

SZAKDOLGOZAT

Ilyefalvi Hanga Klára

2025



**Magyar Agrár- és Élettudományi Egyetem
Budai Campus
Élelmiszertudományi és Technológiai Intézet
Élelmiszermérnök alapképzési szak**

**SÖRÉLESZTŐ SEJTEK VITALITÁSÁNAK
MEGHATÁROZÁSA FELHŐALAPÚ,
MESTERSÉGES INTELLIGENCIÁT ALKALMAZÓ
KÉPFELDOLGOZÁSSAL**

Belső konzulens:	dr. Gillay Zoltán egyetemi docens
Belső konzulens tanszéke:	Élelmiszeripari Méréstechnika és Automatizálás Tanszék
Külső konzulens:	Tarcsi Ádám szakmai vezető, Elte-Soft Nonprofit Kft.
Készítette:	Ilyefalvi Hanga Klára

**Budapest
2025**

Tartalomjegyzék

1. Bevezetés és célkitűzések.....	2
2. Szakirodalmi áttekintés	4
2.1. A sörkészítés technológiája és az élesztők szerepe a folyamatban	4
2.1.1. A sör előállításának folyamata.....	4
2.1.2. Sörélesztők bemutatása	5
2.1.3. A sörélesztő szerepe az erjesztésben.....	5
2.2. Képfeldolgozás és mesterséges intelligencia.....	7
2.2.1. A képfeldolgozás elméleti háttere.....	7
2.2.2. A mesterséges intelligencia fejlődése és területei.....	8
2.2.3. A konvolúciós neurális hálózatok és a képfeldolgozás kapcsolata.....	9
2.3. Korábbi kutatások az élesztősejtek képfeldolgozásos vizsgálatában	10
2.4. No-coding képfeldolgozó eszközök és alkalmasságuk vizsgálata	11
2.5. A felhőalapú számítástechnika	13
2.5.1. A felhőalapú számítástechnika definíciója és főbb tulajdonságai	13
2.5.2. Felhőszámítási architektúrák	14
2.5.3. Felhőszolgáltatási modellek összehasonlítása	15
2.5.4. A felhőalapú számítástechnika előnyei és nehézségei.....	16
2.6. A felhőalapú számítástechnika jelenlegi trendjei a magyar kis- és középvállalkozások körében	18
2.7. Microsoft Azure.....	20
3. Alkalmazott módszerek.....	22
3.1. A sörélesztő-tartalmú minták előkészítése	22
3.2. Mikroszkópos képek elkészítése	24
3.3. A modell elkészítésének eszköze: Custom Vision	25
3.4. A modell felhasználásának környezete: Google Colaboratory (Colab)	29
3.5. A platformokat összekötő REST API működése	29
4. Eredmények és értékelésük	30
4.1. A modell létrehozása az Azure Custom Vision platformon	30
4.2. A kész modell integrálása a Google Colaboratory platformba.....	36
5. Következtetések és javaslatok	40
6. Összefoglalás.....	42
7. Irodalomjegyzék.....	43
8. Táblázatok és ábrák jegyzéke.....	46
8.1. Táblázatok jegyzéke	46
8.2. Ábrák jegyzéke	46

