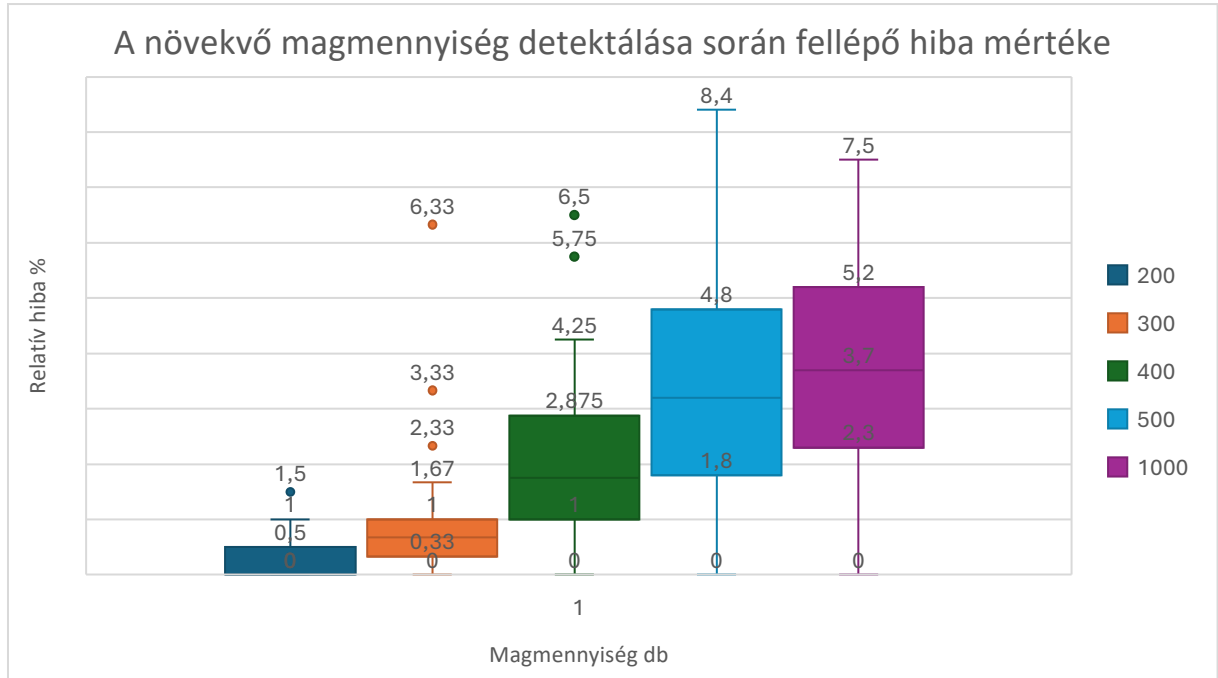
Ennek a hibalehetőségnek a mélyebb vizsgálatára készítettem lineárisan növekvő adagú kevert magmintát és azon is lefuttattam a YOLOv8 modell alapú magszámolást. A 3. melléklet tartalmazza a nyers adatsort. A 9. táblázat eredményei megerősítik az előzőekben tapasztalt trendet.

8. táblázat: A növekvő adagú kendermag adatsorok esetén előforduló hiba

Számolt mag (db)	200	300	400	500	1000
Detektált mag (db)	200.08	297.92	391.16	482.84	963.56
Hiba %	0.28	0.93	2.25	3.432	3.64

Ez egy rendkívül fontos tényező a teljes adagú ezermagtömeg vizsgálat szempontjából, ezért az egyenként 25 db mérés eredményeiből származó relatív hiba százalékos értékeit grafikonon is szemléltettem (15. ábra).

15. ábra: A növekvő magmennyiség detektálása során fellépő hiba mértéke



A 15. ábrán jól látható, hogy 300 mag felett a relatív hiba kiugró értékei egyre nagyobb számban fordulnak elő. A medián értékek és a terjedelem is növekvő tendenciát mutatnak. Egyébként a 125 (25 ismétlésben 200; 300; 400; 500; 1000 mag) vizsgált tételben a számított százalékos eltérés 2,1%-nak adódott. A hiba% növekvő tendenciája szintén tetten érhető (0,28; 0,932; 2,25; 3,42; 3,64).

5. KÖVETKEZTETÉSEK ÉS JAVASLATOK

Az elvégzett statisztikai elemzések alapján látható, hogy a gépi látáson alapuló magdetektálás kiváló alternatívát jelent a hagyományos kézi és a meglehetősen drága műszerezettséget igénylő optikai érzékelővel ellátott magszámlálókkal szemben, ugyanakkor a modell finomhangolására még szükség van, hiszen az MSZ 6354-2:2001 alapján végzett ezermagtömeg meghatározás statisztikailag jobbnak bizonyult.

A mesterséges intelligencián alapuló vizsgálat nem csupán az ezermag-tömeg meghatározására nyújt gyors és olcsó lehetőséget, hanem a nemesítési folyamatban pontos tájékoztatást ad a teljes rendelkezésre álló, növényenként értendő magszámról is.

A sebessége a vizsgálatban alkalmazott, csak CPU-val rendelkező számítógép esetén is lenyűgöző, egy tétel teljes futásideje 200 ezredmásodperc (ms) alatt volt.

A növekvő elemszámoknál jelentkező magasabb relatív hiba felderítése jó alapot jelent a modell finomhangolására. Az 5% feletti hibával detektált képek átvizsgálásával, a tanításra felhasználhatóak az eddig nem detektált objektumok. A hiba mértékét árnyalja, hogy nem mesterséges környezetben készültek sem a betanításra, sem a vizsgálatra felhasznált felvételek.

A rendszer nagy előnye, hogy teljesen automatizálható. A súlymérés eredménye digitálisan feldolgoztatható, a minták továbbítása gépesíthető, a képek elkészítése időzíthető.

A modell osztályai tovább bővíthetőek, így a kender tételekben előforduló csíráképtelen fehér magok külön értékelhetőek.

A fajtatulajdonságnak számító márványozottság és magszín megfelelő adatbázisból tanítható, rendkívül objektív gépi vizsgálatot tenne lehetővé.

Amennyiben szegmentációs modellen futtatjuk a felismerést, úgy a pontos objektum kontúr poligonok alapján számolható a magok átmérője, kerülete, így teljeskörű minőségi osztályozás is megvalósítható.

6. ÖSSZEFOGLALÁS

A kender (*Cannabis sativa L.*) felhasználása rendkívül sokrétű: élelmezési, ipari, rekreációs vagy gyógyászati célra több ezer éve alkalmazzuk.

A kriminalizált növény termesztésére vonatkozó szabályok a legtöbb országban jelentősen módosulnak, egyszerűsítve a növény termelését és feldolgozását. Ez új lendületet ad a nemesítésének, vetőmag előállításnak egyaránt.

A Lajtamag Kft. hédervári telephelyén 3 éve folyó kendernemesítési program kiemelt fontosságú feladata a manuális törzsanyag vetőmag értékelése. A munka során néhány hónap alatt több ezer tételt kell átvizsgálni, melynek során a magszín, a márványozottság és az ezermagtömeg a legfontosabb paraméterek. A nemesítési ciklus kijelöléséhez ezenfelül az egy-egy növényről származó magok pontos darabszámának ismerete is elengedhetetlen, tartalékmaggal is rendelkezni kell.

Ebben a folyamatban kulcsfontosságú egy roncsolásmentes, gyors, ugyanakkor könnyen hozzáférhető és olcsó vetőmagszámolási technika kifejlesztése. Ehhez kapcsolódik az utóbbi években egyre nagyobb teret nyerő gépi látás és adatfeldolgozás tudománya.

