

SZAKDOLGOZAT

Göndöcz Zoltán

Göndöcz Zoltán

2023

MAGYAR AGRÁR- ÉS ÉLETTUDOMÁNYI EGYETEM

KERTÉSZETTUDOMÁNYI INTÉZET

BUDAPEST

Mesterséges Intelligencia modellek alkalmazási lehetőségei a gyógynövény ágazatban

Göndöcz Zoltán

Gyógynövényismerő és -felhasználó szakirányú továbbképzés

Készült a Gyógy- és Aromanövények Tanszéken

Tanszéki konzulens: Dr. Radácsi Péter

Konzulens(ek): \_\_\_\_\_

Bírálok: \_\_\_\_\_

Budapest, 2023. október 26.

\_\_\_\_\_  
tanszékvezető/szakirányfelelős

\_\_\_\_\_  
konzulens

# 1. Tartalomjegyzék

2.	Felhasznált rövidítések .....	4
3.	Bevezetés .....	5
4.	A szakdolgozat célja .....	7
5.	Irodalmi áttekintés.....	8
5.1.	Mesterséges intelligencia és gépi tanulás alapjai .....	8
5.2.	Előrejelzési modellek .....	9
5.3.	Anomáliadetektálás.....	12
5.4.	Dokumentumfeldolgozás .....	13
5.5.	Természetes és mesterséges nyelvfeldolgozás .....	14
5.6.	Szakértői rendszerek .....	20
5.7.	Számítógépes látás .....	21
5.8.	Modellek tervezésének alapvető szempontjai.....	23
6.	Anyag és módszer .....	25
6.1.	Kísérlet: illóolajtartó mirigyszőrök számlálása.....	25
6.2.	Technikai háttér .....	25
6.3.	Adatforrás .....	25
6.4.	Modell betanítása.....	26
7.	Eredmények és értékelésük.....	28
7.1.	I. számú kísérlet.....	28
7.2.	II. számú kísérlet.....	28
7.3.	III. számú kísérlet.....	28
8.	Konklúzió .....	30
9.	Hivatkozások .....	31
10.	Melléklet I. – ChatGPT beszélgetés a gyógyteákról .....	33
11.	Melléklet II. – részletes mérési eredmények .....	35
12.	Melléklet III. – Nyilatkozatok .....	37

## 2. Felhasznált rövidítések

AI	Artificial Intelligence
GMP	Good Manufacturing Practice
GPT	Generative Pre-trained Transformer (megj.: a ChatGPT nem rövidítés, hanem a termék neve)
IFTTT	If this... then that... - hagyományos „ha, akkor” döntési logika
IKT	Információs és Kommunikációs Technológiák
IoT	Internet of Things - Internetre kötött egyszerű eszközök (pl. szenzorok)
LCNC	programozást nem igénylő fejlesztői rendszerek, angolul low-code & no-code
MI	Mesterséges Intelligencia
MIT	Massachusetts Institute of Technology
ML	Machine Learning
NLP	natural language processing - természetes-nyelv feldolgozás
OMSZ	Országos Meteorológiai Szolgálat
PdM	predictive maintenance - karbantartási előrejelzés
RGB	Red-Green-Blue színkeverék definiálása informatikában

### 3. Bevezetés

A Mesterséges Intelligencia (MI) és a gépi tanulás (machine learning – ML) közel egy időben a Neumann-elvű számítógépekkel. Kezdetben ugyan nem állt rendelkezésre a szükséges számítási kapacitás, de az alapelveket és algoritmusokat már a számítástechnikai korai szakaszában kidolgozták. A technológia folyamatos fejlődésének köszönhetően az elmúlt években az AI és MI modellek egyre elterjedtebbek lettek a legtöbb iparágban, az elmúlt egy-két évben divatos téma, marketinges hírverés lett körülötte. Ugyan attól még több évtizedre vagyunk, hogy komplex utasításokat lehessen adni egy gépnek, a technológia jól használható olyan esetekben, amikor nagy mennyiségű adatot kell feldolgozni, gyorsan szükséges az információ feldolgozása, és regurális programkódok, logikák, algoritmusok (pl. IFTTT) nem használhatók. Célszerű ügyelni azonban arra, hogy csak valóban indokolt esetben használjunk AI modelleket, hiszen ezek tervezése, fejlesztése, bevezetése, üzemeltetése meglehetősen költségigényes. Például felesleges egy gépi látás (computer vision) megoldást építeni az éretlen borókaszemek kiválogatására, amikor arra már elérhető optikai válogatógépek.

Az utóbbi években teret nyert, mély programozói és adatelemzői (data scientist) ismereteket nem igénylő, a gyakorlatban is alkalmazható, úgynevezett kódolás nélküli (low-code és no-code - LCNC) megoldások lehetővé tették MI megoldások gyors bevezetését, használatát. Természetesen ezek az általános célú modellek nem helyettesítik 100%-ban azokat a modelleket, melyeket egy adott célfeladatra, például egy gyógyszeripari kutatásra fejlesztettek. Ezek az egyedi, alapos kutatást, tervezést, kódolást igénylő projektek meglehetősen magas költségűek.



1. ábra – LaseWeeder gyomirtó robot (Carbon Robotics, 2023)

Az AI használata egyre inkább elterjed a talajművelés, termesztés és a gyomirtás gépesítése során is. Az új generációs eszközök gyártói már alkalmaznak különböző modelleket gépeikben. Leggyakrabban az önvezető

gépek esetén láthatók, de vannak igen innovatív megoldások más területeken is. Például a Carbon Robotics (2023) kínálatában elérhető LaserWeeder autonóm robot, melynek kamerarendszere több száz gyomnövényt ismer fel gépi látás modell segítségével és égeti azokat ki egy 150 wattos lézernyaláb segítségével (1. ábra). A Lemken Group (2023) ezzel szemben egy másik taktikát választott: IC-Weeder AI adapter a haszonnövényt ismeri fel, és minden mást kiírt mechanikai úton (2. ábra).



2. ábra – IC-Weeder-AI gyomirtó adapter (Lemken Group, 2023)

#### 4. A szakdolgozat célja

A dolgozat célja felmérni, és röviden bemutatni a gyógynövény ágazatban már alkalmazott, és a jövőben alkalmazható Mesterséges Intelligencia (MI) és gépi tanulási (machine learning – ML) modelleket. A dolgozat bemutatja tovább a más iparágakban már alkalmazott modelleket, valamint felméri a gyűjtés, termesztés, feldolgozás, forgalmazás és kutatások során gyakorlatban már alkalmazható ML modellek lehetőségeit, előnyeit hátrányait. A cél, annak a hipotézisnek az igazolása, miszerint MI technológiák használatának a gyógynövény ágazatban is van relevanciája és jövője. A dolgozat második része egy kísérlet bemutatása, miszerint LCNC platformon kódolás nélkül építhető objektumészlelési gépi látás modell segítségével felgyorsítható illóolajmirigyek számlálása.

A dolgozat készítése során a kódolás nélkül használható platformok kapnak kiemelt szerepet, mivel ezek használatához, testre szabásához nincs szükség informatikai és adattudós ismeretekre.

## 5. Irodalmi áttekintés

### 5.1. Mesterséges intelligencia és gépi tanulás alapjai

Általános értelemben a mesterséges intelligencia (MI, AI) az emberi viselkedést és képességeket imitáló szoftveres megoldás. Alapja a gépi tanulás (angolul machine learning - ML), mely tulajdonképpen egy tanítási folyamat, melynek során a gépet megtanítjuk adatokból előrejelzéseket készíteni, következtetéseket levonni. Az így elkészített modellek képesek automatikusan hibákat észlelni és rendellenes működést jelezni különböző rendszerek esetén – ez a terület az **anomália detektálás**. Más modellek képesek megtanulni a képeken, fotókon szereplő objektumokat felismerni – legyen szó tárgyról, vagy egy úrlap címkéinek és az azokhoz tartozó adatok felismeréséről, feldolgozásáról – ezek az ún. **számítógépes látástechnológia** (angolul computer vision) modellek. A **természetes nyelvi feldolgozás** (angolul natural language processing – NLP) a gépi tanulás azon területe, amely az írott és beszélt nyelvet megértő modellek létrehozásával foglalkozik. Ilyen például a gépi fordítás, élő beszéd megértése és leírása, kulcsszavak kiemelése, valamint a szöveg megértése és válasz szintetizálása. A **tudásbányászatra** optimalizált modellek nagy mennyiségű, sokszor nem strukturált (ömlesztett) adatból nyernek ki információkat. Ilyenek lehetnek többek között a karbantartási igényt előre jelző (angolul predictive maintenance) modellek.

A fenti gépi tanulási területek közös jellemzője, hogy mindegyik esetben szükség van egy tanulási és tesztelési folyamatra. Ennek során minta adatok segítségével megtanítjuk a gépnek a különböző kategóriákat az anomáliák felderítéséhez, a felismerendő objektumokat a képeken stb. Azaz az általunk megfelelően előkészített adatot a gép felhasználja, hogy mintákat, ismétlődéseket, eltéréseket keressen, azaz összefüggéseket tárjon fel a bemeneti adat és az előzetesen meghatározott célértékek között. Tehát a ML modell elkészítéséhez szükséges adathalmaz magában foglalja a minta kimeneti adatokat és az ezzel összefüggésben levő, a kimeneti értékeket befolyásoló bemeneti adatokat is. Abban az esetben, ha adatok hiányosak, vagy egyáltalán nem állnak rendelkezésre – például nem rögzítették a korábbi évek tápanyag pótlását, csapadékmennyiséget, stb – úgy gépi tanulási modellt egyáltalán nem lehet készíteni. A tanítási folyamathoz elengedhetetlen a megfelelően előkészített, címkézett, strukturált adathalmaz. Például, ha egy gyógynövények felismerésére képes mobil appot szeretnénk készíteni, a tanítási folyamat a következő lépésekből áll:

- **Adatgyűjtés:** fotók készítése különböző fenológiai fázisokban. A jól működő modellhez fajonként és fázisonként 40-50 kép az ideális, különböző hátterekkel, különböző fényviszonyokkal, különböző szögekben fényképezve.
- **Tagging:** Minta fotók felcímkézése, azaz képenként megjelölve a növényt, vagy a növényi részeket
- **Betanítás:** A címkézett adatok feldolgozása, mely során a gép kapcsolatokat keres a minták jellemzői és a címkézett fajok között és azt egy modellbe ágyazza, azaz betanítja.
- **Rendszerintegráció:** Ezután a modell használható szoftveres alkalmazásokban, és képes lesz arra, hogy egy új fotón képes lesz azonosítani a korábban címkézett fajokat – pontosabban megadja annak valószínűségét, hogy egy fotón szerepel-e az általa már megtanult faj vagy annak egy része.



Fontos kiemelni, hogy a ML modellek az általunk biztosított adatból tudnak dolgozni, összefüggéseket feltárni, mintákat keresni. Abban az esetben, ha a tréning adat hibás, hiányos, úgy a modellezett folyamat sem fog megfelelően működni. Előfordulhat olyan eset is, amikor a modell egy-egy extrém szituációra nincs felkészítve, így meglepő lesz a kimeneti eredmény. Például, ha egy termés hozam előre jelző modellt készítünk, és a tanítási folyamat során megadjuk az elmúlt 10-15-30 év adatait – például csapadék mennyisége, napsütéses órák száma, tápanyag, tápanyag-pótlás, stb – a modell várhatóan jó becslést fog adni. De előfordulhat ilyenkor is olyan szituáció, hogy a 2022-es évben jól működik a modell, de a rákövetkező évben pontatlan lesz. Hiába volt a 2023-as év csapadék szempontjából optimális, az előző évi aszály a talaj vízmegtartó képességét olyan mértékben változtatta, melyre a modell nem volt felkészítve, adott esetben a humán intelligencia sem számolt vele: „*az alacsonyabb termésátlagok mögött az is ott lehet, hogy a tavalyi hatalmas aszály után a talajok vízháztartása nem tudott teljesen helyreállni*”. (Csősz, 2023).

## 5.2. Előrejelzési modellek

Az előrejelzési modellek a tanulási fázisban megadott alapján mintákat definiálnak, és ezeket a mintákat társítják a lehetséges kimenetekhez. A modell publikálása után ezeket a mintákat keresi az új adatokon, és ezek alapján készít előrejelzést. A modellek az alábbi módok szerint adhat előrejelzést:

- **bináris előrejelzést** igaz/hamis kimenettel – például a mai napon szükséges-e öntözni?
- **több kimeneteles** előrejelzést, amikor több lehetséges kimenet van – például a betakarítást a megszokottól korábban, megszokott időben, később, vagy sokkal később szükséges megkezdeni
- **numerikus előrejelzés**, amikor egy kérdést számmal tudunk megválaszolni. Ez a szám lehet egész szám, decimális szám, vagy akár pénznem is. Például a szárítóüzemben beállítandó hőmérsékleti érték, figyelembe véve szárítandó gyógynövény fajtát, mennyiségét, külső és belső időjárási adatokat stb.