1. Bevezetés és célkitűzések

Dolgozatom témáját, a sörélesztősejtek életképességének képfeldolgozós vizsgálatát a Fehér Nyúl magyar kisüzemi sörfőzdével való együttműködés adta. A főzde a kisüzemi, kézműves sörfőzés egyik népszerű vállalkozása Magyarországon, amely kísérletező kedvéről és innovatív, különleges receptúráiról ismert, melyek állandóan frissülnek, hiszen a cég nagy energiát fordít a folyamatos termékfejlesztésre és az új sörök ízjellegének precíz megalkotására. A főzde rendkívül nyitott a sörfőzési folyamatok digitális fejlesztésére, ezen belül is főként adatalapú döntéshozatali rendszerek kiépítésére, a termelési és termékfejlesztési műveletek optimalizálásának érdekében. Az üzem több lehetséges pontján van lehetőség olyan rendszerek kiépítésére, melyek a cég mindennapjait megkönnyíthetik adatalapú döntéshozáson, vagy mesterséges intelligencián alapuló technológiák alkalmazásával. Az egyik ilyen pont az élesztőkezelés és erjesztés folyamatának optimalizálása, egy olyan mesterséges intelligencián alapuló képfeldolgozó rendszer létrehozásával, amely mikroszkópos képek alapján automatikusan ad visszajelzést az élesztősejtek vitalitásáról, így energiát és időt takarítva meg a dolgozóknak, mivel a monoton és fárasztó sejszámlálás feladatát automatizálja. Egy ilyen rendszer segítségével könnyebb nyomon követni az élesztő állapotát a fermentációs folyamatok és az élesztő-újrahasznosítás során, így a kapott információk alapján nem csak az erjesztési lépések optimalizálhatók, hanem a rendszer segíthet a termékfejlesztésben és az adott receptúrához legmegfelelőbb élesztőtípus kiválasztásában is.

Kutatásom során tehát egy mesterséges intelligencián alapuló képfeldolgozó modellt és lehetséges felhasználói felületét hoztam létre, illetve teszteltem, felhőalapú környezetben.

A rendszer megalkotása előtt megvizsgáltam az élesztők életképesség-vizsgálatának jelentőségét és hozzáadott értékét a sörgyártásban, illetve feltérképeztem az élesztősejt-vizsgálatok automatizálására irányuló legfrissebb kutatási tevékenységeket, melyek alapján egyértelmű, hogy nagy igény jelentkezik ipari és kutatás-fejlesztési oldalról is a mikrobiológiai minőségvizsgálatok digitalizálására.

Jellegéből adódóan az élelmiszeriparban számos folyamat automatizálását lehetne képfeldolgozással megoldani, ám ezek a megoldások általában komoly fejlesztői háttér meglétét követelik. Véleményem szerint a feladatra alkalmas, kódolást nem igénylő (no-coding) eszközök hatalmas potenciállal rendelkeznek, főként az élelmiszeripari kis-és középvállalkozások automatizálásának elősegítésében, hiszen segítségükkel saját, rugalmasan skálázható megoldások alakíthatók ki, minimális kezdeti tőkebevonással.

Dolgozatomban az alábbi célok megvalósítását tűztem ki:

1. Feltérképezni az aktuális felhőalapú szolgáltatások technikai hátterét és követelményeit, továbbá felhasználási lehetőségeit, mivel a kis-és középvállalkozások számára szerintem ezek a technológiák nyújthatnák a legrugalmasabb és legsokrétűbb digitalizálási lehetőségeket, összetett fizikai infrastruktúrák kiépítése nélkül.
2. Meghatározni, hogy az ipari gyakorlatban elvégezhető fejlesztés eredményeképpen létrehozott, mesterséges intelligencián alapuló modell milyen eredménnyel tudja ellátni az ember feladatait a mikrobiológiai vizsgálatok vizuális kiértékelésének tekintetében.
3. Megvizsgálni a vitalitásvizsgálat folyamatának és kiértékelésének automatizálhatóságát.
4. Megállapítani, hogy milyen hatékonyságot és eredményt lehet elérni a piacon jelenleg megtalálható, kódolást nem igénylő eszközök felhasználásával egy élelmiszeripari fejlesztés során.

2. Szakirodalmi áttekintés

2.1. A sörkészítés technológiája és az élesztők szerepe a folyamatban

Hogy a sörélesztők életképesség-vizsgálatának szükségességét szemléltessem, először bemutatom a sörfőzés általános folyamatát, majd az élesztők jellemzőit és szerepüket a fermentáció során, ezután ismertetem az új mérőrendszer szerepét a folyamatban.