Szakdolgozatomban egy mesterséges intelligenciát alkalmazó, kendermag detektálására alkalmas modell validálását végeztem el. Az objektumdetektáló modell által felismert és számlált magok mennyiségét összehasonlítottam a manuális vizsgálat eredményével. Ezáltal értékelhetővé vált a számítógépes modell pontossága és megbízhatósága.

A feltárt hibák és értékelési bizonytalanságok alapján javítható, finomítható az eljárás mindaddig, amíg különböző elemszámú, eltérő morfológiai megjelenésű, a környezeti megvilágítástól és háttértől független, nagy pontosságú detektálást tudunk biztosítani.

A kutatás célja egy olyan automatizált vetőmagszámolási rendszer kifejlesztése, amely a következő előnyökkel jár:

Hatékonyságnövelés: A manuális vizsgálatához képest jelentősen gyorsabb és kevésbé munkaigényes.

Pontosság javítása: Az emberi hibaforrások kiküszöbölésével precízebb eredményeket szolgáltat.

Reprodukálhatóság: Azonos körülmények között ismételtén ugyanazt az eredményt adja.

Objektivitás: Nem befolyásolják szubjektív tényezők a vizsgálat eredményét.

Rugalmasság: Különböző kenderfajták és morfológiai jellemzők esetén is alkalmazható.

A mesterséges intelligencia alkalmazása a kendermag detektálásában ígéretes jövőt biztosít a kendernemesítés területén. A kutatás további célja a modell finomhangolása, a detektálási pontosság maximalizálása, valamint a különböző kenderfajták és termesztési körülmények közötti hatékonyságának vizsgálata.

A projekt sikeres befejezése hozzájárulhat a kendernemesítési programok hatékonyságának növeléséhez, a vetőmagtermesztés optimalizálásához és a magyarországi kendertermesztés versenyképességének javításához.

7. KÖSZÖNETNYILVÁNÍTÁS

Szakedolgozatom elkészítésében nagy segítségre voltak kollégáim, akik a K+F részlegben dolgoznak, és egy hiánypótló, a mindennapokban felhasználható módszert dolgoztak ki, ami a munkájukat megkönnyíti, és ebben végeztünk közösen méréseket, és fejlesztettük együtt a modellt és a méréseket is elvégeztük.

Emellett szeretném megköszönni Somody Gergő kollégámnak, aki segített nekem a témaválasztásban és a szakedolgozatom külső konzulensem is volt, így nyomon tudta követni a munkám.

Továbbá Dr. Mikó Péter szakfelelősünknek, aki a külső konzulensem volt, és a szakedolgozatomat építő kritikával olvasta, és nála neki, kapta meg a végső formáját.

8. IRODALOMJEGYZÉK

- Ali, A., Qadri, S., Mashwani, W. K., Belhaouari, S. B., Naeem, S., Rafique, S., Jamal F., Chesneau, C., Anam, S. (2020). Machine learning approach for the classification of corn seed using hybrid features. *International Journal of Food Properties*, 23(1), 1110–1124. <https://doi.org/10.1080/10942912.2020.1778724>
- Bócsa I. (1994): Professor Dr. Ivan Bócsa, the breeder of Kompolti hemp (interview by the JIHA). (Vol 1), J. Int. Hemp Assoc.
- Bócsa I. (2004): A kender és termesztése. Agroinform Kiadó, Kompolt
- Bócsa, I. and Karus, M. (1998) The Cultivation of Hemp. Botany, Varieties, Cultivation and Harvesting. HempTech, Sebastopol, California.
- Bócsa I. - Manninger G. (1981): A kender és a rostlen termesztése. Mezőgazdasági kiadó, Budapest, pp. 9-115.
- Boonsri, P., & Limpiyakorn, Y. (2023). Object Detection Model for Gender Screening of Cannabis Seeds. *Proceedings of the 2023 9th International Conference on Computer Technology Applications*. <https://doi.org/10.1145/3605423.3605448>
- Borhidi A. (1998): A zárva termők fejlődéstörténeti rendszertana. Budapest
- Borsos J., Pusztai P., Dr. Radics L., Dr. Szemán L., Tomposné L. V., (1994.). Szántóföldi növénytermesztés, Kender, <https://mek.oszk.hu/01200/01216/01216.htm>
- Braguy, J., Merey Ramazanova, Giancola, S., Jamil, M., Boubacar Amadou Kountche, Alhassan, R., Salim Al-Babili. (2021). SeedQuant: a deep learning-based tool for assessing stimulant and inhibitor activity on root parasitic seeds. *Plant Physiology (Bethesda)*, 186(3), 1632–1644. <https://doi.org/10.1093/plphys/kiab173>
- Csaba Kollár, & Nagy, B. (2021). A mesterséges intelligencia felhasználási lehetőségei az objektumfelismerésben (második rész). *Biztonságtudományi Szemle*, 3(1), 115–129.

- Csajbók J. (2019): Rostkender. In: Pepó P. : Alternatív növények. Mezőgazda lap- és könyvkiadó, Budapest, pp.165-173.
- De Candolle A.P.(1894): Termesztett növényeink eredete.-Term.tud.Társ., Budapest, pp. 516.
- Sieracka, D., Zaborowicz, M., Frankowski, J. (2023). Identification of Characteristic Parameters in Seed Yielding of Selected Varieties of Industrial Hemp (*Cannabis sativa* L.) Using Artificial Intelligence Methods. *Agriculture*, 13(5), 1097–1097.
<https://doi.org/10.3390/agriculture13051097>
- Farinon, B., Molinari, R., Costantini, L., & Merendino, N. (2020). The Seed of Industrial Hemp (*Cannabis sativa* L.): Nutritional Quality and Potential Functionality for Human Health and Nutrition. *Nutrients*, 12(7), 1935. <https://doi.org/10.3390/nu12071935>
- Ferentinos, K. P., Barda, M., & Damer, D. (2019). An Image-Based Deep Learning Model for Cannabis Diseases, Nutrient Deficiencies and Pests Identification. *Lecture Notes in Computer Science*, 134–145. https://doi.org/10.1007/978-3-030-30241-2_12
- Heo Y. J., Kim S. J., Kim, D., Lee, K., & Chung W. C. (2018). Super-High-Purity Seed Sorter Using Low-Latency Image-Recognition Based on Deep Learning. *IEEE Robotics and Automation Letters*, 3(4), 3035–3042. <https://doi.org/10.1109/lra.2018.2849513>
- Hoffmann W. 1944. “Hanf, *Cannabis sativa* L.,”pp. 314–341 in Roemer T, ed. Handbuch derPflanzenzüchtung, Band IV: Rüben, Kartoffeln, Öl- und Gespinstpflanzen, Tabak. Parey, Berlin
- Iványi I. (2012): Kender. In: Pepó P.: Fenntartható szemléletű szántóföldi növénytermesztés. Agroiinform kiadó, Budapest, pp. 459-474.
- Jiang, H., Hu, F., Fu, X., Chen, C., Wang, C., Tian, L., & Shi, Y. (2023). YOLOv8-Peas: a lightweight drought tolerance method for peas based on seed germination vigor. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1257947>

- Jocher, G., Chaurasia, A. & Qiu, J. (2023): “YOLO by Ultralytics.”
<https://github.com/ultralytics/ultralytics>, 2023. Accessed: February 30, 2023.
- Kovalchuk, I., Pellino, M., Rigault, P., van Velzen, R., Ebersbach, J., R. Ashnest, J., ...
Sharbel, T. F. (2020). The Genomics of Cannabis and Its Close Relatives. *Annual Review of Plant Biology*, 71(1). <https://doi.org/10.1146/annurev-arplant-081519-040203>
- Kundu, N., Rani, G., & Vijaypal Singh Dhaka. (2021). *Seeds Classification and Quality Testing Using Deep Learning and YOLO v5*.
<https://doi.org/10.1145/3484824.3484913>
- Meijer, E.P.M. de 1995. Fibre hemp cultivars: A survey of origin, ancestry, availability and brief agronomic characteristics *Journal of the International Hemp Association* 2(2): 66-73.
- Mishchenko, S., Laiko, I., & Kyrychenko, H. (2021). Breeding of industrial hemp with a high content of cannabigerol by the case of “Vik 2020” cultivar. *Plant Varieties Studying and Protection*, 17(2), 105–112. <https://doi.org/10.21498/2518-1017.17.2.2021.236514>
- Phan, T., Hai, T.T., Le, T., Hoang, V.T., Vu, H., & Nguyen, T.T. (2015). Comparative Study on Vision Based Rice Seed Varieties Identification. *2015 Seventh International Conference on Knowledge and Systems Engineering (KSE)*, 377-382.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
- Robert Connell Clarke, & Mark David Merlin. (2016). *Cannabis : evolution and ethnobotany*. Berkeley: University Of California Press.