Az előrejelzési modelleket a szakirodalom kategorizálásnak (angolul: classification vagy category classification) is nevezi. Például a bináris előrejelzés valójában két osztályt jelent, igaz és hamis, a modell e két osztály valamelyikébe sorolja az adott eseményt. Egy speciális típus a több eredményes osztályozás, amikor egy több kimeneteles előrejelzést a gép nem egy, hanem 2-3 lehetőséggel ad meg, különböző súllyal jelölve azokat.

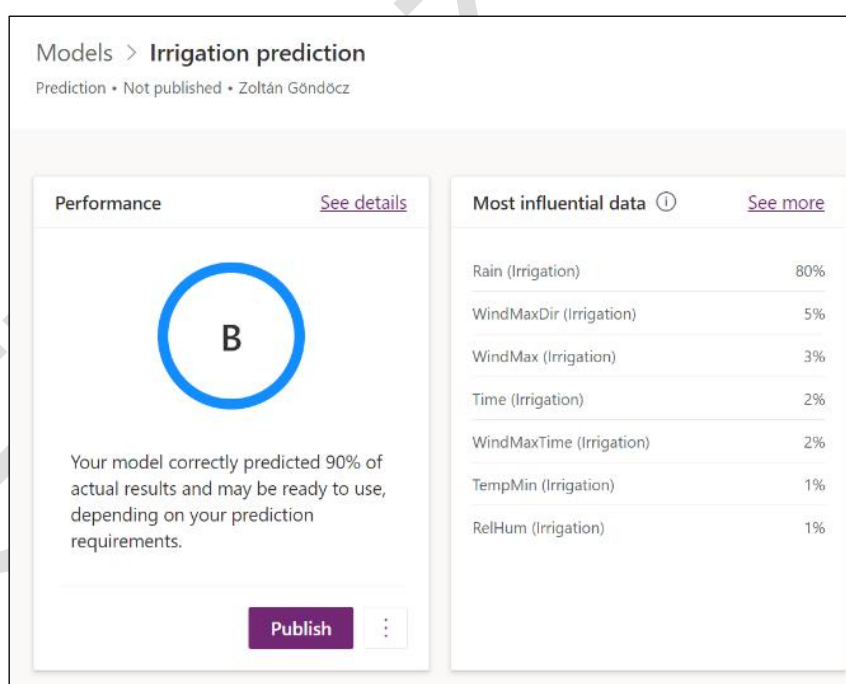
A megfelelően működő előrejelzési modell elkészítéséhez definiálni kell azon paramétereket, melyek a kimenetel szempontjából relevánsak. Például, ha hozambecslést szeretnénk végezni, úgy a betanítás során meg kell adnunk azokat az ismérveket, melyektől a várható hozam függ. Például: tápanyag, tápanyagpótlás, csapadék, napsütéses órák száma stb. A betanítás ez alapján történik, majd ennek végeztével következik a modell kiértékelése. Ehhez a gép a megadott adatok egy részét, ún. teszt adatkészletet használ a modell megbízhatóságának és illeszkedésének megállapításához. Amennyiben a betanítási adatok kellően diverzifikáltak, úgy a modell megbízhatóbb lesz. Sok esetben előfordul, hogy a betanítási adatok kimenetei egyenletesen oszlanak el, ilyen esetekben a modell alulillesztett lesz, azaz az általa adott eredmény nem tér el jelentősen a véletlentől. A másik véglet, amikor a betanítási kimenetek egy irányba mutatnak, ilyenkor a modell túlillesztett lesz. Ez leginkább akkor fordul elő, ha a betanítási adatokban valamely ismérv közvetlenül korrelál az eredménnyel.

A betanítási adatok helyes megválasztása mellett kritikus a megfelelő mennyiségű adat megadása. LCNC rendszereknél a minimum követelmény általában 50 adatsor, de optimális esetben legalább 800-1000 rekordot szükséges megadni, valóság-hű kimenet-eloszlással. E követelmény például jelentősen megnehezíti éves előrejelzések (pl. termés hozam stb.) készítését, mivel ezek nem állnak rendelkezésre. A későbbi használathoz érdemes mielőbb megkezdeni minden adat pontos regisztrálását és megoldani hosszú távú tárolásukat.

### 5.2.1. Öntözési igény előrejelzése

Öntözés szükségességének előrejelzésére, vízigény becslésére AI és ML segítségével több tanulmány is rendelkezésre áll. Például Gao et al., (2023) tanulmányukban több ML algoritmus és adatforrás használatát tanulmányozták és jutottak arra, hogy 20-22% víz és energia spórolható hatékony ML modellek definiálásakor – összehasonlítva a hagyományos, kötött ütemezésű öntözési eljárásokkal. Kritikus szempont az betanítási adat minősége és mennyisége is, de kevés adat esetén is fejlesztettek elfogadható teljesítménnyel működő deep learning algoritmusokat, jobbra a tápanyagutánpótlás területén (Dhal et al., 2022).

A probléma jellegéből adódóan azonban egy elkészített modell nem feltétlenül propagálható, használható általános célú megoldásként. Például az eltérő regionális és mikroklíma sajátosságok nem feltétlenül teszik lehetővé egy más földrajzi régió adatai alapján készített modell adaptálását. Ilyenkor hatékonyabb lehet egy LCNC megoldás használata az egyedi kódolás helyett, annak ellenére, hogy nem teszik lehetővé a modell finomhangolását. De megfelelő minőségű forrásadat használatával megbízható megoldások építhetők.



3. ábra – Fiktív öntözés-előrejelzési modell teljesítményindexe (Göndöcz, 2023)

Az 3. ábra egy Microsoft AI Builder segítségével épített Machine Learning előrejelzési modell megbízhatóságát mutatja be. A forrásadat valós OMSZ Adattárház (OMSZ, 2021) időjárási adatok (csapadékmennyiség, napi hőmérséklet, széljárás, páratartalom) alapján készült, kiegészítve fiktív öntözési információval, melyet a 4. ábra mutat be. Egyszerű logikája: amennyiben előző két napban legalább 10 mm eső

esett, az öntözőrendszer nem kapcsol be a képzeletbeli területen. Tehát a példában egy bináris előrejelzés készül. Üzemi körülmények között célszerűbb lenne numerikus értéket adni annak függvényében, hogy mennyi öntözésre van szükség. Természetesen ez abban az esetben lehetséges, ha a betanítás során rendelkezése állnak további részletes öntözési adatok – például annak időtartama, felhasznált víz mennyisége, napi párolgás, stb.

1	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	Time	Rain	TempAvg	TempMin	TempMax	RelHum	WindSp	WindDir	WindMax	WindMaxDir	WindMaxTime	WindAvg	Evapor	Irrigation
2	2023.01.01	0,0	8,9	6,6	13,6	88,0	1,9	D	7,4	205	599,00	1,9	1,1	True
3	2023.01.02	0,0	6,6	2,0	12,8	96,0	1,6	DDK	5,1	163	609,00	1,6	0,5	True
4	2023.01.03	1,5	4,8	3,1	6,3	100,0	0,9	DDK	4,2	142	640,00	1	0,1	True
5	2023.01.04	0,7	5,6	2,4	10,0	95,0	1,6	DDNy	8,1	218	1301,00	1,6	0,6	True
6	2023.01.05	0,1	6,3	4,6	8,4	93,0	5,2	DDNy	16,2	220	828,00	5,2	0,6	True
7	2023.01.06	0,0	4,5	0,3	8,8	86,0	1,7	DDK	7,8	255	12,00	1,8	1	True
8	2023.01.07	0,0	5,3	2,7	8,1	93,0	1,6	K	6,2	163	199,00	1,6	0,6	True
9	2023.01.08	0,0	5,1	0,5	8,4	90,0	2,4	D	9	148	1332,00	2,4	0,9	True
10	2023.01.09	8,0	8,2	7,0	10,1	79,0	2,1	D	8,6	168	574,00	2,2	0,5	False
11	2023.01.10	5,4	6,4	5,4	8,0	95,0	4,1	K	14,7	11	1325,00	4	0,5	False
12	2023.01.11	0,0	5,8	4,1	10,4	90,0	4,3	ÉÉK	13,5	28	2,00	4,4	0,8	True

4. ábra – Fiktív öntözési adatok generálása Excelben (Göndöcz, 2023)

Érdemes megfigyelni, hogy a legnagyobb súllyal (80%) az előző két napi esőt vette figyelembe a rendszer, míg a hőmérséklet és a relatív páratartalom napi átlaga lényegesen kisebb, 1% mértékben. Az adathalmaz része volt a potenciális párolgás napi összege is, mely mm-ben volt megadva, ezt a rendszer teljes mértékben ignorálta – abból adódóan, hogy túlnyomóan 0,1-0,2 mm közötti értékek szerepeltek. 2% súllyal az adott napi dátum is befolyással volt a modellre, azonban ez akár felhasználói hiba is lehet. Amennyiben úgy ítéljük meg, hogy nem releváns, ezt az oszlopot ki kell kapcsolni a betanítás során.

Ez a demonstrációs céllal készített modell vélhetően megbízhatóan működne azokban az esetekben, amikor kevés tapasztalattal is döntést lehet hozni az öntözés szükségességéről. Közel áll egy IFTTT algoritmushoz – *ha az elmúlt két napon esett, akkor nem öntözünk* – bár annál kicsit fejlettebb, a döntéshez néhány más szempontot is figyelembe vesz. Üzemi körülmények között a modell definiálásához érdemes további adatokat figyelembe venni – például talajhőmérséklet, légnyomás, talajnedvesség stb, kiegészítve az előrejelzés adataival összevetett valós csapadékmennyiséget. Pontosabb előrejelzéshez a regionális OMSZ adatok helyett érdemesebb saját mérésekre támaszkodni. Ezek gyűjtése jól automatizálható IoT eszközökkel, szenzorokkal, melyek megléte az első feltétel egy ML modell építéséhez, így érdemes mielőbb megkezdeni.

### 5.2.2. Gépek, gyártósorok meghibásodásának, szervizigényének előrejelzése

Az előrejelzési modellek egyik speciális fajtája az úgynevezett karbantartási előrejelzés (angolul predictive maintenance - PdM). Eszközök, gépek, infrastruktúra elemek működés közbeni állapotáról – például motor fordulatszáma, sebesség, olajsint, fogyasztás, szelephézag stb. – gyűjtünk adatokat. Ezeket kiegészítve a meghibásodási adatokkal tanítjuk be a modellt, hogy előre jelezze a lehetséges meghibásodást, karbantartás szükségességét. Nem kizárólagosan gépek, műszaki cikkek esetén alkalmazhatók, például egy autópálya

kopórétegének cseréje, vagy az útjelek újra festésének szükségessége is előre jelezhető az időjárás, forgalmi terhelés stb. függvényében.

Termesztés és feldolgozás során használt munkagépek karbantartása jellemzően ütemezetten, adott üzemóra elérése után történik. Holott különböző műveletek, különböző körülmények más-más mértékben veszik igénybe az erőgépeket, üzemi gépeket. Például egy aprítógépet ugyanannyi üzemóra alatt jelentősebb mértékben erodál az *Altheae radix* aprítása, mint a citromfű herbájának másodlagos feldolgozása. Iparági gyakorlat, hogy a karbantartást a gyártó szakemberei végzik, erre sem kis-, sem nagyüzemi körülmények között nincs helyi szakértelem. Ebből is adódik, hogy sem a gyártó, sem az üzemeltető szempontjából nem szerencsés a szükségesnél gyakoribb karbantartási szünet. Egy váratlan leállás miatt szünetel a feldolgozás, és a szervizcsapat munkája is hatékonyabb, ha csak előre ütemezhető munkái vannak, nem szükséges a váratlan hibából adódó átütemezés. Kisebb értékű eszközök esetén jól működő üzleti stratégia, miszerint kettesével szereznek be talajművelő eszközöket, megoldva ezzel a redundanciát és az alkatrészellátást. Természetesen ez nagyobb értékű beruházásoknál nem járható út.