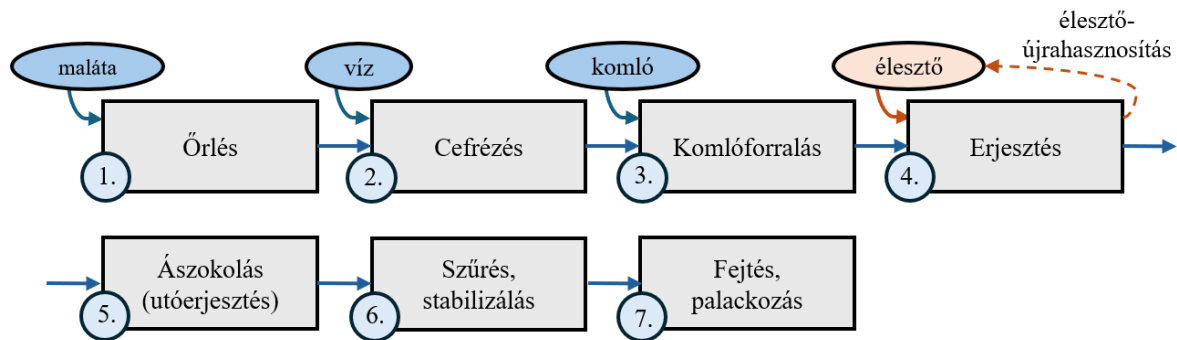
2.1.1. A sör előállításának folyamata

A sörkészítés folyamata az alábbi lépésekre osztható: őrlés, cefrőzés, komlóforralás, erjesztés, ászokolás, szűrés és stabilizálás, majd a sör lefejtése, palackozása.

Az őrlés során a malátázott (ritkább esetben malátázatlan) gabonaszemeket roppantással feltárják, hogy a magbelsőben található értékes komponenseket (elsősorban keményítő, illetve fehérjék) hozzáférhetőbbé tegyék. A maláta csíráztatott, majd különböző mértékben aszalt gabonát jelent. A sörgyártáshoz leggyakrabban árpát használnak, de recepttől függően többféle gabona is szolgálhat alapanyagként (pl. búza, zab, rizs, esetleg kukorica stb.). A roppantott gabonát ezután vízben áztatják és melegítik, ez a cefrőzés. A folyamat célja a maláta értékes komponenseinek oldatba vitele, és a malátázás során aktivált enzimek segítségével a keményítő erjeszhető szénhidrátokká bontása. A következő lépésben a cefrét leszűrik, majd az így előállított sörléhez komlót adnak és felforralják (komlóforralás). Forralás után a sörlévet megfelelő hőmérsékletűre hűtik, majd oxigént juttatnak bele, így az élesztő szaporodását elősegítő közeget hoznak létre. Ezután következik az élesztő hozzáadása, amely az erjeszhető szénhidrátokat alkohollá és szén-dioxiddá alakítja, emellett számos, a sör ízprofiljának kialakításáért felelős anyagcsere mellékterméket állít elő. Erjesztés után az élesztőt a tartály aljából kiengedve eltávolítják, és általában újra felhasználják más sörök előállításához. Az élesztőelvétel után következik az ászokolás (utóerjesztés), amely során a sört zárt tartályokban hetekig alacsony hőmérsékleten tartva biztosítják az íz- és aromaanyagok finomítását, illetve a maradék élesztősejtek ülepedését. Ezt követően a sört szűrik és stabilizálják, majd lefejtik és palackozzák (Eßlinger, 2009). A sörgyártás folyamatát az *1. ábra* szemlélteti:

1. ábra: A sörgyártás lépései és az élesztő helye a folyamatban

(Forrás: saját munka)



2.1.2. Sörélesztők bemutatása

A sörgyártás során erjesztésre felhasznált mikroorganizmusok leggyakrabban a Saccharomyces nemzetségbe tartozó *S. cerevisiae* és *S. pastorianus* élesztőgombák. A *Saccharomyces cerevisiae*-t felsőerjesztésű (ale) sörök előállításához használják, ugyanis ezek az élesztősejtek az erjesztés végén a sörlé felszínén gyűlnek össze. A *Saccharomyces pastorianus*-t alsóerjesztésű (lager) sörök erjesztésére alkalmazzák. Az alsóerjesztési folyamatok jellegzetessége, hogy az élesztősejtek az erjesztés végén csomókba tömörülnek (flokkulálódnak), majd az erjesztőtartály aljára süllyednek. Fontos különbség még a két élesztőfaj között, hogy a felsőerjesztésű élesztők magasabb (16-20 °C) az alsóerjesztésűek alacsonyabb (8-12 °C) hőmérsékleten tudnak megfelelően erjeszteni (Deák et al., 2006).