- Sarker, T. T., Islam, T., & Ahmed, K. R. (2024). Cannabis Seed Variant Detection using Faster R-CNN. *ArXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.2403.10722>
- Small, E., & Marcus, D. (2003). Tetrahydrocannabinol Levels in Hemp (CANNABIS SATIVA) Germplasm Resources. *Economic Botany*, 57(4), 545–558. [https://doi.org/10.1663/0013-0001\(2003\)057\[0545:tlihcs\]2.0.co;2](https://doi.org/10.1663/0013-0001(2003)057[0545:tlihcs]2.0.co;2)
- Terven, J., & Cordova-Esparza, D. (2023). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *arXiv preprint arXiv:2304.00501*.
- Wang, N., Liu, H., Li, Y., Zhou, W., & Ding, M. (2023). Segmentation and Phenotype Calculation of Rapeseed Pods Based on YOLO v8 and Mask R-Convolution Neural Networks. *Plants*, 12(18), 3328–3328. <https://doi.org/10.3390/plants12183328>
- Wu, W., Zhou, L., Chen, J., Qiu, Z., & He, Y. (2018). GainTKW: A Measurement System of Thousand Kernel Weight Based on the Android Platform. *Agronomy*, 8(9), 178. <https://doi.org/10.3390/agronomy8090178>
- Zhao, J., Ma, Y., Yong, K., Zhu, M., Wang, Y., Luo, Z., Huang, X. (2022). Deep-learning-based automatic evaluation of rice seed germination rate. *Journal of the Science of Food and Agriculture*, 103(4), 1912–1924. <https://doi.org/10.1002/jsfa.12318>

9. MELLÉKLETEK

1. melléklet: Szabvány gépi EMT vizsgálat alapadatai

Szabvány EMT													
Sorszám	Név	1	2	3	4	5	6	7	8	átlagból EMT	Variancia	Standard eltérés	Variációs együttható
1	K01 K23B7 002	1.287	1.254	1.31	1.311	1.29	1.29	1.287	1.298	12.909	0.000316	0.01778	1.3773529
2	K05 K23B30 003	1.105	1.111	1.091	1.075	1.077	1.057	1.039	1.056	10.764	0.000632	0.025134	2.33502
3	K05 K23B30 004	1.014	1.052	1.004	0.974	1.045	0.998	0.982	1.012	10.101	0.000753	0.027435	2.7160315
4	K08 K23B1 007	0.932	0.916	0.92	0.895	0.906	0.931	0.926	0.904	9.163	0.000183	0.01353	1.4767137
5	K13 K23B1 019	1.137	1.084	1.087	1.111	1.166	1.101	1.068	1.108	11.075	0.000983	0.031349	2.830008
6	K18 K23B2 010	1.203	1.209	1.228	1.183	1.136	1.156	1.186	1.196	11.871	0.000869	0.029474	2.4827762
7	K19 K23B2 011	1.392	1.387	1.453	1.398	1.46	1.407	1.419	1.442	14.198	0.000814	0.028534	2.0098215
8	K20 K23B7 008	1.399	1.4	1.46	1.437	1.419	1.456	1.453	1.44	14.33	0.000595	0.02439	1.7020023
9	K22 K23B7 012	1.444	1.435	1.412	1.406	1.478	1.4	1.403	1.389	14.209	0.000867	0.029445	2.0722837
10	K22 K23B7 013	1.122	1.135	1.138	1.119	1.133	1.115	1.116	1.153	11.29	0.000175	0.013217	1.1708362
11	L05 K23B1 024	1.144	1.148	1.154	1.063	1.119	1.177	1.166	1.174	11.433	0.001396	0.037357	3.2679811
12	L08 K23B1 032	0.937	1.004	1.021	1.017	0.981	0.986	1.002	0.96	9.885	0.000831	0.02883	2.9164945
13	L10 K23B1 038	1.316	1.314	1.305	1.329	1.324	1.339	1.332	1.327	13.232	0.000121	0.010977	0.8295673
14	L12 K23B1 043	1.181	1.192	1.175	1.19	1.154	1.192	1.186	1.165	11.794	0.000193	0.013876	1.1765865
15	L16 K23B2 019	1.096	1.13	1.134	1.097	1.111	1.116	1.148	1.08	11.142	0.000513	0.022659	2.0340182
16	L20 K23B7 019	1.352	1.35	1.322	1.379	1.33	1.325	1.32	1.353	13.416	0.000424	0.020591	1.5350537
17	L21 K23B7 020	1.265	1.284	1.244	1.287	1.264	1.257	1.28	1.244	12.656	0.000288	0.016962	1.3401771
18	L21 K23B7 021	1.544	1.525	1.562	1.597	1.587	1.581	1.604	1.494	15.617	0.00147	0.038343	2.4551544
19	L21 K23B7 022	1.575	1.601	1.539	1.553	1.584	1.566	1.583	1.575	15.72	0.000373	0.01931	1.2283403
20	M09 K23B3 001	1.342	1.361	1.354	1.367	1.361	1.371	1.373	1.38	13.637	0.000142	0.011928	0.8746986
21	M11 K23B3 009	1.377	1.39	1.384	1.332	1.41	1.4	1.366	1.398	13.821	0.000602	0.024532	1.7749779
22	M13 K23B4 001	1.072	1.022	0.997	1.044	1.004	1.071	1.032	1.103	10.35	0.001346	0.036693	3.5176484
23	M17 K23B4 011	1.016	0.966	0.974	0.984	1.008	0.997	1.011	0.988	9.932	0.000327	0.018087	1.8214593
24	M19 K23B32 001	1.461	1.494	1.429	1.454	1.452	1.466	1.468	1.439	14.576	0.000389	0.019723	1.3528341
25	M22 K23B8 003	1.677	1.667	1.658	1.69	1.592	1.586	1.64	1.636	16.432	0.001439	0.037935	2.3085407
26	M24 K23B8 007	1.177	1.198	1.162	1.213	1.199	1.164	1.148	1.169	11.788	0.000499	0.022346	1.8957625
27	M24 K23B8 008	1.356	1.363	1.347	1.317	1.358	1.372	1.329	1.354	13.494	0.000329	0.01815	1.344955
28	M26 K23B5 003	1.185	1.161	1.238	1.172	1.15	1.169	1.182	1.169	11.782	0.000705	0.026553	2.2536118
29	N07 K23B2 045	1.206	1.209	1.212	1.227	1.176	1.22	1.195	1.236	12.103	0.000352	0.018773	1.5512947
30	N10 K23B3 016	1.29	1.173	1.209	1.229	1.183	1.201	1.228	1.217	12.16	0.001286	0.03586	2.9483943
31	N11 K23B3 020	1.172	1.184	1.19	1.13	1.167	1.191	1.181	1.142	11.697	0.000508	0.022532	1.9264397
32	N13 K23B4 016	1.069	1.055	1.052	1.065	1.051	1.085	1.073	1.056	10.632	0.000143	0.011961	1.1249703
33	N15 K23B4 020	1.324	1.296	1.29	1.295	1.308	1.308	1.341	1.348	13.136	0.000474	0.02177	1.6570809
34	N16 K23B4 021	1.15	1.168	1.142	1.144	1.144	1.148	1.11	1.08	11.356	0.000763	0.027619	2.4317478
35	N23 K23B8 015	0.78	0.762	0.763	0.799	0.793	0.782	0.766	0.738	7.727	0.000386	0.019643	2.5415225
36	N24 K23B8 019	1.251	1.275	1.288	1.229	1.276	1.324	1.299	1.308	12.811	0.000945	0.030742	2.3993767
37	N24 K23B8 020	1.147	1.096	1.084	1.124	1.086	1.11	1.116	1.153	11.145	0.000677	0.026011	2.3338705