Hasonlóan a más célra használt előrejelzési modelleknél, itt is szükség van betanítási adatokra. Ezeket jellemzően az eszköz diagnosztikai adatainak rögzítésével, szenzorok által gyűjtött információk tárolásával érhetjük el. A megbízható működéshez több berendezés adataira és karbantartási naplójára van szükség. Ebből adódóan a felhasználó oldali modellezés a gyakorlatban kizárható, azonban gyártók jellemzően már elmozdultak ebbe az irányba. Például a CLAAS (2023) 5 évig díjmentesen biztosítja a *Remote Service* szolgáltatásához való hozzáférést, így gyűjtve felhasználói adatokat az általuk gyártott gépekről: *„A gép megmondja, hogy mire van szüksége, a szervizpartner pedig azonnal reagál. Az intelligens hálózatba kötött CLAAS gépek automatikusan tájékoztatják a szervizpartnert, aki a konkrét adatokhoz közvetlenül hozzáférve azonnal reagálni tud. ... A gép tájékoztatja a szervizpartnert egy soron következő karbantartás követelményeivel kapcsolatban, így azt késedelmek nélkül el lehet végezni. ... Most díjmentesen kipróbálható 5 évig - a CLAAS fedezi a költségeket. Mindössze egy beleegyezésre van szükség”*

### 5.3. Anomáliadetektálás

Az anomáliadetektálásra betanított modellek célja ritka események, megfigyelések feltárása. Általában gyanús viselkedés jelzésére, a vártól statisztikailag eltérő események felderítésére használják. Több évtizedes gyakorlata van a spam és phishing jellegű e-mailek, hitelkártya visszaélések megelőzése, kibertámadások kivédése, hardver infrastruktúra meghibásodásának észlelésére. Például, ha a bankkártyámat jellemzően 8-10 üzletben használom rendszeresen, akkor ettől a mintától eltér egy tranzakció egy másik földrészen. Azaz az anomáliák a várt értéken vagy értéktartományon kívül eső értékek. A detektálásuk során azokat az eseményeket azonosítjuk, melyek jelentősen eltérnek az értékelt adatok többi részétől. Paramétere a túrérték, mely a szolgáltatás definiálásakor és finomhangolásakor adható meg. Ezek a modellek jól használhatók riasztások küldésére, gyors beavatkozást, hibaelhárítást tesz lehetővé. Jellemzően olyan scenáriókban érdemes alkalmazni, ahol a nagyobb mennyiségű adatot humán intelligencia már nem tudna megfelelő sebességgel feldolgozni, vagy csak igen drágán. Az IFTTT algoritmusoktól eltérően nem csak a küszöbértékektől való direkt eltérést tudjuk figyelni, hanem azokat

az eseteket, melyek eltérnek a megszokott mintáktól. Míg egy egyszerű algoritmus jelez, ha a megadott hőmérséklet alá/fölé csökken, addig egy anomáliadetektáló modell meg tudja tanulni, hogy a hirtelen hőmérsékletváltozás is jelenthet gondot, mielőtt a küszöbértéket elérné a rendszer és a teljes fagyasztó leengedne. Ilyen felhasználási területek jellemzően az IoT szenzorokkal mérhető adatok, de bármilyen adatsorra építhető. Például:

- Raktárak, szárító- és feldolgozóüzemek környezeti adatainak, hőmérséklet, páratartalom stb.
- Meteorológiai adatok figyelése és szükség esetén beavatkozás. Például üvegházak fűtésének, szellőztetésének stb vezérlésére.
- Feldolgozó, földművelő, betakarító stb. gépek működési adatai, melyek a meghibásodás előjelzése mellett más anomáliákra is felhívhatják a figyelmet. Ilyen például, ha csökken egy filterező gép átocsátó képessége, mely nem feltétlenül meghibásodás, lehet, hogy a kezelő nem megfelelően helyezte be a filtereket, vagy nem megfelelő méretűre lett aprítva a gyógynövény.
- Más modellekből származó információ feldolgozása. Például computer vision modellek betaníthatók a sárga lapon levő kártevők megszámlálására, mely információt felhasználva egy anomáliadetektáló modell jelezni tud egy kártevőtámadást, ha hirtelen nő a számolt egyedek száma

#### 5.4. Dokumentumfeldolgozás

A dokumentumfeldolgozás során hagyományos, papír alapú űrlapokból, egységes szerkezetű iratokból nyerünk ki információkat. Ez a terület a gépi tanulás egyik legelterjedtebb használati módja, így sok tapasztalat áll rendelkezésre, aránylag kevés munkával, gyorsan lehet űrlapfeldolgozást automatizálni.

A jövőben várhatóan kissé vissza fog szorulni köszönhetően az okostelefonok széles körű elterjedésének, valamint annak, hogy a rendszertervezők egyre inkább törekednek a digitális űrlapok használatára. Ezt a Covid19 világjárvány tovább gyorsította, ma már elenyésző az Internetes szolgáltatásokat nem használó vállalkozások aránya (KSH, 2023). Bevált IKT iparági gyakorlat, hogy papír alapú űrlapok helyett törekedni kell a papírmentes irodák és üzleti folyamatok kialakítására, lehetőség szerint digitális űrlapok használatára, a papír szkennelése és manuális rögzítése helyett. Jelentős felhasználási terület továbbá a papír alapú dokumentációk digitalizálása olyan esetekben, amikor nem elegendő szkennelni a dokumentumokat, hanem az információt struktúrált formában szükséges kinyerni. Ilyenek például a papír alapú laborjegyzőkönyvek, GMP dokumentációk, melyeknek már a tárolása is jelentős raktárkapacitást vesz igénybe. A szakképzés során meglátogatott üzemek vezetői is megerősítették ezt, de ezzel párhuzamosan már digitálisan is tárolják a dokumentumok túlnyomó részét, hiszen üzleti partnereikkel online kommunikálnak.

Az űrlapfelismerő modellek betanításhoz néhány példa elegendő, utána a modell jól használható. A legtöbb platform a nyomtatott mellett a kézírással kitöltött űrlapokat is képes feldolgozni, akár magyar nyelvű szöveggel is megbirkózik. Több gyártótól is elérhető LCNC platform, ezeket összehasonlítva az egyedi fejlesztésekkel, néhány korláttal kell számolni: például nem tudnak több nyelvű űrlapokat kezelni – nyelvenkénti betanításra van szükség, az alacsonyabb licenstdíjú megoldások nem tudnak feldolgozni több oldalas űrlapokat, illetve gondot okozhat a komplex űrlapok feldolgozása – például melyek egymásba ágyazott táblákat tartalmaznak (Microsoft, 2023a).

A dokumentumfeldolgozó modellek betanítása viszonylag egyszerű, platformtól függően 5-10 úrlappal, betanítás után működésük gyors és automatikus, azonban licenceköltségük relatíve magas – 1-3 amerikai dollár oldalanként (Microsoft, 2023b) – érdemes gondosan tervezni, hogy mely űrlapok esetén gazdaságos leváltani a humán erőforrást. Jellemző felhasználási terület korábbi papír alapú űrlapok egyszerű szkennelése helyett az információ digitalizálása és az adatok relációs adatbázisokba történő mentése. Ilyenek lehetnek például korábbi laborjegyzőkönyvek, táblatörzskönyvek, permetezési naplók, bármilyen űrlap, mely az évek során egységes űrlapformátumban került rögzítésre. Ezek az adatok igen hasznosak lehetnek például előrejelzési modellekhez, de a betanításhoz ezeket a papír alapú információkat digitalizálni kell és struktúrált formában, ideális esetben relációs adatbázisban tárolni. Fontos figyelembe venni, hogy a gépnek a pontos űrlapformátum ismerete szükséges, gyakran változó űrlapszerkezet esetén elkerülhetetlen a kézi adatrögzítés. Azaz egy modell egy űrlapformátumot képes kezelni.

## 5.5. Természetes és mesterséges nyelvfeldolgozás

A természetes nyelvfeldolgozás (angolul natural language processing - NLP), a számítástechnika és a nyelvészet tudományágakat ötvöző szakterülete. Alapvetően az írott és beszélt nyelvek gépek általi megértésével, emberi szövegeket mimelő írott szövegek és beszéd mesterséges előállításával foglalkozik. Tágabb értelemben ide tartozik a természetes nyelvekre és nyelvekről történő gépi fordítás, valamint az írott és beszélt szövegek kulcsszavainak kiemelése, hangulatelemzése is.

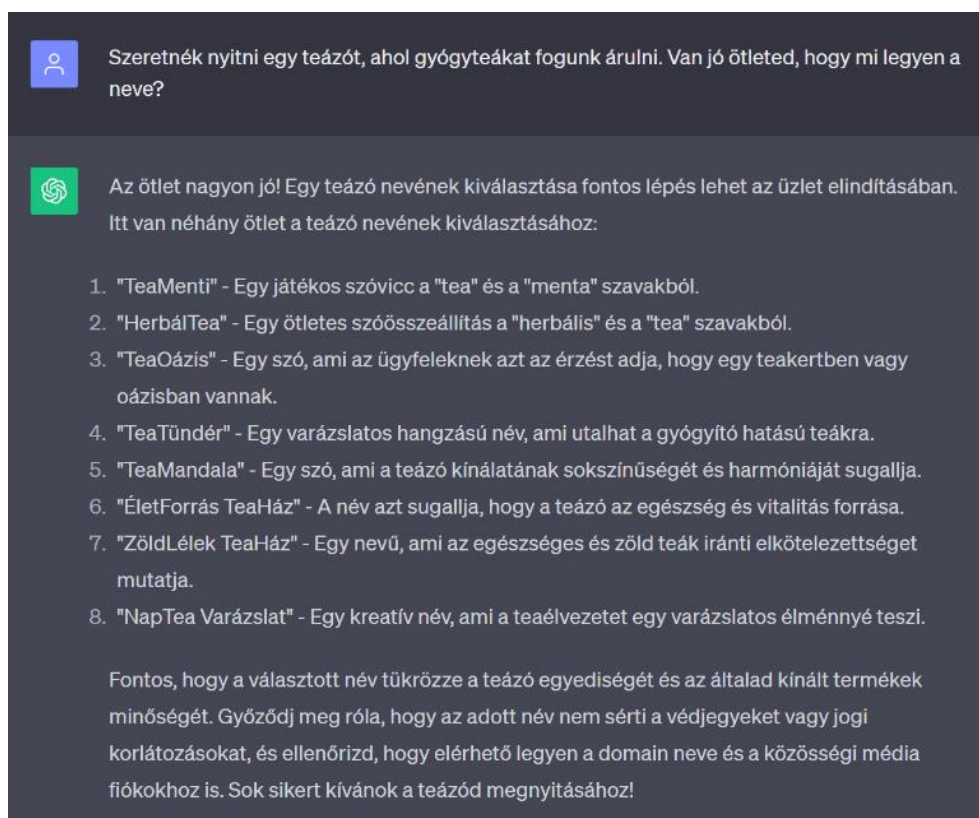
Mivel a mesterséges nyelvek esetén a modellek szinte teljesen azonosak a természetes nyelvek esetén alkalmazottakkal – például programozási nyelvek, kottairás jelrendszere, kémiai anyagok reprezentációja – ezeket a területeket a szakdolgozat egy közös fejezetben mutatja be.

Ezen modellek közös jellemzője, hogy igen nagy mennyiségű szöveges, illetve beszélt nyelvi forrás szükséges a betanításhoz, hogy az valóban a humán intelligencia által használt nyelvezetet tükrözze. Mivel a terület az utóbbi években jelentős fejlődésen ment keresztül, egyre jobb minőségű modellek érhetők el, érdemes megvizsgálni, hogy általános célú használat mellett szakmai célra milyen módon használhatók.

### 5.5.1. Generatív modellek

A generatív modellek nagy mennyiségű tanulóadatot használva szöveget, képet, zeneművet stb. generálni képesek modellek. A generatív modellek betanítása, az ahhoz szükséges nagy mennyiségű adat előszítése igen jelentős, évekig tartó munka. Ebből adódóan a felhasználók a kész modelleket használják, melyeknél a gyártók elvégezték a betanítást, és készen állnak a használatra. Azonban ki kell emelni, hogy ezek a modellek nem készítenek új tartalmat, nem állítanak elő új információt, hanem a tanulás során megismert információt felhasználva, az információmorzsákat megfelelő sorrendbe helyezve készítenek szöveget, képet stb. Például a ChatGPT 3.5 verziójának betanítása 2021. szeptemberében befejeződött, így hiába kérjünk, hogy írjon dolgozatot a 2023-as év Nobel-díjas tudósairól, arra nem lenne képes (OpenAI, 2023). Az új változata, a v4.0 frissebb információkat tartalmaz – valamint jelentős rendszerintegrációs lehetőségeket –, de ellentétben a korábbi verzióval, az nem ingyenes. De a jelenlegi ingyenes verzió is komoly „tudással” bír, meglepően pontos és kreatív szövegeket


képes generálni. A korábbi verziók, időnként megmosolyogtató hibái – például Házirend készítésekor következetesen beírta, hogy tűzokádó sárkányt tűzvédelmi okokból tartani tilos – már nem jellemzők. Sajnos azonban továbbra is hajlamosak az úgynevezett hallucinációra, amikor mindenképp válaszolni akar a felhasználónak, és fals információkat költenek. Ez természetesen fokozott óvatosságra int olyan témákban, melyeknél nincs megfelelő ismeretünk. Azonban megfelelő háttérismerettel, hasznos segítséget tudnak nyújtani. Például ötletek meríthetők egy vállalkozás beindításához, termékek, szolgáltatások kialakításához. A 5. ábra egy ChatGPT beszélgetés egy részletét emeli ki, a gép egy gyógynövény teaház nevére adott ötleteket, és felhívta a figyelmet a védjegyekre vonatkozó jogi korlátozásokra is.