Az élesztősejt alakja gömbölyded, tojásdad, vagy megnyújtott ellipszoid alakú. A sejt előfordulhat egyesével, párosan, olykor rövid láncként vagy csomókban. Mérete változó, általában körülményektől, kortól, növekedési stádiumtól függ. A sörélesztő aszexuálisan, sarjadzással szaporodik, így mikroszkópban gyakran a képződő sarjjal (bimbó) együtt figyelhető meg.


2.1.3. A sörélesztő szerepe az erjesztésben

Az erjesztési folyamat elején a sörlévet élesztővel beoltják, melynek mennyisége általában a sörlé kiindulási extrakttartalmától, a sör receptúrájától és az élesztő típusától, illetve állapotától (sejtszám, életképesség) függ. Az élesztő a szaporodási fázis során még 3-4 generációt osztódik, így a sejtszám körülbelül egy nagyságrenddel nő (Deák et al., 2006). Az erjesztés során az erjesztőtank tartalmában bekövetkező változásokat a 2. ábra szemlélteti. Ahogyan az ábrán is látható, a kezdeti szaporodási (exponenciális) fázis után az élesztők mennyisége egy ideig beáll egy viszonylag állandó értékre, majd az erjesztés folyamán, miközben egyre kevesebb az erjeszthető szénhidrát a közegben, az idősebb generációk lesüllyednek a tartály aljára, és szakaszosan eltávolításra kerülnek (élesztőelvétele). Ha nem megfelelő ütemben távolítják el a

kiülepedett élesztőt, a sejtek autolízisbe kezdhetnek, azaz saját magukat kezdik el lebontani, amely kellemetlen ízhibát okoz a sörben.

2. ábra: A sörlé egyes összetevőinek és néhány jellemző paraméter változása a fermentáció során

(Forrás: <http1>, lefordítva)



A sörlében található élesztősejtek vitalitásának rendszeres vizsgálata az erjesztés során segíthet a sejtek szaporodási tevékenységének, illetve erjesztési képességének nyomon követésében. Emellett, mivel az erjesztőtartályból elvett élesztőt általában újból, azaz több erjesztés alkalmával is felhasználják, használat előtt rendkívül fontos az oltóélesztő életképességének vizsgálata is.

Az élesztők életképességének vizsgálatára használt egyik legnépszerűbb módszer a vitális festés, melynek során az élesztősejteket metilénkék festékkel festik meg. A festék a sejtek membránján áthatol és bejutva a citoplazmába és sejszervecskébe, megfesti azokat. A holt sejtek membránja nagy mértékben átengedi a festéket, így a sejtek rövid idő alatt kékre színeződnek. Az élő sejtek citoplazmájába ellenben kevés festék képes bejutni, és az is a dehidrogenáz enzim hatására szintelen leuko-metilénkékké redukálódik, így az élő sejtek átlátszóak maradnak. Az eredeti vitalitásvizsgálat során összesen tíz látótérben számolt élő és holt sejtek százalékos arányszámát kell meghatározni, hogy az a mintára reprezentatív eredményt mutasson (György, 2020). A vitalitás képlete:

$$\text{Vitalitás} = \frac{\text{élő sejtek száma}}{\text{élő sejtek száma} + \text{holt sejtek száma}} * 100 \text{ [\%]}$$

Kucharczyk et al. (2025) kutatásaik alapján megállapították, hogy az erjesztési folyamatok (pl. fermentációs hőmérséklet, sörlé levegőztetése) optimalizálásával csökkenteni lehetne az

újrahasznosítandó oltóélesztő holt sejt-arányát, amely hozzájárulna a fermentáció sikerességéhez. Bottari et al. (2014) szerint pedig a kisüzemi sörfőzdek folyamatszabványosításának kulcsa az élesztők életképességének periodikus vizsgálatában rejlik, mivel egy élesztőkezelési (yeast management) program létrehozásával garantálható lenne a kisüzemekre jellemző változatos termelés minőségének biztosítása.