38	O07 K23B2 053	1.11	1.164	1.097	1.18	1.144	1.103	1.173	1.114	11.358	0.001132	0.033641	2.9623067
39	O11 K23B3 032	1.463	1.413	1.409	1.431	1.493	1.485	1.433	1.458	14.482	0.000997	0.031575	2.1804074
40	O12 K23B3 035	1.209	1.195	1.217	1.239	1.24	1.229	1.238	1.21	12.222	0.000284	0.016839	1.37785
41	O14 K23B4 030	1.32	1.321	1.324	1.289	1.315	1.278	1.281	1.331	13.075	0.000448	0.021159	1.6184215
42	O14 K23B4 031	0.976	1.014	1.006	1.038	0.992	1.072	1.009	1.084	10.24	0.00144	0.037941	3.705672
43	O16 K23B4 036	1.331	1.262	1.297	1.257	1.287	1.277	1.354	1.267	12.914	0.001198	0.034616	2.6803147
44	O21 K23B1 076	1.16	1.096	1.124	1.092	1.108	1.094	1.091	1.146	11.139	0.000716	0.026761	2.4024699
45	O26 K23B5 010	1.493	1.496	1.52	1.489	1.467	1.502	1.515	1.519	15	0.000324	0.017988	1.1990731
46	P10 K23B3 039	0.972	0.984	0.939	0.969	0.939	0.966	0.958	0.962	9.61	0.000245	0.015661	1.6294478
47	P11 K23B3 041	1.74	1.775	1.8	1.79	1.748	1.776	1.774	1.768	17.714	0.000393	0.01982	1.1189146
48	P12 K23B3 045	1.108	1.121	1.147	1.102	1.086	1.119	1.102	1.094	11.099	0.000362	0.01903	1.7145699
49	P13 K23B4 046	1.204	1.192	1.139	1.145	1.169	1.188	1.188	1.168	11.741	0.000535	0.023124	1.9694244
50	P15 K23B4 051	1.019	1.056	1.045	1.044	1.047	1.034	1.052	1.074	10.464	0.000257	0.016026	1.531593
51	P18 K23B4 060	0.941	0.918	0.881	0.895	0.851	0.922	0.921	0.9	9.036	0.000802	0.028314	3.1334065
52	P19 K23B4 061	1.419	1.415	1.454	1.408	1.426	1.384	1.446	1.418	14.214	0.000475	0.021796	1.533589
53	P25 K23B5 013	1.401	1.378	1.346	1.362	1.389	1.351	1.371	1.392	13.737	0.000394	0.019855	1.4453016
54	P26 K23B5 015	0.928	0.905	0.986	0.956	0.962	0.953	0.939	0.979	9.508	0.000707	0.026587	2.7956662
55	Q02 K23B4 066	0.969	0.943	1.044	0.99	0.971	0.983	0.961	0.974	9.793	0.000881	0.029689	3.0313784
56	Q04 K23B4 072	1.165	1.15	1.165	1.15	1.151	1.146	1.157	1.121	11.506	0.000193	0.013907	1.2088664
57	Q12 K23B6 001	1.178	1.161	1.176	1.21	1.207	1.167	1.223	1.171	11.865	0.000537	0.02317	1.9525792
58	Q12 K23B6 003	1.277	1.271	1.276	1.245	1.276	1.281	1.262	1.291	12.722	0.00019	0.013773	1.0824665
59	Q13 K23B6 006	1.532	1.497	1.516	1.506	1.512	1.523	1.505	1.523	15.141	0.000132	0.011511	0.7601694
60	Q16 K23B8 021	1.019	1.002	1.015	1.006	0.95	1.029	0.99	0.996	10.009	0.000582	0.024133	2.4112089
61	Q18 K23B8 026	1.502	1.474	1.485	1.446	1.465	1.454	1.497	1.48	14.754	0.000389	0.019712	1.336051
62	Q18 K23B8 027	0.529	0.548	0.544	0.538	0.5	0.532	0.546	0.504	5.302	0.000346	0.018597	3.5079943
63	Q21 K23B32 015	1.388	1.335	1.329	1.342	1.323	1.279	1.345	1.329	13.338	0.0009	0.029994	2.2488508
64	R01 K23B4 074	1.719	1.657	1.678	1.705	1.679	1.736	1.694	1.683	16.937	0.00064	0.025301	1.4936575
65	R04 K23B4 080	0.829	0.837	0.805	0.796	0.806	0.79	0.795	0.803	8.075	0.000279	0.016716	2.0697208
66	R07 K23B3 062	1.051	1.112	1.053	1.039	1.051	1.026	1.066	1.098	10.622	0.000851	0.029179	2.7475752
67	R07 K23B3 063	1.163	1.215	1.22	1.211	1.186	1.208	1.213	1.214	12.037	0.000375	0.019374	1.6094817
68	R10 K23B3 070	1.081	0.998	1.059	1.098	1.035	1.071	1.06	1.086	10.61	0.001021	0.031946	3.0109692
69	R12 K23B6 014	1.216	1.223	1.241	1.166	1.283	1.187	1.221	1.221	12.199	0.001206	0.034726	2.8470164
70	R14 K23B6 017	1.171	1.172	1.15	1.14	1.12	1.134	1.11	1.092	11.363	0.000801	0.028297	2.4906221
71	R14 K23B6 018	1.21	1.216	1.219	1.284	1.243	1.262	1.23	1.199	12.33	0.000817	0.028588	2.3187993
72	R19 K23B8 038	1.04	1.069	1.032	1.032	1.012	1.048	1.065	1.024	10.403	0.000385	0.019631	1.8870959
73	R26 K23B1 119	0.925	0.951	0.927	0.963	1.001	0.987	0.977	0.972	9.63	0.00074	0.027205	2.8254175
74	S03 K23B4 083	1.159	1.072	1.068	1.146	1.111	1.067	1.085	1.081	10.986	0.001312	0.036225	3.2973251
75	S04 K23B4 088	1.292	1.27	1.247	1.283	1.246	1.278	1.297	1.29	12.753	0.000389	0.019712	1.545566
76	S07 K23B3 073	1.149	1.234	1.212	1.218	1.211	1.223	1.19	1.181	12.021	0.000757	0.027505	2.2877559
77	S08 K23B3 074	1.153	1.157	1.127	1.147	1.122	1.133	1.097	1.132	11.334	0.000375	0.019361	1.7080924
78	R04 K23B4 081	0.792	0.841	0.848	0.847	0.805	0.808	0.812	0.804	8.198	0.000489	0.022123	2.6991159
79	R07 K23B3 064	0.853	0.849	0.898	0.857	0.853	0.812	0.866	0.881	8.587	0.000634	0.025179	2.9324795
80	R07 K23B3 065	0.994	1.034	0.988	1.022	1.005	0.992	1	1.004	10.05	0.000248	0.015743	1.5666538
81	R10 K23B3 071	1.021	1.064	1.107	1.091	1.084	1.039	1.12	1.111	10.734	0.001263	0.035544	3.2922996
82	R12 K23B6 015	0.929	0.958	0.967	0.969	0.942	0.975	0.977	0.933	9.562	0.000364	0.019084	1.9957541
83	R14 K23B6 019	1.081	1.068	1.086	1.125	1.076	1.068	1.071	1.127	10.877	0.000596	0.024423	2.2453091