5. ábra - Gyógynövény teaház névötletek (Szöveg: OpenAI ChatGPT v3.5; Prompt: Göndöcz, 2023)

Az adatbázisában levő információk alapján – melyeket publikus információk alapján építettek, nagyobb súllyal figyelembe véve a tudományos igényű oldalakat (OpenAI, 2023) – akár szaktanácsadásra is használhatók. Például, ha hurutos köhögésre kérünk gyógytea javaslatokat több monotea alternatívát is ad: gyömbér, kamilla, kakukkfű, tüdőfű, édesgyökér. A javaslatait indokolja is, például a kakukkfű esetén az antivirális, a kamilla esetén a gyulladáscsökkentő hatást is kiemeli. A javasolt lista alapvetően rendben van, bár a tüdőfű kissé kilóg a sorból. Amikor erre rákérdezzük, akkor megerősíti, hogy klinikai vizsgálatok nem állnak rendelkezésre és felhívja a figyelmet az orvosi konzultáció fontosságára (6. ábra). A teljes chat megtalálható a „Melléklet I.” fejezetben.

ZG A tüdőfű teának van klinikailag igazolt hatása?

 A tüdőfű (*Pulmonaria officinalis*) egy gyógynövény, amely hagyományosan használták légzőszervi problémák, például köhögés, asztma és tüdőproblémák kezelésére. Azonban a tüdőfű hatásairól csak korlátozott tudományos vizsgálatok és klinikai bizonyítékok állnak rendelkezésre.

Az orvosi gyakorlatban általában olyan gyógynövényeket alkalmaznak, amelyekről szélesebb körű és megbízható tudományos bizonyítékok állnak rendelkezésre. A tüdőfű esetében a klinikai kutatások hiányoznak, és nincsenek jól dokumentált bizonyítékok arra vonatkozóan, hogy valóban hatékony lenne a légzőszervi problémák kezelésében.

Ezért azt javaslom, hogy ha súlyos légzőszervi problémáid vannak, vagy hosszú ideje tartó köhögéssel küzdesz, fordulj orvoshoz. Az orvos meg tudja vizsgálni és megadhatja a megfelelő kezelést, amely a leginkább hatásos lehet az adott helyzetben.

Mint mindig, amikor gyógynövényeket vagy alternatív gyógymódokat használasz, fontos konzultálni az egészségügyi szakemberrel, mivel bizonyos esetekben a gyógynövények és az alternatív terápia nem megfelelőek vagy akár ártalmasak is lehetnek. Az orvos tudja tanácsolni a legmegfelelőbb kezelési lehetőségeket az egyedi egészségi állapotod alapján.

6. ábra - Tüdőfű tea (szöveg: OpenAI ChatGPT v3.5; prompt: Göndöcz, 2023)

Sajnos nem csak a pozitív, hanem sajnos a negatív hatásokkal is számolni kell. Mivel a modell túlnyomó részt nyilvános Internetes információkat használ, valamint a modell hajlamos a hallucinálásra, nem tudhatjuk, hogy az adott válasz mennyire megalapozott, mennyire pontos. Igaz, hogy a fejlesztők törekednek a tudományos igényességre, a felhasználók már nem biztos. Emellett sajnos számolni kell az etikátlan felhasználással is, például házi dolgozatok elkészítését, saját szellemi terméként feltüntetett dokumentumok készítésénél stb. Az ilyen visszaélések kiküszöbölésére célszerű ún. AI Detector eszközöket használni – ezek angol nyelvű szövegnél 90% feletti megbízhatósággal, magyar nyelvű esetén alacsonyabb, 60% körüli pontossággal állapítja meg, hogy AI segítségével készült a szöveg (Marjit, 2023).


Fontos továbbá figyelembe venni, hogy a szerzői jogok, személyes adatokhoz való jogok, a generált tartalom felhasználásának joga stb. jelenleg nem tisztázott (Walsh, 2023). Sajnos több modell esetén – például Dall-E, Midjourney, ChatGPT – is felmerült a gyanú, hogy szerzői jog hatálya alá eső információt használtak fel a betanítás során. Ugyan a gyártók törekednek arra, hogy ezeket kivegyék a modellekből, sajnos nem zárható ki, hogy a gép által generált tartalom szerzői jogokat sért. Továbbá figyelembe kell venni, hogy az Egyesült Államok Szerzői Jogi Irodájának döntése értelmében MI segítségével generált tartalomra nem kérhető szerzői jog (Zirpoli, 2023), tehát ha a termékem logóját azzal készítem, azt bárki lemásolhatja. Továbbá a gép nem lehet a szerzői jog tulajdonosa sem. Az Európai Unió, valamint meglepő módon korát jelentősen megelőzve Magyarország is hasonló állásponton helyezkedik el (Necz, 2018). Így jelenleg nem tisztázott, hogy a szerzői jog az eredeti, a betanításhoz használt adat, információ szerzőjét, vagy a MI modell felhasználóját, az ún. prompt megfogalmazóját illeti. Iparági gyakorlat, hogy az ingyenes termékek esetén a modell készítője fenntartja a jogot a generált tartalomra, például a Dall-E segítségével készült képek jogtulajdonosa az OpenAI (2023).



Bár elsőre bagatellnek tűnik, de a prompt helyes megfogalmazása is komoly jelentőséggel bír, egy szinonima, más szórend jelentősen befolyásolja a gép által készített szöveget, képet. A 7. ábra és a 8. ábra ugyanazon prompt segítségével generált terméklogó ötleteket mutatja be, annyi különbséggel, hogy első esetben a közönséges orbáncfű latin, míg második esetben az angol nevét használta. A Dall-E v2 esetén ugyanaz a prompt többször lefuttatva más-más képeket generál, de a jelenleg fejlesztési fázisban levő v3 változat ugyanazon képeket készíti el.



7. ábra - *Hypericum perforatum* prompt (kép: OpenAI Dall-E, 2023; prompt: Göndöcz, 2023)



8. ábra - *St John's wort* prompt (kép: OpenAI Dall-E, 2023; prompt: Göndöcz, 2023)


Végül, de nem utolsó sorban érdemes kiemelni a generatív modellek továbbfejlesztési lehetőségeit vállalati, szervezeti, egyetemi szinten. A ChatGPT v4.0 már lehetőséget biztosít arra, hogy a modell ismereteit kiterjesszük belső dokumentációkra, információkra. Például lehetőség van arra, hogy az egyetemi könyvtár elektronikus dokumentumait, a beadott szakdolgozatok, házi dolgozatok alapján egy saját generatív modellt építsünk, mely nem csak publikus, de a belső, bizalmas dokumentumokat is használja. Természetesen ez esetben az üzemeltető döntése, hogy a chatbot belső, kizárólag vállalati felhasználásra készül, a nyilvánosság számára nem elérhető. Az ilyen egyedi továbbfejlesztéssel pedig csökkenthető a hallucináció kockázata is, része lehet egy szakértői rendszernek is.

### 5.5.2. Gépi fordítás használata természetes nyelvek és szakmai leírónyelvek esetén

A közel 70 éves múltra visszatekintő gépi fordítás az elmúlt években jelentős fejlődésen ment keresztül. Míg korábban jellemzően a nagyobb tanulási mintával, nagyobb arányban beszélt nyelvek fordítása volt emberközelibb, ma már kisebb csoportok által beszélt nyelvek – például Közép európai nyelvek – gépi fordítása is jónak mondható, köszönhetően annak, hogy a korábban használt szabály alapú fordítás helyett a modern fordítómotorok már minta és statisztikai gépi modelleket használnak (Wang et al., 2022). Ígéretes terület a beszélt

nyelv felismerése és annak élő fordítása akadálymentesítés és feliratozás céljából. A Microsoft PowerPoint 2019 és a PowerPoint Online már rendelkezik olyan feliratozó funkcióval, mely az előadó által élőben mondott szöveget a prezentáció során feliratként megjeleníti, akár más nyelvre lefordítva is. A funkció jelenleg a legelterjedtebb beszélt nyelveket – például angol, spanyol, német, kínai, hindi stb. – ismeri fel, míg a felirat nyelve többek között magyar is lehet. A 9. ábra bemutatott fordítás ugyan nem tökéletes, nem hibátlan, de érhetően adja vissza az orbáncfű botanikai leírását.

**SUMMARY**



**Hypericum perforatum**, commonly known as St. John's Wort, is a perennial herbaceous plant native to Europe, Asia, and North Africa. It is well-known for its bright yellow flowers and has been used for various medicinal and therapeutic purposes for centuries. Here's a botanical description of **Hypericum perforatum**:

**Plant Type:** *Hypericum perforatum* is a herbaceous plant, which means it lacks woody stems and generally dies back to the ground each year.

**Size:** It typically grows to a height of 30 to 90 cm (12 to 35 inches).

**Stem:** The stems of St. John's Wort are erect, branched, and can be woody at the base. They are usually covered with small, translucent oil glands that give the plant a characteristic dotted appearance when viewed against the light.

Phytotherapy  
This photo by Shutterstock author is licensed under CC BY-SA

Általában kis átmeneti olajmirigyekkel vannak borítva, amelyek a fény felé nézve a növény jellegzetes pontozott megjelenését adják.

9. ábra - Angol nyelvű prezentáció gépi feliratozása magyar nyelven (dia: Göndöcz; szöveg: ChatGPT, 2023)

A gépi fordításnak van egy másik, nemrég kialakult felhasználási területe is. A természetes nyelvek fordítási modelljeit, azok fejlesztése során összegyűlt tapasztalatot felhasználva az utóbbi időben kezdenek elterjedni olyan modellek, melyek természetes nyelvet mesterséges nyelvekre fordítanak, illetve mesterséges nyelven készült kódokat, sémákat elemeznek. Ilyenek például a programkódokat készítő botok – például a ChatGPT v3.5 több programozási nyelvet is ismer, igen jó kódokat képes írni. De egyre gyakrabban használják a modelleket matematikai egyenletek megoldására, valamint komplex molekulaképletek tulajdonságainak előrejelzésére (Öztürk et al., 2020). Utóbbi esetben az okozza a feladat nehézségét, hogy ellentétben a természetes nyelvekkel, programkódokkal, nem áll rendelkezésre megfelelő mennyiségű adat a modellek betanítására. Az MIT kutatói ezért olyan módszereket kerestek, melyekkel az NLP modellek módszertana kis mintán is használható a molekuláris nyelvtan megtanulására és a molekulák tulajdonságainak előrejelzésére gyógyszerészeti kutatások során (Zewe, 2023).

Összefoglalva a gépi fordítás egyre nagyobb segítséget nyújt a nemzetközi együttműködésben kommunikációban. Mivel már nem szabály alapú algoritmusok végzik a fordítást, hanem a gép humán fordítók által készített adatból tanul, a szakmai kifejezések fordítása is egyre pontosabb. Azonban azt fontos figyelembe venni, hogy nincs minden nyelvpárra elérhető elegendő tréning adat. Például egy koreai-magyar fordítást a gép két lépcsőben, köztes nyelv, az angol használatával fogja lefordítani. Ezáltal kétszeresére nő a fordítási hibák

lehetősége, hisz amit pontatlanul fordít a bemeneti nyelvről angolra, már biztosan nem lesz helyes angolról magyarra.

### 5.5.3. Szövegelemző modellek

A természetes nyelveket feldolgozó modellek között megtalálható több, használatra kész, betanítást nem igénylő modell. Ezek funkciói szorosan nem kötődnek a gyógynövény ágazathoz, de nem zárható ki, hogy egy gyógynövény kereskedelmi vállalkozás, gyártóüzem, gyógyszeripari cég ne tudná hasznosítani tudásukat. Felsorolás-szerűen a modellek és röviden a feladatuk:

- **Szövegfelismerés:** optikai karakterfelismerő, angolul optical character recognition (OCR) modellek szkennel, nyomtatott szöveg digitalizálását teszik lehetővé. Jól használható nem strukturált, szöveges adatok digitalizálására – például tréningadat előkészítéséhez is. Megbízhatóan működnek a kézírásfelismerő modellek is, így tréningadat akkor is készíthető, ha a kísérletek, természetés során az adatok „matekfüzetben” lettek rögzítve. Egy ilyen OCR eszközt használt Staub et al., (2016) Dioszkoridész De Materia Medica c. könyvének középkori latin kiadásának digitalizálására is.
- **Nyelvfelismerés:** felismeri, hogy a szöveg milyen nyelven íródott. Több nyelvi környezetben jól használható folyamatautomatizálásra. Például a bejövő e-maileket (megrendelések, panaszok, támogatási kérelmek stb.) az adott csapathoz irányítja, dokumentumokat nyelvek szerint szétválogatni stb. (Microsoft, 2023c).
- **Entitáskinyerés:** (angolul entity extraction) Természetes és jogi személyek adatait emeli ki strukturált és nem strukturált szöveges dokumentumokból. Ilyenek például: név, cím, telefonszám, életkor stb. Néhány modell képes más entitásokat, például fizikai mértékegységeket (súly, sebesség, hőmérséklet stb.), színeket és más értelmezési tartományokat is kinyerni. Ügyviteli rendszereknél, dokumentumkezelőknél használhatók dokumentációk strukturálására (Microsoft, 2023c).
- **Kulcsszókeresés:** szöveges információból kinyeri a legfontosabb kulcsszavakat. Többek között dokumentumok összefoglalóinak automatikus készítésére, dokumentumok kategorizálására használhatók. A fentebb említett Staub et al., (2016) ugyanazon tanulmányában az adatdigitalizálás után egy ilyen modellt futtató szoftveres megoldást használt Dioszkoridész könyvében szereplő gyógynövények fitoterápiás kategóriákba, hatásirányokba való sorolásához.
- **Hangulatelemzés:** szöveges információ hangvételét elemzi és sorolja kategóriákba (pozitív, negatív, semleges, vegyes). Jellemzően nagy mennyiségben kitöltött ügyfélelégedettségi kérdőívek, közösségi hálózatok posztjait elemzik ezek segítségével, kiemelve a nagyon pozitív és nagyon negatív példákat és továbbítja azokat a marketing osztály részére. Nagy ügyfélkörrel rendelkező gyártók, forgalmazók részére lehet releváns, termékélelégedettség, vállalati arculat stb. elemzésének automatizálásához. Egy ilyen modellt használt például Neill et al., (2023) is kutatásában, melyben a biogazdaság koncepcióval (bioeconomy concept) kapcsolatos társalgásokat elemezte a Twitter közösségi hálózaton.