Véleményem szerint a felhasznált sörélesztő állapotának pontos ismerete nem csak a gyártási folyamatok optimalizálásában és a sörhibák kialakulásának megelőzésében, hanem a termékfejlesztésben is nagy segítséget nyújthat. Adott élesztőtörzs életképességének vizsgálata a főzési folyamat és az élesztő-újrahasználás során segíthet kiszűrni a gyengén teljesítő törzseket, illetve precízen meghatározni az élesztő viselkedését (szaporodási sebesség, stresszhatárok, flokkulációs képesség), így segítve az adott recepthez legjobban illő törzs kiválasztását. Illetve később, ha már elegendő historikus adat áll rendelkezésre, létrehozhatóak olyan adatalapú döntéshozatali rendszerek, amelyek segíthetnek optimalizálni az erjesztési folyamatokat, ezzel segítve a vállalat költségeinek visszafogását.

2.2. Képfeldolgozás és mesterséges intelligencia

A következő részben bemutatom a képfeldolgozás elméleti hátterét és általános menetét, majd a mesterséges intelligencia definícióját és területeit, végül pedig a konvolúciós neurális hálózatok működésének elvét.

2.2.1. A képfeldolgozás elméleti háttere

A számítógép számára a kép egy numerikus pixelérték tömbje. Minden pixel egy számszerű értéket tartalmaz, amely a szürkeárnyalatot (grayscale), vagy színes kép esetében az intenzitásokat (RGB értékeket) reprezentálja. A digitális képet tehát egy mátrixként írhatjuk le matematikailag. A képfeldolgozás célja ezen mátrixok átalakítása, elemzése és értelmezése.

Egy fekete-fehér (grayscale) kép esetében a pixelek értékei egyetlen kétdimenziós mátrixban jelennek meg, amelynek mérete a kép szélessége és magassága (felbontása). A mátrix elemei ebben az esetben diszkrét értékek, általában 0 (fekete) és 255 (fehér) közötti egész számok.

A színes képek általában az RGB (Red, Green, Blue) színmodell alapján írhatók le. A színes kép három darab, egymással párhuzamos kétdimenziós mátrixból áll, amelyek a vörös, zöld és kék csatornákat reprezentálják. Így egy háromdimenziós tenzor jön létre, melynek dimenziói: magasság x szélesség x csatornák. Minden pixel egy háromdimenziós vektorként is felfogható, amely a három színek komponensét tartalmazza (pl. [125, 200, 80]) (Gonzalez és Woods, 2018).

A képek további feldolgozása során gyakran alkalmaznak normalizálást, ahol a pixelek értékeit a [0,1] tartományba transzformálják a számítások egyszerűsítése és a neurális hálók stabilabb

tanulása érdekében. A képek átalakítására úgynevezett maszkokat használnak, amelyek olyan mátrixokat jelentenek, melyeket a kép felett eltolva különböző transzformációk hajthatók végre a kiindulási képen.

A hagyományos képfeldolgozás első lépése az előfeldolgozás, melynek célja a nyers kép minőségének javítása. Módszerei például a zajcsökkentés- vagy szűrés Gauss szűrővel, kontrasztfokozás hisztogramkiegyenlítéssel, vagy színnormalizálás. A második lépés a szegmentálás, azaz a kép kisebb részekre való bontása, például objektumok háttértől való elkülönítésének céljából. Ennek eszközei lehetnek a küszöbölés, élkeresés, régiónövelés stb. A harmadik lépésben történik meg a jellemzők kinyerése, melynek során textúra- alak- vagy színjellemzőket nyerünk ki a képből, a negyedik lépésben pedig ezen kinyert jellemzők alapján történik az osztályozás és felismerés. Képfeldolgozásra manapság egyre több területen alkalmaznak mesterséges intelligenciát, illetve konvolúciós neurális hálózatokat. Ezek a technológiák a következő alfejezetekben kerülnek bemutatásra.