84	R14 K23B6 020	1.081	1.055	1.065	1.066	1.063	1.058	1.098	1.071	10.697	0.000195	0.013958	1.3049886
85	R19 K23B8 039	1.092	1.158	1.113	1.109	1.079	1.1	1.139	1.129	11.148	0.000673	0.025942	2.3268886
86	R26 K23B1 120	1.227	1.216	1.236	1.199	1.23	1.225	1.193	1.241	12.21	0.000293	0.017117	1.4020044
87	S03 K23B4 084	1.068	1.053	1.046	1.138	1.112	1.083	1.06	1.072	10.791	0.000983	0.031355	2.9059415
88	S04 K23B4 089	1.284	1.254	1.239	1.259	1.295	1.253	1.247	1.27	12.627	0.000363	0.019056	1.509224
89	S07 K23B3 074	1.074	1.055	1.046	1.061	1.084	1.049	1.063	1.071	10.629	0.000168	0.012977	1.2209635
90	S08 K23B3 075	1.278	1.275	1.297	1.263	1.259	1.267	1.326	1.279	12.805	0.000476	0.021817	1.7038207
91	R04 K23B4 082	1.061	1.048	1.057	1.071	1.055	1.015	1.06	1.042	10.513	0.000288	0.016983	1.615665
92	R07 K23B3 066	1.039	0.984	0.976	0.978	0.988	1.001	0.963	1.014	9.929	0.000592	0.024322	2.4496411
93	R07 K23B3 067	1.084	1.114	1.086	1.065	1.077	1.095	1.136	1.109	10.958	0.000523	0.022865	2.0866537
94	R10 K23B3 072	1.31	1.332	1.315	1.357	1.361	1.33	1.309	1.327	13.3	0.000396	0.019889	1.4952376
95	R12 K23B6 016	0.97	1.004	1.009	0.999	1.007	0.966	0.966	1.009	9.912	0.000404	0.020098	2.0275384
96	R14 K23B6 021	1.106	1.099	1.093	1.112	1.112	1.083	1.129	1.121	11.069	0.000224	0.014961	1.3516666
97	R14 K23B6 022	1.139	1.053	1.099	1.15	1.126	1.109	1.091	1.167	11.167	0.001331	0.036476	3.2662655
98	R19 K23B8 040	1.287	1.337	1.35	1.305	1.32	1.35	1.339	1.315	13.253	0.000508	0.022545	1.7010127
99	R26 K23B1 121	0.911	0.886	0.951	0.919	0.881	0.898	0.984	0.904	9.165	0.00121	0.034788	3.7947242
100	S03 K23B4 085	0.863	0.936	0.955	0.899	0.953	0.976	0.93	0.92	9.288	0.001264	0.035553	3.8269944

2. melléklet: Gépi látáson alapuló EMT vizsgálat alapadatai

Sorszám	Név	Gépi látás EMT																átlag	Varianscia	Standard eltérés	Variációs együttható	
		1	2	3	4	5	6	7	8	1	2	3	4	5	6	7	8					
1	K01 K23B7 002	635	651	643	648	637	639	638	643	8.3	13.071	12.75	12.908	12.809	13.03	12.989	13.009	12.908	12.93425	0.012495	0.111783	0.864237458
2	K05 K23B30 003	688	695	677	679	695	690	680	690	7.553	10.978	10.868	11.157	11.124	10.868	10.946	11.107	10.946	10.99925	0.013233	0.115036	1.045856124
3	K05 K23B30 004	535	530	545	527	523	531	537	528	5.441	10.17	10.266	9.983	10.324	10.403	10.247	10.132	10.305	10.22875	0.017168	0.131026	1.280962408
4	K08 K23B1 007	572	580	584	575	577	580	574	569	5.38	9.406	9.276	9.212	9.357	9.324	9.276	9.373	9.455	9.334875	0.006226	0.078904	0.84526025
5	K13 K23B1 019	882	888	885	875	884	887	883	882	9.814	11.127	11.052	11.089	11.216	11.102	11.064	11.114	11.127	11.11138	0.002543	0.050427	0.45382838
6	K18 K23B2 010	529	533	532	520	525	533	527	519	6.418	12.132	12.041	12.064	12.342	12.225	12.041	12.178	12.366	12.17363	0.016707	0.129254	1.061753043
7	K19 K23B2 011	501	500	501	497	508	497	504	502	7.235	14.441	14.47	14.441	14.557	14.242	14.557	14.355	14.412	14.43438	0.010749	0.103675	0.718252306
8	K20 K23B7 008	641	646	640	651	644	646	647	644	9.417	14.691	14.577	14.714	14.465	14.623	14.577	14.555	14.623	14.60313	0.006224	0.07889	0.540223427
9	K22 K23B7 012	715	710	715	726	716	720	715	714	10.128	14.165	14.265	14.165	13.95	14.145	14.067	14.165	14.185	14.13838	0.008708	0.093318	0.66003413
10	K22 K23B7 013	847	842	843	850	843	857	849	854	9.665	11.411	11.479	11.465	11.371	11.465	11.278	11.384	11.317	11.39625	0.005367	0.07326	0.642845665
11	L05 K23B1 024	670	665	674	667	674	671	676	674	7.832	11.69	11.777	11.62	11.742	11.62	11.672	11.586	11.62	11.66588	0.004494	0.067036	0.574634173
12	L08 K23B1 032	889	882	888	904	888	892	884	881	8.84	9.944	10.023	9.955	9.779	9.955	9.91	10	10.034	9.95	0.006545	0.080899	0.813050508
13	L10 K23B1 038	683	679	670	682	674	669	681	678	8.897	13.026	13.103	13.279	13.045	13.2	13.299	13.065	13.122	13.14238	0.011071	0.105218	0.800601534
14	L12 K23B1 043	719	715	715	709	714	700	706	710	8.441	11.74	11.806	11.806	11.906	11.822	12.059	11.956	11.889	11.873	0.0103	0.101488	0.854775609
15	L16 K23B2 019	395	399	404	401	406	402	400	396	4.48	11.342	11.228	11.089	11.172	11.034	11.144	11.2	11.313	11.19025	0.010965	0.104713	0.935750968
16	L20 K23B7 019	865	868	868	877	863	860	868	867	11.804	13.646	13.599	13.599	13.46	13.678	13.726	13.599	13.615	13.61525	0.006006	0.0775	0.569212975
17	L21 K23B7 020	667	670	667	679	666	680	660	676	8.501	12.745	12.688	12.745	12.52	12.764	12.501	12.88	12.575	12.67725	0.017739	0.133189	1.050615694
18	L21 K23B7 021	683	680	684	673	683	675	690	677	10.651	15.594	15.663	15.572	15.826	15.594	15.779	15.436	15.733	15.64963	0.016118	0.126957	0.811243817
19	L21 K23B7 022	544	546	546	538	539	552	539	533	8.565	15.744	15.687	15.687	15.92	15.891	15.516	15.891	16.069	15.80063	0.030379	0.174294	1.103085764
20	M09 K23B3 001	948	947	938	942	941	949	936	935	12.934	13.643	13.658	13.789	13.73	13.745	13.629	13.818	13.833	13.73063	0.00643	0.080187	0.584002326
21	M11 K23B3 009	522	516	519	516	519	515	525	519	7.288	13.962	14.124	14.042	14.124	14.042	14.151	13.882	14.042	14.04613	0.00817	0.09039	0.643524988
22	M13 K23B4 001	476	475	476	477	485	482	477	475	5	10.504	10.526	10.504	10.482	10.309	10.373	10.482	10.526	10.46325	0.006263	0.079136	0.75632293
23	M17 K23B4 011	492	496	498	490	495	490	491	496	5.01	10.183	10.101	10.06	10.224	10.121	10.224	10.204	10.101	10.15225	0.004094	0.063986	0.630264696
24	M19 K23B32 001	351	348	348	351	352	345	346	348	5.128	14.61	14.736	14.736	14.61	14.568	14.864	14.821	14.736	14.71013	0.011176	0.105714	0.718651207