## 5.6. Szakértői rendszerek

Szakértői rendszerek alatt azokat az informatikai megoldásokat, tudás alapú rendszereket értjük, melyet egy speciális részterületen szakértője a döntés meghozatalához használni tud. MI esetén ezeket a rendszerek a humán intelligencia képességeit képesek imitálni. Szabály alapú, IFTTT rendszerek fejlesztése már az 1960-as években kezdődött. Az egyik első AI-t használó orvosdiagnosztikai eszköz az 1975-ben megjelent Mycin, mely etikai megfontolásokból nem került gyakorlati alkalmazásra – komoly szakmai ellenállásba ütközött, hogy egy gép hozza meg a döntést egy onkológiai kezelés esetén szükséges antibiotikum kúráról – holott a gép által felállított diagnózis meghaladta az általános orvosok eredményeit, és közel hasonló volt a szakorvosok diagnózisához (Trivedi, 2018).

Hasonló rendszerek ma már könnyen építhetők LCNC platformokon. Például szakértői chatbot, web portál néhány napos munkával készíthető, amennyiben elektronikus formában, strukturáltan már rendelkezésre állnak a tudásbázis felállításához szükséges információk. Mint minden adat alapú projektnél, a leginkább időigényes fázis az tanuló adat definiálása. A piacon ma már rengeteg AI öndiagnosztikai eszköz érhető el, de a korábbi etikai problémát még ma is többen felvetik. Low-code platform gyártók általában ki is hangsúlyozzák, hogy a terméküket nem javasolják orvosdiagnosztikai botok építésére. Például a Microsoft élesen elzárkózik a felelősség elől bármilyen hasonló jellegű felhasználásnál (Microsoft, 2023c). Összefoglalva: egy fitoterápia bot könnyen építhető lenne, bár a szükséges adatok gyűjtése, strukturálása időigényesebb lenne, azonban mindenképpen javasolt jogi és etikai szempontból is körbejárni a kérdést, mielőtt egy vállalat ilyen termékkel kíván a piacra lépni.

### 5.6.1. Kártevők diagnosztizálása és kezelése

A fentiekkel szemben más területeken nem etikai kérdések, hanem a rendelkezésre álló, betanításra használható adat, vagy a probléma komplexitása akadályozza meg, hogy szakértői rendszer építsünk. Alapvetően károsítók előrejelzésre megfelelő lenne egy előrejelzési modell, mely figyelembe veszi a talajra, terményre, időjárásra vonatkozó adatokat. Ezek az adatok akár valós időben gyűjthetők hálózatba kötött IoT eszközök segítségével, kiegészítve nagy felbontású kamerával rendelkező drónok felvételeivel. Az előrejelzési modell betanításához szükség lesz computer vision modell építésére is, melyet betanítunk a kártevők vagy a károkozók jelenlétének detektálására. Ez alapvetően nagy területen működhet, ahol még van idő a detektálás után a termőterület további részén védekezni a támadás ellen. Kisebb területeken ilyen képi adatokra nem igazán tudunk támaszkodni, mert könnyen lehet, hogy mire detektáljuk a károsítót, addigra már a teljes terület fertőzött. Ilyenkor jobbára a múltbéli adatokból készült előrejelzési modell pontosságára tudunk támaszkodni. Abban az esetben, ha megvan az előrejelzés, és sikerült a károsítót meghatározni, szükség lesz egy kategorizáló/besoroló modellre, melynek segítségével a rendszer meghatározza a védekezés módját, javaslatot tesz az adott situációban hatékonyan használható növényvédelmi alternatívákra.

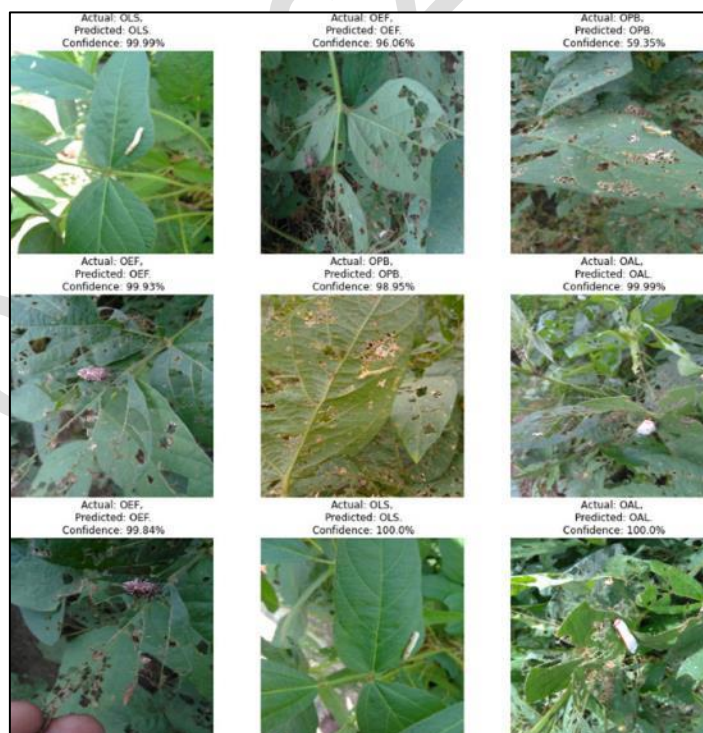
Összefoglalva: technikailag megoldható lehet egy komplex növényvédelmi szakértői rendszer építése, de igen magas költségekkel járna. Már magában az előrejelzéshez szükséges adatok gyűjtését végző szenzorhálózat, és annak vezetékes vagy vezeték nélküli adatkapcsolata, drónok beszerzése is igen magas költség. Továbbá gondot jelent, hogy a rendszerhez szükséges 3-4 modell betanításához szükséges adat elérhetősége nem

biztosított. A pontos modellekhez itt már célszerűbb lenne full-code modelleket építeni, ami további költségekkel jár. Megnehezíti ilyen modellek építését, hogy gyógynövényekre igen kevés az engedélyezett szerek száma, továbbá fokozott fogyasztói igény van a vegyszerek teljes elhagyására (Radácsi, 2023).

## 5.7. Számítógépes látás

A számítógépes látás (angolul: computer vision) a Mesterséges Intelligencia azon területe, mely vizuális észleléssel, felismeréssel foglalkozik. Ide tartozik a képek osztályokba sorolása, objektumok felismerése, valamint arcok felismerése, elemzése. Az utóbbi időben egyre inkább teret nyernek a videóelemző modellek is, melyek mozgóképes anyagokat elemeznek, indexelnek, és kombinálva használják az előző három állóképes technikát. A számítógépes látás az AI egyik legtöbbször kutatott területe, több kódolás nélküli platformmegoldás is elérhető: *Lobe*, *Google AutoML*, *Google Teachable Machine*, *Microsoft Power Platform*, *Apple CreateML*.

A **képbesorolás** egy olyan computer vision modell, mely arra van betanítva, hogy a kép fő témája alapján a képet osztályokba sorolja. Ez, hasonlóan az adat alapú kategorizáló modellekhez lehet bináris, vagy több kimenetes osztályba sorolás is. Valamint egy kép tartozhat egy osztályhoz, vagy többhöz is, mely esetben a gép az osztályokat súlyozottan adja meg. Ilyen modelleket használnak a növényfelismerő appok is, például a több kutatóintézet által finanszírozott, közösségi alapon adatokkal feltöltött és karbantartott alkalmazás a *Pl@ntNet Növényfelismerő* (PlantNet, 2023). De jól használható a technológia arra is, hogy károsítók nyomait feltérképezzük, megkülönböztetve az egészséges és beteg növényi részeket. Erre jó példa az 10. ábra, Tirkey et al., (2023) tanulmánya, ahol a kutatók különböző képbesoroló algoritmusok hatékonyságát hasonlították össze.




10. ábra – Károsítók felismerésének teljesítménypontszáma (Tirkey et al., 2023)

Az **objektumfelismerő** vagy **objektumészlelő** modellek képbesoroló modellek fejlettebb változatai. Nem csak azt jelzik, hogy egy adott objektum szerepel-e a képen, hanem képesek megállapítani a pozícióját is. Nem

csak egy igaz/hamis választ ad, hanem azt is, hogy az objektum a képen hol helyezkedik el. A modell egy tömböt ad vissza, mely tartalmazza a felismert objektum(ok) koordinátáit is. Amennyiben az adott objektum többször szerepel a képen, meg is tudjuk számolni őket, a tömb elemeit megszámlálva.

Az **arcfelismerés** területe nem kötődik szorosan az agrárium területéhez, viszonylag ritkán van szükség emberi arcok felismerésére, illetve az arcokra kiülő érzelmek beazonosítására. Ezeket a modelleket speciális scénáriókban használják, pl. egy fényképezőgép pontosan akkor készíti a fotót, amikor mosolyt érzékel. Arra vonatkozó termékmarketing kísérletek is vannak, hogy egy áruház polcán mely termékeket nézik a vásárlók és azok külleme milyen érzelmeket vált ki az adott termék. Esetleg egy gyógyszeripari kutatóközpont biztonsági rendszerének része lehet egy arcfelismerő rendszer, egy kulcskártyás beléptetés mellett másodlagos hitelesítésként valamilyen biometrikus azonosítást és végezve.

A gépi látás működése a képfájlok tárolási elvére vezethető vissza. A számítógépek a képeket úgynevezett bittérképént (bitmap) tárolják. Minden képpontról (pixel) tudjuk a pozícióját (X és Y koordináta), valamint a pixel színének kódja. Fekete-fehér képek esetén ez legtöbbször 0 (fekete) és 255 (fehér) közötti érték, a szürke tónusai szerint skálázva. Színes fotók esetén a leggyakoribb az RGB (red, green, blue) ahol a vörös, zöld és kék színek árnyalatait tároljuk és ezek keverékéből áll össze a 16 millió pixelszín valamelyike. A 11. ábra egy mirigyszőr egyik pixelének bitmap koordinátái, valamint RGB kódja (117,89,69 → ■) látható.



11. ábra – Mirigyszőr fotó pixelkoordináták bittérképén (fotó: Radácsi, 2023; bitmap: Göndöcz, 2023)

A tanulás során a gép ezen numerikus adatok mintáit, karakterisztikáit elemzi és állít fel összefüggéseket. Minden objektumnak megvannak a maga sajátosságai, ezeket az úgynevezett *feature*-öket használjuk az objektum keresésére. Például a kör esetén olyan raszterpontokat keresek, melyek a középponttól egyenlő távolságra vannak. Természetesen komplexebb objektumok esetén nem csak a koordináták geometriai összefüggéseire, hanem a színekódokra, szomszéd pixelekkal, pixelcsoportokkal való összefüggésekre is egyenleteket állít fel a gép. Majd, amikor a modellt használjuk, akkor ezeknek az egyenleteknek a teljesülését keresi (Shin, 2020).

A bevezető fejezetben említett, a piacon már elérhető Carbon Robotics LaserWeeder, valamint a Lemken IC-Weeder-AI termékei eltérő módszert használnak gyomirtásra szánt gépi látás modellek betanítására. Előbbi a

gyomnövények felismerését tanította be, minden mást írt a robot, míg utóbbi a haszonnövényt ismeri fel, a többit írja. Mindkét stratégiának vannak előnyei és hátrányai.

- A LaserWeeder csak a betanított gyomokat fogja írni, cserében módosítás nélkül használható más kultúrában is. Azonban a széles gyomportfólió betanítása több időt, tanulóadatot, ezáltal mindenképp magasabb induló költséget jelent.
- A Lemken Group megoldásánál épp a fordítottja igaz. Néhány növény betanítása relatív kisebb időigénnyel bír, azonban ügyelni kell arra, hogy az eszközt más kultúrában használva a haszonnövényeket biztosan ismerje fel, azokat ne irtsa ki. Sőt, ez a módszer a gyártónak biztosít lehetőséget, hogy kiegészítő szoftvercsomagokat értékesítsen, melyek az alapfunkciókat egészítik ki további növények felismerésével.

A számítógépes látás alkalmazására a gyógynövény ágazatban is igen sok lehetőség nyílik. A korábbi fejezetekben már röviden bemutatott, a piacon elérhető alkalmazások (PI@ntNet, LaserWeeder, IC-Weeder-AI) mellett lehetséges irányok lehetnek:

- Objektumészlelési modellek számlálási feladatokhoz: például illóolaj mirigyek számlálása. Kártevők, rovarok számlálása sárga lapon, feromon csapdákbán.
- Képbesoroló modellek: például drogok beazonosítása, karanténnövények egyértelmű beazonosítása gyűjtői munka támogatásához. Megfelelő mennyiségű minta esetén vékonyréteg kromatográfia szilikagél foltjainak elemzésére.

## 5.8. Modellek tervezésének alapvető szempontjai

**Csak azért ne építsünk egy modellt, mert képesek vagyunk rá.** A 2020-as években a Mesterséges Intelligencia igen népszerű marketinghívószóvá vált. Sok helyen megjelenik, befektetői, cégvezetői elvárás lett a használata, bizonyítandó ezzel egy-egy vállalat innovációpozitív mivoltát. Például nagyon jó modelleket lehetne építeni válogatószalagok melletti munka támogatására, anomáliák, hibák jelzésére. De ezekre vagy vannak céleszközök, vagy nem lenne költséghatékony. Egy computer vision modellnek legalább 2-3 másodpercre van szüksége egy kép feldolgozására, ez idő alatt a szalagon akár több tucat termék is továbbhalad.

**Megfelelő mennyiségű tanulóadat használata.** Minden modell típusnál meghatározott a minimális és az optimális adat. A minimális mennyiség általában egy prototípus, teszt, demó építéséhez elegendő, éles környezetben nem elegendő. Több fotó vagy adat használatával növelhető a modell pontossága. A legtöbb LCNC platformon 5-15 kép, vagy 50 adatsor már elegendő a betanítás elkezdéséhez. Azonban ez nem jelenti azt, hogy ilyen alacsony számmal megbízhatóan működni is fog. Kevés fotó, illetve adat esetén nagyobb a kockázat, hogy a gép zajt, irreleváns információt tanul elemeket tanul meg.

**Törekedni kell a változatosságra.** A megbízható modellek az objektumokat különböző háttér előtt, eltérő fényviszonyok között, több perspektívában és változó méretben ábrázoló fotókról tanulják meg felismerni. Hasonlóan az adat alapú modelleknél, ha túlsúlyban van az egyik adatosztály, akkor a gép valószínűsíti, hogy annak nagyobb az esélye. Például egy esősebb időszakban gyűjtött locsolási adatsor azt eredményezi, hogy a locsolót kevesebbszer kapcsoltuk be, a modell meg fogja tanulni ezt az információt. A helyesen megválasztott

tréningadat vegyesen tartalmaz esős, aszályos és átlagos időszakokat is. Érdeemes észrevenni, hogy a Carbon Robotics demonstrációs fotói, videói éjszakai körülmények között készültek, és a LaserWeeder saját fényszóróit használják az éles üzem közbeni megvilágításhoz, az analízishez használt képek készítéséhez. Ezzel kiküszöbölik azokat a problémákat, melyek a különböző nappali környezeti viszonyokból – napsütés, felhős, esős időjárás – adódnak, és a modell pontosságát zavarják.

**Ügyelni kell az „ismétlődő zaj” elkerülésére.** Ha például olyan modellt készítünk, mely a mentát különbözteti meg a citromfűtől, és az egyiket cserépben, míg a másikat szaporító ládában élő példányokkal tanítjuk be, akkor a modell ezeknek a háttérobjektumoknak a mintáit is megtanulja és keresik a későbbi képeken. Ennek a fordítottja is igaz, ha például arra tanítunk be egy modellt, hogy különböztesse meg az egészséges máktokot a fertőzöttől, és a fotókat homogén, stúdió-szerű háttér előtt laborban, stúdióban készítjük, a modell nem fog megbízhatóan működni üzemi körülmények között. Hasonlóan az adatsor alapú modelleknél a kimenet szempontjából irreleváns információkat a tréningadatok közül ki kell szűrni. Az Előrejelzési modellek c. fejezetben bemutatott öntözési példa esetén például a modell 2% súllyal figyelembe vette a mérés időpontját. Ez hosszú távú, több évet felölelő adatsoroknál lehet releváns, hisz az időjárásnak van szezonálisitása, de a példa modell csak néhány hónap adatot vett figyelembe, ott ez egyértelmű hiba, a modell megbízhatóságát torzító tényező.

**Gazdaságosság.** Az MI projektek költségfaktorai a hardver költségek, szoftver licence díjak, és a szakértői, fejlesztői humán erőforrás költségek. Az MI modellek nagy számítási kapacitással, úgynevezett high-performance computing szervereket kívánnak, melyek a legdrágább eszközök közé tartoznak. Épp ezért sok esetben nem is helyi, hanem felhőszolgáltatásként vásárolják ezeket. A licence díjak is igen magasak, a kísérletben használt platform havi kezdődíja 500 amerikai dollár (Microsoft 2023b). Végül, de nem utolsósorban, a szakértői díjak szintén a legmagasabbak közé tartoznak.



## 6. Anyag és módszer

### 6.1. Kísérlet: illóolajtartó mirigyszőrök számlálása

Az illóolajtartó mirigyszőrök számolása egy vizuális feladat, azaz egy computer vision modell létrehozása szükséges. Mivel nem csak azt kell eldönteni, hogy az adott képen szerepel-e mirigy, így nem elegendő egy képesbesoroló modell. Objektumfelismerést kell alkalmazni, mivel az képes az adott tárgy koordinátáit meghatározni a képen, és ha több szerepel, akkor azokat egy adattömbbe rendezni. A tömb elemeinek megszámlálásával lesz lehetőségünk a mirigyek számának meghatározására.

### 6.2. Technikai háttér

A kísérlet során a Microsoft Power Platform AI Builder (Microsoft, 2023c) alaprendszerét használtuk. Ez a platform kódolás nélküli lehetőséget biztosít különböző modellek elkészítésére, valamint a kész modell más rendszerekkel való integrálásra: például az eredmény küldésére emailben, adatbázisba írása, Excel exportálásra stb. Ugyan más LCNC megoldások is lehetőséget biztosítanak a modellek kódolás nélküli elkészítésére, de a kész modell integrálásához a legtöbb esetben már szükséges programozói ismeret. A kísérlet során prioritást élvezett, hogy kódolás nélkül megvalósítható legyen. Természetesen a kényelmes használatnak a korlátait is figyelembe kell venni:

- A Microsoft a platformot üzleti ügyviteli rendszerek készítéséhez tervezte. Alapvetően egy általános célú üzleti rendszerplatform, mely nincs felkészítve speciális felhasználói forgatókönyvekre. Például az AI Builder esetén nem tudjuk a modelleket finomhangolni, nem ismerjük, hogy pontosan melyik algoritmust használják a betanítás során.
- Hasonlóan más LCNC megoldásokhoz, egy rövid próbaidőszak után a platform használathoz licencedíjat kell fizetni – például az űrlapfeldolgozó modellek díja oldalanként 2 amerikai dollárba kerül. Ezekért cserébe természetesen technikai dokumentáció és terméktámogatás is jár.

### 6.3. Adatforrás

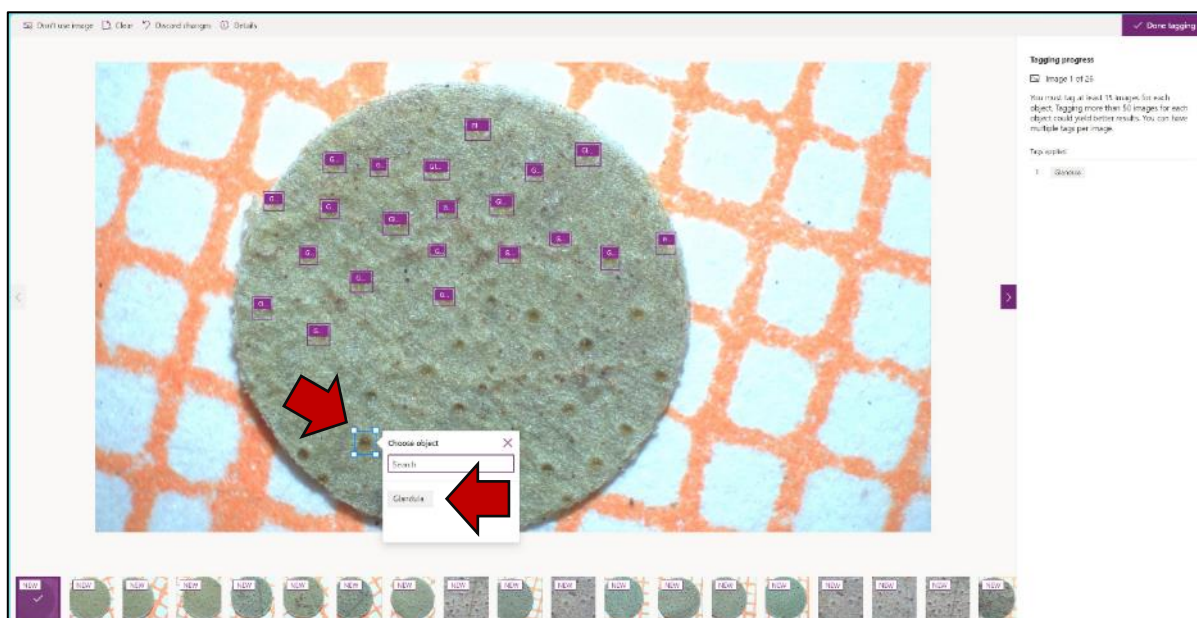
A modell betanítása Dr. Radácsi Péter által készített Zeiss Stemi 2000 típusú sztereómikroszkóp EUROMAX típusú USB mikroszkópkamerával készített fotók segítségével történt. A kísérlethez az 1. táblázatban felsorolt taxonok fotói lettek felhasználva. A taxonok préselt, száraz leveleiből, bőrlukasztó segítségével 3,2, illetve 4 mm átmérőjű köröket vágunk ki. A levelek korábbi évek, egyéb jellegű vizsgálataiból származtak.

1. táblázat – Forrásadatok objektumészlelési modell betanításához (Göndöcz, 2023)

Faj	Latin név	méret (mm)	darabszám
Amerikai bazsalikom	<i>Ocimum americanum</i>	3,2	8
Amerikai bazsalikom	<i>Ocimum americanum</i>	4	14
„Aroma” bazsalikom	<i>Ocimum basilicum</i> „Aroma”	4	11
„R-S” bazsalikom	<i>Ocimum basilicum</i> „R-S”	4	14
„Thai” bazsalikom	<i>Ocimum basilicum</i> „Thai”	4	9

## 6.4. Modell betanítása

A kísérlethez egy ún. egyéni objektumfelismerő modell készült, ahol a felkészített alapmodell betanítását a felismerni kívánt objektumokról készült fotók segítségével kell elvégezni. Az AI Builder egy grafikus eszközt biztosít, melynek segítségével az észlelni kívánt objektumok felcímkézhetők (angolul tagging). Első lépésben fel kell tölteni a tanításhoz szükséges, megfelelően előkészített fotókat, meghatározni a címkéket (angolul tag), majd a fotókon bekeretezni (angolul bounding box) az objektumokat (12. ábra).

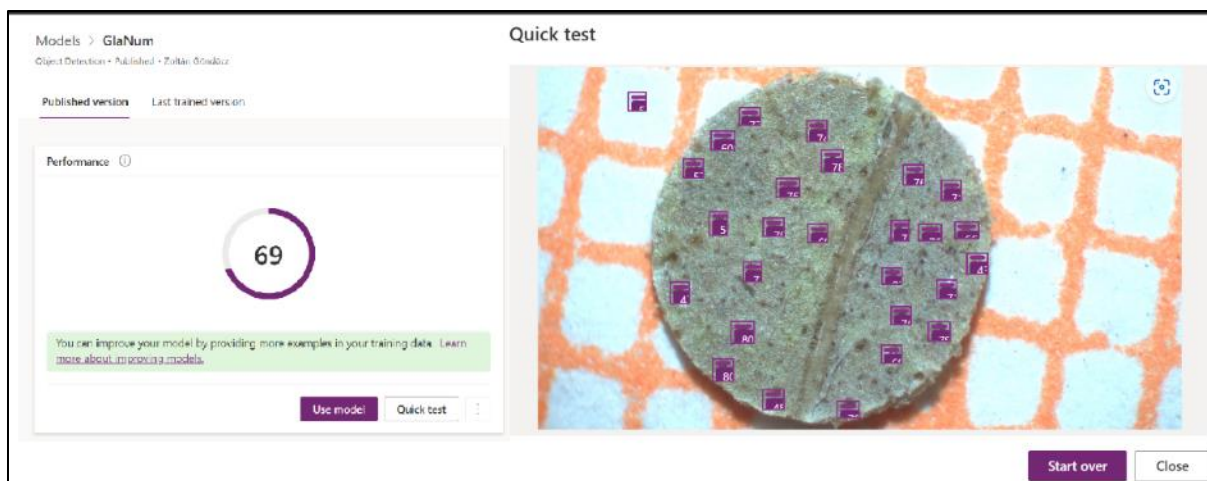


12. ábra – Forrásfotó címkézése AI Builder segítségével (Göndöcz, 2023)

A betanításhoz legalább 15 fotó szükséges, melyek felcímkézése után a gép elemzi a fotókat és elkészíti a modellt.