25	M22 K23B8 003	376	381	383	376	379	381	381	376	6.375	16.955	16.732	16.645	16.955	16.821	16.732	16.732	16.955	16.81588	0.015485	0.12444	0.740013923
26	M24 K23B8 007	859	866	857	846	858	862	855	845	10.135	11.799	11.703	11.826	11.98	11.812	11.758	11.854	11.994	11.84075	0.010237	0.10118	0.854505211
27	M24 K23B8 008	949	947	942	954	949	952	950	954	12.922	13.616	13.645	13.718	13.545	13.616	13.574	13.602	13.545	13.60763	0.003247	0.056979	0.418725061
28	M26 K23B5 003	688	683	684	676	690	689	685	682	8.064	11.721	11.807	11.789	11.929	11.687	11.704	11.772	11.824	11.77913	0.00613	0.078295	0.66469381
29	N07 K23B2 045	693	689	686	692	693	684	691	692	8.403	12.126	12.196	12.249	12.143	12.126	12.285	12.161	12.143	12.17863	0.003565	0.059711	0.490293939
30	N10 K23B3 016	799	794	783	796	781	798	790	797	9.842	12.318	12.395	12.57	12.364	12.602	12.333	12.458	12.349	12.42363	0.011963	0.109373	0.880366714
31	N11 K23B3 020	743	731	732	734	736	731	723	739	8.623	11.606	11.796	11.78	11.748	11.716	11.796	11.927	11.668	11.75463	0.009273	0.096296	0.819214419
32	N13 K23B4 016	715	725	722	728	727	728	733	722	7.663	10.717	10.57	10.614	10.526	10.541	10.526	10.454	10.614	10.57025	0.006236	0.078966	0.747059783
33	N15 K23B4 020	713	709	710	713	716	712	708	710	9.378	13.153	13.227	13.208	13.153	13.098	13.171	13.246	13.208	13.183	0.002332	0.048291	0.366311051
34	N16 K23B4 021	340	343	342	344	348	350	342	345	4.011	11.797	11.694	11.728	11.66	11.526	11.46	11.728	11.626	11.65238	0.012546	0.112008	0.961242434
35	N23 K23B8 015	253	255	256	254	253	254	255	254	1.981	7.83	7.769	7.738	7.799	7.83	7.799	7.769	7.799	7.791625	0.001001	0.031641	0.406084218
36	N24 K23B8 019	550	548	548	553	562	553	559	558	7.146	12.993	13.04	13.04	12.922	12.715	12.922	12.784	12.806	12.90275	0.015039	0.122634	0.95044771
37	N24 K23B8 020	581	582	579	577	575	574	568	575	6.537	11.251	11.232	11.29	11.329	11.369	11.389	11.509	11.369	11.34225	0.00783	0.088487	0.780152823
38	O07 K23B2 053	781	779	799	782	787	770	780	784	9.083	11.63	11.66	11.368	11.615	11.541	11.796	11.645	11.585	11.605	0.014642	0.121005	1.042699808
39	O11 K23B3 032	481	475	479	479	472	472	479	476	6.987	14.526	14.709	14.587	14.587	14.803	14.803	14.587	14.679	14.66013	0.011086	0.105291	0.718211264
40	O12 K23B3 035	439	443	441	444	437	438	445	442	5.397	12.294	12.183	12.238	12.155	12.35	12.322	12.128	12.21	12.235	0.006495	0.080589	0.658675144
41	O14 K23B4 030	527	526	526	528	512	526	526	521	6.841	12.981	13.006	13.006	12.956	13.361	13.006	13.006	13.131	13.05663	0.017753	0.133241	1.020484645
42	O14 K23B4 031	916	922	921	920	927	923	914	932	9.293	10.145	10.079	10.09	10.101	10.025	10.068	10.167	9.971	10.08075	0.003912	0.062543	0.620421377
43	O16 K23B4 036	619	616	611	622	620	617	625	622	7.966	12.869	12.932	13.038	12.807	12.848	12.911	12.746	12.807	12.86975	0.008221	0.09067	0.704521255
44	O21 K23B1 076	492	491	482	485	485	492	489	489	5.357	10.888	10.91	11.114	11.045	11.045	10.888	10.955	10.955	10.975	0.007041	0.083908	0.764538615
45	O26 K23B5 010	269	270	269	270	269	271	269	270	4.071	15.134	15.078	15.134	15.078	15.134	15.022	15.134	15.078	15.099	0.001736	0.041665	0.275947634
46	P10 K23B3 039	365	367	369	364	363	366	368	362	3.535	9.685	9.632	9.58	9.712	9.738	9.658	9.606	9.765	9.672	0.004199	0.064796	0.669937804
47	P11 K23B3 041	885	907	899	896	899	906	886	894	16.014	18.095	17.656	17.813	17.873	17.813	17.675	18.074	17.913	17.864	0.026304	0.162186	0.907892747
48	P12 K23B3 045	686	690	691	689	681	692	685	679	7.74	11.283	11.217	11.201	11.234	11.366	11.185	11.299	11.399	11.273	0.006127	0.078272	0.694335297
49	P13 K23B4 046	515	516	520	515	527	519	505	514	6.06	11.767	11.744	11.654	11.767	11.499	11.676	12	11.79	11.73713	0.020154	0.141966	1.209548598
50	P15 K23B4 051	451	460	457	467	455	453	458	457	4.857	10.769	10.559	10.628	10.4	10.675	10.722	10.605	10.628	10.62325	0.012574	0.112135	1.055560248
51	P18 K23B4 060	624	621	630	626	628	634	614	630	5.531	8.864	8.907	8.779	8.835	8.807	8.724	9.008	8.779	8.837875	0.007895	0.088854	1.005374166
52	P19 K23B4 061	862	876	863	866	863	865	860	867	12.491	14.491	14.259	14.474	14.424	14.474	14.44	14.524	14.407	14.43663	0.006569	0.08105	0.561420268
53	P25 K23B5 013	272	271	271	271	273	272	271	272	3.729	13.71	13.76	13.76	13.76	13.659	13.71	13.76	13.71	13.72863	0.001404	0.037466	0.272903783
54	P26 K23B5 015	766	765	753	765	759	756	766	755	7.469	9.751	9.763	9.919	9.763	9.841	9.88	9.751	9.893	9.820125	0.005027	0.070903	0.722019616