A betanítás után megjelenik a modell teljesítményindexe, valamint egy gyors teszt is végezhető (13. ábra). A teljesítmény-index értelmezésénél ügyelni kell arra, hogy az nem a jövőbeni elemzések pontosságát mutatja. A gép a tréning során véletlenszerűen kiválaszt néhány minta adatot, és a betanított modellen ezt a tesztkészletet lefuttatja. A pontszám tesztkészlet találatai és a mintaadaton felcímkézett objektumok közötti relációt mutatja. Kevesebb fotó esetén ez akár 100% is lehet, azaz mindent megtalál, ami éles üzemben elég valószínűtlen. A nagyon magas 95% feletti indexek esetén gyanakodni kell, hogy a tréning nem volt kellően változatos. Az alacsony pontszámok esetén valószínűleg nem megfelelően címkéztük az objektumokat (Chamarthy, 2019).


A pontosabb betanításhoz célszerű legalább 50 fotót használni, ezzel a modell pontosabbá válik, annak ellenére, hogy alacsonyabb teljesítményindexet kapunk. Ez abból adódik, hogy jobban diverzifikált a tréninghez használt adatkészlet. Nagyobb számú képfájl esetén 65-85% közötti eredmény igen jónak számít.



13. ábra – Kész modell teljesítményének tesztelése AI Builderben (Göndöcz, 2023)

Mivel a modell betanítása, a képek felcímkézése elég időigényes folyamat, a kísérlet kiterjedt arra is, hogy kis mintaszámmal elérhető-e a kívánt pontosság? Megtakarítható-e az időigényes, összpontosítást igénylő munka? Ehhez az alábbi három szcenárió szerepelt a kísérletben:

1. Az *Ocimum americanum* 4 mm-es fotókból kivágott részletek, melyek mindegyikén minden mirigy be lett jelölve (14. ábra)
2. A tréning fotóállomány mindegyikén 3-4 mirigy lett bejelölve.
3. Minden taxon első 5 fotóján az összes mirigy be lett jelölve.




14. ábra -I. sz. kísérlethez felhasznált tréningadat (fotó: Radácsi, 2023; szerkesztés: Göndöcz, 2023)

## 7. Eredmények és értékelésük

### 7.1. I. számú kísérlet

Az elkészült modell teljesítményindexe 76%. A magas index ellenére, a kis adatkészletből adódóan a modell nem tudta helyesen megtanulni a mirigyeket felismerni. 4 teszt alapján a modell nagyobb nagyítások esetén megtalálta az összes mirigyeket, más esetekben sok hibával dolgozott. Megfelelő nagyítás esetén a modell más taxon esetén is képes volt felismerni szinte az összes mirigyeket (15. ábra jobb alsó kép). Mivel a modell nem volt képes megtalálni a mirigyeket a teljes körkivágott mintákon, így a teljes adatállományon a teszt nem lett lefuttatva.



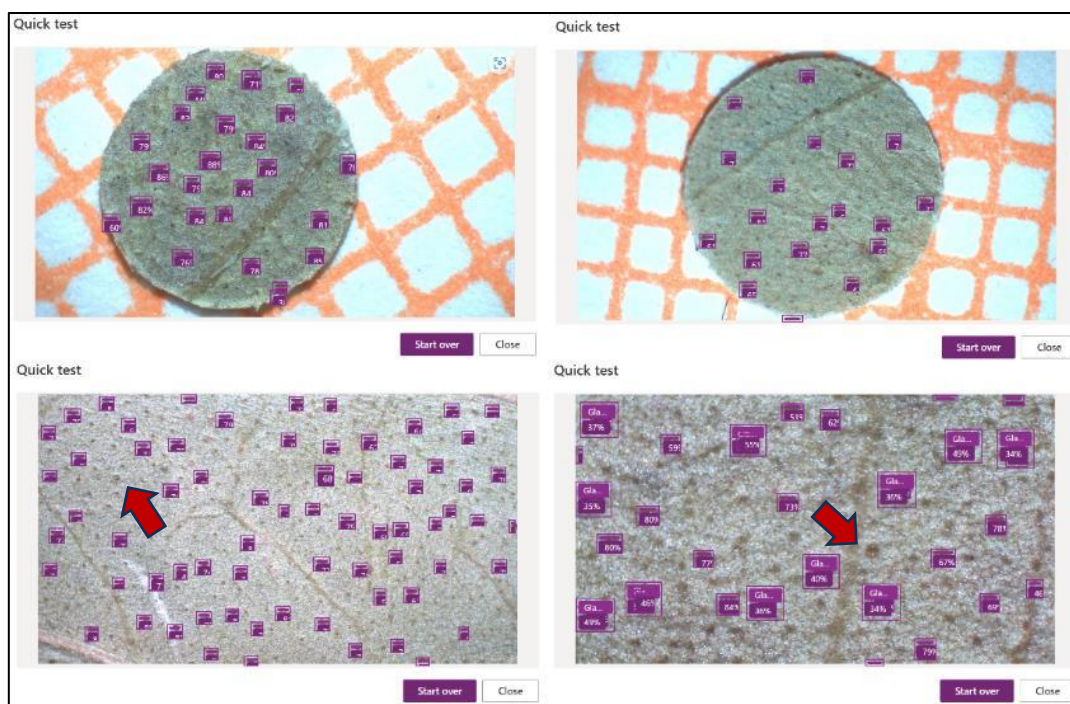
15. ábra – I. sz. kísérlet gyorseszteszt eredmények (Göndöcz, 2023)

### 7.2. II. számú kísérlet

Tréning adatkészlet: a teljes képállomány mind az 56 fotója, változtatás nélkül. Képenként 3-4 mirigy lett címkézve. A modell elkészítése után a teljesítményindex 10% lett, ami rendkívül alacsony megbízhatóságot jelent, így ezen a modellen gyorsesztesztek nem készültek.

### 7.3. III. számú kísérlet

Tréning adatkészlet: minden taxonból az első 5 fotó, módosítás nélkül, melyeken minden mirigyképlet be lett jelölve. Az elkészült modell jónak számító 69%-os teljesítményindexet kapott. A manuális tesztek során mind kisebb, mind nagyobb zoom nagyítású képeken jó eredményeket produkált, elenyésző számú hibával: a körkivágású mintákon minden mirigyeket megtalált, míg a kivágás nélküli levélrészek fotóin 1-2 mirigyeket nem talált meg (16. ábra).



16. ábra - III. sz. kísérlet gyorsesztezt eredmények (Göndöcz, 2023)

A részletes, mintánkénti adatok a II. mellékletben találhatóak. A taxononkénti átlagos mirigysűrűség adatokat a 2. táblázat tartalmazza.

2. táblázat - átlagos mirigysűrűség (Göndöcz, 2023)

Faj	átmérő (mm)	minták (db)	Mirigysűrűség (db/cm <sup>2</sup> )
Amerikai bazsalikom	3,2	8	262,6
Amerikai bazsalikom	4	10	197,3
„Aroma” bazsalikom	4	8	216,8
„R-S” bazsalikom	4	12	203,6
„Thai” bazsalikom	4	6	164,5

A gyorsesztezt után a modell a teljes képállományon le lett futtatva. Ennek automatizálására egy Microsoft Power Automate automatizált munkafolyamat készült, mely robot az összes képfájlt megnyitotta és az eredményeket egy Excel táblába írta. A gépnek az 56 kép feldolgozására átlagosan 11 percre volt szüksége, azaz nagyjából 12 másodperc alatt képes feldolgozni egy képmintát.

## 8. Konklúzió

Egy mintaképen minden mirigyet be kell jelölni. Ha nem jelöljük be, a gép megtalálja a hasonlóságot a bejelölt mirigyekkel, és keresni fogja az okát, hogy az miért nem lett bejelölve. Ezáltal hibásan fog a modell működni.

A betanítást vagy hibátlan körkivágású, vagy kivágás nélküli levélrészleteken külön modelleken célszerű elvégezni. Amennyiben egy modell használata szükséges, úgy törekedni kell arra, hogy a két perspektíva hasonló arányban szerepeljen a mintában. A 3. kísérlet során a mintaképek 80%-a teljes körkivágású volt, melyeken a modell helyesen is működött. A többi képen hibázott, mert nem volt elegendő a minta a tanuláshoz. Ezek a képek a mirigysűrűség számításból ezért ki is lettek zárva.

Bár az illóolajtartó mirigyszőrök igen hasonlóknak tűnnek, megfelelő nagyítással látható, hogy jelentősen eltérnek. További nehézség az ép és a felhasadt, elkopott mirigyek közötti eltérés, valamint, hogy a mikroszkóp fénye más-más szögben esik a mirigyekre, máshol csillognak (17. ábra). Ezekből a sajátosságokból adódóan nagy tanítási mintán kell dolgozni, hogy megfelelően pontos eredményt kapjunk. Alternatív megoldás lehetne a deep learning megoldások használata, melyek kis mintán is betaníthatók, de ezekből LCNC megoldás nem érhető el.



17. ábra - *Ocimum basilicum* 'Aroma' mirigyeinek különbözősége (fotó: Radácsi, szerkesztés: Göndöcz, 2023)

A betanítás során könnyebbséget jelentett, hogy a mintákat labor körülmények között kell feldolgozni. Így nem volt szükség a különböző hátterek, eltérő fényviszonyok stb. okozta különbözőségek miatt a változatosságra fokozottan ügyelni.

Összehasonlítva a manuális számolással, lényegesebb magasabb számú mintát lehet bevonni a mirigysűrűség meghatározásához, és pontosan betanított modell esetén, a nagyobb elemszámból adódóan pontosabb átlag számítható. Azonban számolni kell a betanításhoz szükséges idővel is, mely csak akkor térül meg, ha a modellt többször használjuk vagy elegendően nagy mintán kell alkalmazni.

## 9. Hivatkozások

1. Csósz, T. (2023): **Csósz Tibor vilaggazdasag.hu interjú** (a Mezőgazdasági Szövetkezők és Termelők Országos Szövetségének – MOSZ tanácsosa) <https://www.vg.hu/agrar/2023/07/feszult-a-gabonapiac-mar-nem-csak-az-ukranok-tamadjak-az-olasz-importoroket>
2. Dhal, S. D.; Bagavathiannan, M.; Braga-Neto, U.; Kalafatis S. (2022): Nutrient optimization for plant growth in Aquaponic irrigation using Machine Learning for small training datasets - **Artificial Intelligence in Agriculture Volume 6**, 2022, Pages 68-76
3. Gao, H.; Zhangzhong, L; Zheng, W.; Chen, G. (2023): How can agricultural water production be promoted? a review on machine learning for irrigation. **Journal of Cleaner Production Volume 414**, 15 August 2023, 137687
4. OMSZ (2021): Meteorológiai Adattár – **Országos Meteorológiai Szolgálat** <https://www.met.hu/omsz/tevekenysegek/adattar/>
5. CLAAS (2023): Remote Service module tájékoztató – **CLAAS** <https://special.claas.com/cl-pw-hu/gepek/digitalis-megoldasok/remote-service>
6. KSH (2023): Digitális Gazdaság helyzetkép 2022, **Központi Statisztikai hivatal** <https://ksh.hu/s/helyzetkep-2022/#/kiadvany/digitalis-gazdasag>
7. Carbon Robotics (2023): LaserWeeder Implement technikai dokumentáció **Carbon Robotics** <https://carbonrobotics.com/laserweeder>
8. PI@ntNet (2023): PI@ntNet™ Identify webes alkalmazás <https://identify.plantnet.org/hu>
9. Tirkey, D.; Singh, K. K.; Tripathi, S. (2023): Performance analysis of AI-based solutions for crop disease identification, detection, and classification. **Smart Agricultural Technology Volume 5**, October 2023, 100238
10. Microsoft (2023a): Overview of document processing model – AI Builder technikai dokumentáció – **Microsoft Learn** <https://learn.microsoft.com/en-us/ai-builder/form-processing-model-overview>
11. Microsoft (2023b): AI Builder licenclési útmutató – **Microsoft Learn** <https://learn.microsoft.com/en-us/ai-builder/administer-licensing>
12. Microsoft (2023c): AI Builder technikai dokumentáció – **Microsoft Learn** <https://learn.microsoft.com/en-us/ai-builder/>
13. Chamrathy, R. (2019): Interpreting machine learning model performance measures – **IBM Data Science in Practice** <https://medium.com/ibm-data-ai/interpreting-machine-learning-model-performance-measures-ef2138047b96>
14. OpenAI (2023): Introducing ChatGPT – **OpenAI** – <https://openai.com/blog/chatgpt>
15. Walsh, D. (2023): The legal issues presented by generative AI – **MIT Sloan** <https://mitsloan.mit.edu/ideas-made-to-matter/legal-issues-presented-generative-ai>
16. Zirpoli, C. T. (2023): Generative Artificial Intelligence and Copyright Law – **Congressional Research Service** <https://crsreports.congress.gov/product/pdf/LSB/LSB10922>