55	Q02 K2384 066	431	439	428	436	431	428	437	435	4.273	9.914	9.733	9.984	9.8	9.914	9.984	9.778	9.823	9.86625	0.009156	0.095688	0.969852876
56	Q04 K2384 072	719	723	709	719	716	715	706	724	8.252	11.477	11.414	11.639	11.477	11.525	11.541	11.688	11.398	11.51988	0.010381	0.101889	0.884458442
57	Q12 K2386 001	743	736	735	733	736	747	738	731	8.706	11.717	11.829	11.845	11.877	11.829	11.655	11.797	11.91	11.80738	0.007032	0.083857	0.71020794
58	Q12 K2386 003	834	830	833	830	821	836	816	834	10.604	12.715	12.776	12.73	12.776	12.916	12.684	12.995	12.715	12.78838	0.012051	0.109778	0.858417243
59	Q13 K2386 006	292	292	293	293	292	291	290	291	4.429	15.168	15.168	15.116	15.116	15.168	15.22	15.272	15.22	15.181	0.002897	0.053825	0.354555784
60	Q16 K2388 021	264	262	260	262	263	262	263	264	2.651	10.042	10.118	10.196	10.118	10.08	10.118	10.08	10.042	10.09925	0.00253	0.050301	0.498069019
61	Q18 K2388 026	341	345	348	339	340	343	343	343	5.134	15.056	14.881	14.753	15.145	15.1	14.968	14.968	14.968	14.97988	0.015595	0.124879	0.833643317
62	Q18 K2388 027	256	254	256	255	256	255	254	255	1.313	5.129	5.169	5.129	5.149	5.129	5.149	5.169	5.149	5.1465	0.000279	0.01669	0.324306989
63	Q21 K23832 015	370	371	370	375	373	373	373	372	4.989	13.484	13.447	13.484	13.304	13.375	13.375	13.375	13.411	13.40688	0.003879	0.062284	0.464565895
64	R01 K2384 074	876	862	864	860	857	880	875	881	14.819	16.917	17.191	17.152	17.231	17.292	16.84	16.936	16.821	17.0475	0.035541	0.188523	1.105867894
65	R04 K2384 080	253	251	252	254	252	253	252	253	2.054	8.119	8.183	8.151	8.087	8.151	8.119	8.151	8.119	8.135	0.000878	0.029626	0.364182461
66	R07 K2383 062	323	321	322	322	325	323	327	320	3.417	10.579	10.645	10.612	10.612	10.514	10.579	10.45	10.678	10.58363	0.00529	0.072732	0.687215046
67	R07 K2383 063	683	683	680	687	678	684	687	686	8.344	12.217	12.217	12.271	12.146	12.307	12.199	12.146	12.163	12.20825	0.003389	0.058218	0.476875766
68	R10 K2383 070	930	942	932	942	943	933	943	936	10.236	11.006	10.866	10.983	10.866	10.855	10.971	10.855	10.936	10.91725	0.004063	0.063744	0.583887587
69	R12 K2386 014	555	563	584	568	565	566	563	572	6.901	12.434	12.258	11.817	12.15	12.214	12.193	12.258	12.065	12.17363	0.03194	0.178717	1.468065635
70	R14 K2386 017	661	658	659	660	649	656	657	667	7.396	11.189	11.24	11.223	11.206	11.396	11.274	11.257	11.088	11.23413	0.007522	0.08673	0.77202439
71	R14 K2386 018	402	402	401	406	402	397	398	404	5.013	12.47	12.47	12.501	12.347	12.47	12.627	12.595	12.408	12.486	0.008309	0.091151	0.730028556
72	R19 K2388 038	276	275	277	278	275	277	275	276	2.891	10.475	10.513	10.437	10.399	10.513	10.437	10.513	10.475	10.47025	0.001831	0.042788	0.4086596
73	R26 K2381 119	533	540	531	529	528	529	529	531	5.118	9.602	9.478	9.638	9.675	9.693	9.675	9.675	9.638	9.63425	0.004845	0.069607	0.722490566
74	S03 K2384 083	490	494	494	493	491	489	488	490	5.35	10.918	10.83	10.83	10.852	10.896	10.941	10.963	10.918	10.8935	0.002583	0.050822	0.466533415
75	S04 K2384 088	477	472	473	476	476	475	473	474	6.096	12.78	12.915	12.888	12.807	12.807	12.834	12.888	12.861	12.8475	0.002291	0.047866	0.372569637
76	S07 K2383 073	435	431	434	435	439	431	432	427	5.248	12.064	12.176	12.092	12.064	11.954	12.176	12.148	12.29	12.1205	0.010081	0.100403	0.828377309
77	S08 K2383 074	254	252	253	252	253	251	252	252	2.852	11.228	11.317	11.273	11.317	11.273	11.363	11.317	11.317	11.30063	0.001681	0.040995	0.362763612
78	R04 K2384 081	908	905	906	893	894	911	908	920	7.432	8.185	8.212	8.203	8.323	8.313	8.158	8.185	8.078	8.207125	0.006392	0.079949	0.974141118
79	R07 K2383 064	771	766	765	753	752	756	775	756	6.788	8.804	8.862	8.873	9.015	9.027	8.979	8.759	8.979	8.91225	0.010272	0.101352	1.137220487
80	R07 K2383 065	744	746	741	743	750	748	735	742	7.633	10.259	10.232	10.301	10.273	10.177	10.205	10.385	10.287	10.26488	0.004102	0.064046	0.623929694
81	R10 K2383 071	710	708	716	707	707	699	712	713	7.764	10.935	10.966	10.844	10.982	10.982	11.107	10.904	10.889	10.95113	0.00632	0.079499	0.725945634
82	R12 K2386 015	942	932	941	936	934	951	934	929	8.995	9.549	9.651	9.559	9.61	9.631	9.458	9.631	9.682	9.596375	0.005098	0.071402	0.744053414
83	R14 K2386 019	979	983	973	975	975	971	988	981	10.925	11.159	11.114	11.228	11.205	11.205	11.251	11.058	11.137	11.16963	0.004181	0.064657	0.578866349
84	R14 K2386 020	868	859	857	875	873	876	863	866	9.321	10.738	10.851	10.876	10.653	10.677	10.64	10.801	10.763	10.74988	0.007976	0.089306	0.830762728