17. Necz D. (2018): A mesterséges intelligencia hatása a szerzői jogra – **Iparjogvédelmi és Szerzői Jogi Szemle** - 13. (123.) évfolyam 6. szám, 2018. december
18. Marjit, U. (2023): AI Content Detection Tools for Academic Researchers – **Researcher Site** <https://researchersite.com/the-best-5-ai-content-detection-tools-for-academic-researchers/>
19. Staub, P.O.; Casu L.; Leonti, M.; (2016): Back to the roots: A quantitative survey of herbal drugs in Dioscorides' De Materia Medica (ex Matthioli, 1568); **Phytomedicine Volume 23, Issue 10**, September 2016, Pages 1043-1052
20. Wang H., Wu H., He Z., Huang L., Church K. W., (2022): Progress in Machine Translation, **Engineering Volume 18**, November 2022, Pages 143-153
21. Öztürk, H.; Özgür, A.; Schwaller, P.; Laino, T.; Ozkirimli, E. (2020): Exploring chemical space using natural language processing methodologies for drug discovery, **Drug Discovery Today Volume 25**, Issue 4, April 2020, Pages 689-705
22. Zewe, A. (2023): Learning the language of molecules to predict their properties – **MIT News** <https://news.mit.edu/2023/learning-language-molecules-predict-properties-0707>
23. Trivedi, M. C. (2018): **A Classical Approach to Artificial Intelligence** 331. oldal (ISBN-10. 8190698893)
24. Neill, A. M., O'Donoghue C., Stout J. C. (2023): Who is talking about bioeconomy? Stakeholder and sentiment analysis using social media **EFB Bioeconomy Journal Volume 3**, November 2023, 100055
25. Radácsi P. (2023): Növényvédelem a gyógynövénytermesztésben előadás – MATE Gyógynövényismerő és -felhasználó szakirányú továbbképzés <https://elearning.uni-mate.hu/mod/resource/view.php?id=600023>
26. Shin, T. (2020): A Beginner-Friendly Explanation of How Neural Networks Work - **Towards Data Science** - Jun 2, 2020 <https://towardsdatascience.com/a-beginner-friendly-explanation-of-how-neural-networks-work-55064db60df4>



## 10. Melléklet I. – ChatGPT beszélgetés a gyógyteákról

**GZ:** Szia, tudnál javasolni gyógytea keveréket hurutos köhögésre? Fontos, hogy természetes alapanyagokból, gyógynövényekből készíthető tea legyen!

ChatGPT:

Szia! Persze, szívesen javaslok néhány gyógynövény alapú teakeveréket hurutos köhögésre. Ezek a gyógynövények segíthetnek enyhíteni a tüneteket és gyorsabban felépülni:

Méz, citrom és gyömbér tea:

Hozzávalók:

- 1 csésze forró víz
- 1 evőkanál méz
- Fél citrom leve
- Kevés frissen reszelt gyömbér (kb. egy szeletnyi)

Ezt a teát a gyömbér gyulladáscsökkentő hatásával, a méz antimikrobiális tulajdonságaival és a citrom C-vitamin tartalmával ajánlják hurutos köhögés ellen.

Kamillatea:

Hozzávalók:

- 1 csésze forró víz
- 1 teáskanál szárított kamillavirág

A kamilla tea nyugtató hatású, és enyhítheti a torokirritációt.

Tüdőfű tea:

Hozzávalók:

- 1 csésze forró víz
- 1 teáskanál szárított tüdőfű (tüdőfű teakeverék beszerezhető gyógynövényboltokban)

A tüdőfű gyulladáscsökkentő hatással rendelkezik, és segíthet a hurutos köhögés enyhítésében.

Kakukkfű tea:

Hozzávalók:

- 1 csésze forró víz
- 1 teáskanál szárított kakukkfű

A kakukkfű antibakteriális és köhögéscsillapító hatású, és segíthet enyhíteni a köhögést.

Édesgyökér tea:

Hozzávalók:

- 1 csésze forró víz
- 1 teáskanál szárított édesgyökér

Az édesgyökér tea nyugtató hatású és enyhítheti a torokirritációt.

Mindig győződj meg róla, hogy nem vagy allergiás vagy érzékeny valamelyik összetevőre, és konzultálj orvosoddal, ha a tüneteid hosszabb ideig fennállnak vagy súlyosbodnak. A teakeverékeket fogyaszthatod naponta többször, amíg a tüneteid enyhülnek. Ne feledd, hogy a gyógynövényekkel történő kezelés nem helyettesíti az orvosi tanácsadást, és fontos az orvosi konzultáció, ha a tünetek súlyosak vagy tartósak.

**GZ:** Ezek inkább monoteák. Olyat tudsz javasolni, ami több gyógynövény keverékéből áll?

ChatGPT:

Természetesen, itt van egy gyógynövény-teakeverék javaslat hurutos köhögésre, amely több gyógynövényből áll:

### **Gyógynövényes Köhögés elleni Tea**

Hozzávalók:

- 1 teáskanál szárított kakukkfű
- 1 teáskanál szárított menta levelek
- 1 teáskanál szárított bodzavirág
- 1 teáskanál szárított édesgyökér
- 1 csésze forró víz
- Méz és citrom ízlés szerint (opcionális)

Elkészítés:

Melegítsd fel a vizet, majd öntsd rá a gyógynövényeket egy bögrébe.

*Fedd le a bögrét, és hagyd állni 10-15 percig, hogy a gyógynövények kinyerjék az ízüket és hatóanyagukat.*

*Szűrd le a teát, majd ízlés szerint adj hozzá mézet és citromot a további íz és gyógyhatás hozzáadása érdekében.*

*Ez a teakeverék több gyógynövényt is tartalmaz, amelyek segíthetnek enyhíteni a köhögést és a hurutos tüneteket. A kakukkfű köhögéscsillapító hatással bír, a menta segíthet a légutak kitisztításában, a bodza vírusellenes tulajdonságokkal rendelkezik, az édesgyökér pedig enyhítheti a torokirritációt. Ne feledd, hogy ha bármilyen allergiás reakciót tapasztalsz, vagy a tüneteid súlyosak, konzultálj orvosoddal.*

**GZ:** *A tüdőfű teának van klinikailag igazolt hatása?*

**ChatGPT:**

*A tüdőfű (*Pulmonaria officinalis*) egy gyógynövény, amely hagyományosan használták légzőszervi problémák, például köhögés, asztma és tüdőproblémák kezelésére. Azonban a tüdőfű hatásairól csak korlátozott tudományos vizsgálatok és klinikai bizonyítékok állnak rendelkezésre.*

*Az orvosi gyakorlatban általában olyan gyógynövényeket alkalmaznak, amelyekről szélesebb körű és megbízható tudományos bizonyítékok állnak rendelkezésre. A tüdőfű esetében a klinikai kutatások hiányoznak, és nincsenek jól dokumentált bizonyítékok arra vonatkozóan, hogy valóban hatékony lenne a légzőszervi problémák kezelésében.*

*Ezért azt javaslom, hogy ha súlyos légzőszervi problémáid vannak, vagy hosszú ideje tartó köhögéssel küzdesz, fordulj orvoshoz. Az orvos meg tudja vizsgálni és megadhatja a megfelelő kezelést, amely a leginkább hatásos lehet az adott helyzetben.*

*Mint mindig, amikor gyógynövényeket vagy alternatív gyógymódokat használsz, fontos konzultálni az egészségügyi szakemberrel, mivel bizonyos esetekben a gyógynövények és az alternatív terápiák nem megfelelőek vagy akár ártalmasak is lehetnek. Az orvos tudja tanácsolni a legmegfelelőbb kezelési lehetőségeket az egyedi egészségi állapotod alapján.*

## 11. Melléklet II. – részletes mérési eredmények

Fájlnev	Mirigyszám	Átmérő (mm)	Mirigysűrűség (db/cm <sup>2</sup> )
Americanum3_2mm.jpg	27	3,2	335,7174581
Americanum3_2mm_1.jpg	26	3,2	323,2834782
Americanum3_2mm_2.jpg	22	3,2	273,5475584
Americanum3_2mm_3.jpg	25	3,2	310,8494982
Americanum3_2mm_4.jpg	8	3,2	99,47183943
Americanum3_2mm_5.jpg	14	3,2	174,075719
Americanum3_2mm_6.jpg	23	3,2	285,9815384
Americanum3_2mm_7.jpg	24	3,2	298,4155183
Americanum4mm.jpg	74	N/A	N/A
Americanum4mm_1.jpg	72	N/A	N/A
Americanum4mm_10.jpg	23	4	183,0281846
Americanum4mm_11.jpg	45	4	358,098622
Americanum4mm_12.jpg	27	N/A	N/A
Americanum4mm_13.jpg	28	N/A	N/A
Americanum4mm_2.jpg	18	4	143,2394488
Americanum4mm_3.jpg	21	4	167,1126902
Americanum4mm_4.jpg	30	4	238,7324146
Americanum4mm_5.jpg	32	4	254,6479089
Americanum4mm_6.jpg	14	4	111,4084602
Americanum4mm_7.jpg	22	4	175,0704374
Americanum4mm_8.jpg	21	4	167,1126902
Americanum4mm_9.jpg	22	4	175,0704374
Aroma4mm.jpg	13	4	103,450713
Aroma4mm_1.jpg	32	N/A	N/A
Aroma4mm_10.jpg	39	4	310,352139
Aroma4mm_2.jpg	39	N/A	N/A
Aroma4mm_3.jpg	40	4	318,3098862
Aroma4mm_4.jpg	23	4	183,0281846
Aroma4mm_5.jpg	20	N/A	N/A
Aroma4mm_6.jpg	21	4	167,1126902
Aroma4mm_7.jpg	30	4	238,7324146
Aroma4mm_8.jpg	33	4	262,6056561
Aroma4mm_9.jpg	19	4	151,1971959
RS4mm.jpg	41	4	326,2676333
RS4mm_1.jpg	2	N/A	N/A
RS4mm_10.jpg	24	4	190,9859317
RS4mm_11.jpg	20	4	159,1549431
RS4mm_12.jpg	30	4	238,7324146
RS4mm_13.jpg	25	4	198,9436789
RS4mm_2.jpg	40	4	318,3098862
RS4mm_3.jpg	21	4	167,1126902
RS4mm_4.jpg	25	4	198,9436789
RS4mm_5.jpg	69	N/A	N/A

Fájlnév	Mirigyszám	Átmérő (mm)	Mirigysűrűség (db/cm <sup>2</sup> )
RS4mm_6.jpg	21	N/A	N/A
RS4mm_7.jpg	22	4	175,0704374
RS4mm_8.jpg	28	4	222,8169203
RS4mm_9.jpg	29	4	230,7746675
Thai4mm.jpg	33	4	262,6056561
Thai4mm_1.jpg	33	N/A	N/A
Thai4mm_2.jpg	27	4	214,8591732
Thai4mm_3.jpg	19	4	151,1971959
Thai4mm_4.jpg	19	4	151,1971959
Thai4mm_5.jpg	13	4	103,450713
Thai4mm_6.jpg	13	4	103,450713
Thai4mm_7.jpg	6	N/A	N/A
Thai4mm_8.jpg	9	N/A	N/A

## 12. Melléklet III. – Nyilatkozatok

### NYILATKOZAT

#### a szakdolgozatnyilvános hozzáféréséről és eredetiségéről

A hallgató neve: **GÖNDÖCZ ZOLTÁN**  
A Hallgató Neptun kódja: **ZATIRU**  
A dolgozat címe: **Mesterséges Intelligencia modellek alkalmazási lehetőségei a gyógynövény ágazatban**  
A megjelenés éve: **2023**  
A konzulens intézetének neve: **Kertészettudományi Intézet**  
A konzulens tanszékének a neve: **Gyógy- és Aromanövények 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 mindenkor 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: Budapest, 2023, október 26.

  
Hallgató aláírása

## NYILATKOZAT

**GÖNDÖCZ ZOLTÁN** (név) (hallgató Neptun azonosítója: **ZATIRU**) konzulenseként nyilatkozom arról, hogy a szakdolgozatot áttekintettem, a hallgatót az irodalmi források korrekt kezelésének követelményeiről, jogi és etikai szabályairól tájékoztattam.

A szakdolgozatot a záróvizsgán történő védelemre javaslom / nem javaslom<sup>1</sup>.

A dolgozat állam- vagy szolgálati titkot tartalmaz: igen nem<sup>2</sup>

Kelt: 2023 év október hó 27. nap



belső konzulens

---

<sup>1</sup> A megfelelő aláhúzendó.

<sup>2</sup> A megfelelő aláhúzendó.