85	R19 K23B8 039	944	938	921	927	932	934	947	937	10.544	11.169	11.241	11.448	11.374	11.313	11.289	11.134	11.253	11.27763	0.010582	0.102867	0.912136846
86	R26 K23B1 120	978	993	986	968	974	968	958	968	11.918	12.186	12.002	12.087	12.312	12.236	12.312	12.441	12.312	12.236	0.01983	0.140819	1.150858392
87	S03 K23B4 084	978	983	994	994	996	984	988	990	10.76	11.002	10.946	10.825	10.825	10.803	10.935	10.891	10.869	10.887	0.004871	0.069789	0.64103499
88	S04 K23B4 089	848	870	867	859	861	857	864	862	10.892	12.844	12.52	12.563	12.68	12.65	12.709	12.606	12.636	12.651	0.009801	0.099002	0.782563943
89	S07 K23B3 074	755	758	765	760	773	772	775	763	8.188	10.845	10.802	10.703	10.774	10.592	10.606	10.565	10.731	10.70225	0.010937	0.10458	0.977181941
90	S08 K23B3 075	884	893	890	888	897	888	872	903	11.428	12.928	12.797	12.84	12.869	12.74	12.869	13.106	12.656	12.85063	0.017855	0.133622	1.039809359
91	R04 K23B4 082	951	958	956	953	954	961	966	956	10.147	10.67	10.592	10.614	10.647	10.636	10.559	10.504	10.614	10.6045	0.002799	0.05291	0.498935607
92	R07 K23B3 066	880	870	876	863	886	872	862	884	8.744	9.936	10.051	9.982	10.132	9.869	10.028	10.144	9.891	10.00413	0.010696	0.103421	1.033780474
93	R07 K23B3 067	725	720	731	735	730	735	731	732	8.151	11.243	11.321	11.15	11.09	11.166	11.09	11.15	11.135	11.16813	0.006135	0.078324	0.701320078
94	R10 K23B3 072	875	858	870	879	874	862	867	877	11.664	13.33	13.594	13.407	13.27	13.346	13.531	13.453	13.3	13.40388	0.013179	0.114799	0.856457581
95	R12 K23B6 016	904	897	901	882	880	885	892	886	8.92	9.867	9.944	9.9	10.113	10.136	10.079	10	10.068	10.01338	0.010218	0.101083	1.009476044
96	R14 K23B6 021	875	906	891	898	901	902	914	882	10.121	11.567	11.171	11.359	11.271	11.233	11.221	11.073	11.475	11.29625	0.026432	0.162579	1.43922976
97	R14 K23B6 022	992	986	984	986	981	986	975	979	11.223	11.314	11.382	11.405	11.382	11.44	11.382	11.511	11.464	11.41	0.003659	0.060486	0.530115039
98	R19 K23B8 040	796	797	791	792	803	798	799	806	10.677	13.413	13.396	13.498	13.481	13.296	13.38	13.363	13.247	13.38425	0.007194	0.084819	0.633720337
99	R26 K23B1 121	839	831	836	827	843	834	846	840	7.759	9.248	9.337	9.281	9.382	9.204	9.303	9.171	9.237	9.270375	0.004853	0.069664	0.751473095
100	S03 K23B4 085	790	783	774	775	779	777	796	793	7.356	9.311	9.395	9.504	9.492	9.443	9.467	9.241	9.276	9.391125	0.010513	0.102533	1.091805662

3. melléklet: A növekvő magmennyiségből gépi látással detektált értékek adatsora

Sorszám	Számolt érték	Becsült érték	Eltérés
1	200	199	0.5
2	200	198	1
3	200	200	0
4	200	200	0
5	200	200	0
6	200	200	0
7	200	200	0
8	200	200	0
9	200	200	0
10	200	200	0
11	200	200	0
12	200	201	0.5
13	200	197	1.5
14	200	200	0
15	200	203	1.5
16	200	200	0
17	200	200	0
18	200	201	0.5
19	200	200	0
20	200	203	1.5
21	200	200	0
22	200	200	0
23	200	200	0
24	200	200	0
25	200	200	0
26	300	298	0.666667
27	300	301	0.333333
28	300	281	6.333333
29	300	299	0.333333
30	300	290	3.333333
31	300	300	0
32	300	293	2.333333
33	300	295	1.666667
34	300	299	0.333333
35	300	300	0
36	300	297	1
37	300	299	0.333333
38	300	304	1.333333
39	300	302	0.666667
40	300	300	0
41	300	298	0.666667

42	300	302	0.666667
43	300	297	1
44	300	299	0.333333
45	300	300	0
46	300	298	0.666667
47	300	299	0.333333
48	300	299	0.333333
49	300	300	0
50	300	298	0.666667
51	400	390	2.5
52	400	388	3
53	400	389	2.75
54	400	377	5.75
55	400	383	4.25
56	400	393	1.75
57	400	395	1.25
58	400	374	6.5
59	400	390	2.5
60	400	397	0.75
61	400	402	0.5
62	400	400	0
63	400	395	1.25
64	400	399	0.25
65	400	395	1.25
66	400	392	2
67	400	393	1.75
68	400	374	6.5
69	400	397	0.75
70	400	394	1.5
71	400	392	2
72	400	395	1.25
73	400	386	3.5
74	400	397	0.75
75	400	392	2
76	500	486	2.8
77	500	476	4.8
78	500	479	4.2
79	500	495	1
80	500	494	1.2
81	500	497	0.6
82	500	479	4.2
83	500	474	5.2
84	500	493	1.4
85	500	486	2.8
86	500	471	5.8
87	500	471	5.8

88	500	484	3.2
89	500	480	4
90	500	490	2
91	500	491	1.8
92	500	477	4.6
93	500	458	8.4
94	500	485	3
95	500	500	0
96	500	476	4.8
97	500	471	5.8
98	500	483	3.4
99	500	484	3.2
100	500	491	1.8
101	1000	935	6.5
102	1000	1000	0
103	1000	959	4.1
104	1000	930	7
105	1000	953	4.7
106	1000	999	0.1
107	1000	969	3.1
108	1000	948	5.2
109	1000	936	6.4
110	1000	974	2.6
111	1000	990	1
112	1000	978	2.2
113	1000	969	3.1
114	1000	965	3.5
115	1000	963	3.7
116	1000	962	3.8
117	1000	925	7.5
118	1000	1000	0
119	1000	957	4.3
120	1000	987	1.3
121	1000	969	3.1
122	1000	976	2.4
123	1000	960	4
124	1000	937	6.3
125	1000	948	5.2

10. NYILATKOZAT

NYILATKOZAT

a szakdolgozatnyilvános hozzáféréséről és eredetiségéről

A hallgató neve: Seiwerth Anna
A Hallgató Neptun kódja: KTLDEK
A dolgozat címe: **Kender (Cannabis sativa L.) nemesítésben felhasznált vetőmagok gépi detektálási folyamatának validálása**
A megjelenés éve: 2024
A konzulens intézetének neve: Növénytermesztési-tudományok Intézet
A konzulens tanszékének a neve: Agronómia Tanszék

Kijelentem, hogy az általam benyújtott szakdolgozat egyéni, eredeti jellegű, saját szellemi alkotásom. Azon részeket, melyeket más szerzők munkájából vettem át, egyértelműen megjelöltem, és az irodalomjegyzékben szerepeltettem.

Ha a fenti nyilatkozattal valótlan állítottam, tudomásul veszem, hogy a záróvizsga-bizottság a záróvizsgából kizár és a záróvizsgát csak új dolgozat készítése után tehetek.

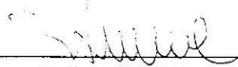
A leadott dolgozat, mely PDF dokumentum, szerkesztését nem, megtekintését és nyomtatását engedélyezem.

Tudomásul veszem, hogy az általam készített dolgozatra, mint szellemi alkotás felhasználására, hasznosítására a Magyar Agrár- és Élettudományi Egyetem mindenkori szellemi tulajdon-kezelési szabályzatában megfogalmazottak érvényesek.

Tudomásul veszem, hogy dolgozatom elektronikus változata feltöltésre kerül a Magyar Agrár- és Élettudományi Egyetem könyvtári repozitori rendszerébe. Tudomásul veszem, hogy a megvédett és

- nem titkosított dolgozat a védést követően
- titkosításra engedélyezett dolgozat a benyújtásától számított 5 év eltelte után nyilvánosan elérhető és kereshető lesz az Egyetem könyvtári repozitori rendszerében.

Kelt: Mosonmagyaróvár, 2024. 04. 15.


Hallgató aláírása

NYILATKOZAT

Seiwerth Anna hallgató Neptun azonosítója: KTLDEK konzulenseként nyilatkozom arról, hogy a szakdolgozatot¹ áttekintettem, a hallgatót az irodalmi források korrekt kezelésének követelményeiről, jogi és etikai szabályairól tájékoztattam.

A szakdolgozatot a záróvizsgán történő védeésre javaslom / nem javaslom².

A dolgozat állam- vagy szolgálati titkot tartalmaz: igen nem^{*3}

Kelt: 2024. 04. 15.


belső konzulens

¹ A megfelelő dolgozattípus meghagyása mellett a többi típus törlendő.

² A megfelelő aláhúzendó.

³ A megfelelő aláhúzendó.