2.2.2. A mesterséges intelligencia fejlődése és területei

A mesterséges intelligencia (MI) a számítástechnika egy olyan kutatási és alkalmazási területe, amelynek célja az emberi intelligenciához hasonló kognitív funkciók gépi modellezése. Ilyen funkciók például a tanulás, problémamegoldás, érvelés, nyelvfeldolgozás és vizuális érzékelés. A fogalom megszületése az 1950-es évekre vezethető vissza, amikor a híres kérdés megfogalmazódott: „Tudnak-e gondolkodni a gépek?” (Turing, 1950).

A gépi tanulás megjelenése az 1980-as évekre tehető, amikor a számítástechnika teljesítményének növekedése lehetővé tette az adatvezérelt megközelítésen alapuló rendszerek létrehozását. A gépi tanulás (machine learning, ML) lényege, hogy a rendszer nem előre beprogramozott szabályokból, hanem példákból és adatokból tanul és tapasztalatok alapján javítja a teljesítményét (Chaturvedi et al., 2024). A gépi tanulás főbb típusai a következők:

- *felügyelt tanulás (supervised learning)*: itt a modell előre címkézett adatokból tanul
- *felügyelet nélküli tanulás (unsupervised learning)*: a modell ebben az esetben címkék nélkül keres mintázatokat és csoportokat
- *mege erősítéses tanulás (reinforcement training)*: ekkor az algoritmus próbálkozások, hibák, illetve visszajelzések útján tanul optimális döntéseket hozni

A neurális hálók (Artificial Neural Networks, ANN) koncepciója az emberi agy idegsejtjeinek működéséből merített inspirációt. Ezek olyan számítási modellek, amelyek csomópontokból (neuronok) állnak és képesek komplex mintázatok felismerésére. Az egyik legjelentősegteljesebb eredménynek a backpropagation (visszaszorító) algoritmus

létrehozása tekinthető 1986-ban, amely lehetővé tette a több rétegből álló neurális hálókat hatékony tanítását (Rumelhart et al., 1986).

A 2010-es évektől kezdve a mélytanulás (deep learning) vált a mesterséges intelligencia meghatározó paradigmájává. A mélytanulás a gépi tanulás speciális ága, amely többrétegű (mély) neurális hálózatokkal dolgozik, és igen hatékony kép- és beszéd felismerésben, illetve természetes nyelvfeldolgozásban. A mélytanulás egyik architektúrája, a konvolúciós neurális hálózat (convolutional neural network, CNN), amely a képfeldolgozásban különösen sikeres, mivel képes automatikusan megtanulni a képi jellemzőket konvolúciós rétegek segítségével.

Az utóbbi évek egyik legnagyobb fejleménye a nagyméretű nyelvi modellek (large language model, LLM) térnyerése. Az LLM-ek olyan modellek, amelyek hatalmas szöveges adatokon tanulva képesek összefüggő szövegek generálására, értelmezésére és különböző nyelvi feladatok megoldására. Ide tartoznak például a GPT, a BERT vagy a LLaMA modellek.

2.2.3. A konvolúciós neurális hálózatok és a képfeldolgozás kapcsolata

A konvolúciós hálózatok (továbbiakban: CNN) csomópontrétegekből állnak. Az egyes csomópontok össze vannak kötve egymással és mindegyikhez tartozik egy súly (weight) és küszöbérték (threshold). Amikor egy csomópont kimenete meghaladja a megadott küszöbértéket, aktiválódik és adatokat küld a hálózat következő rétegének.

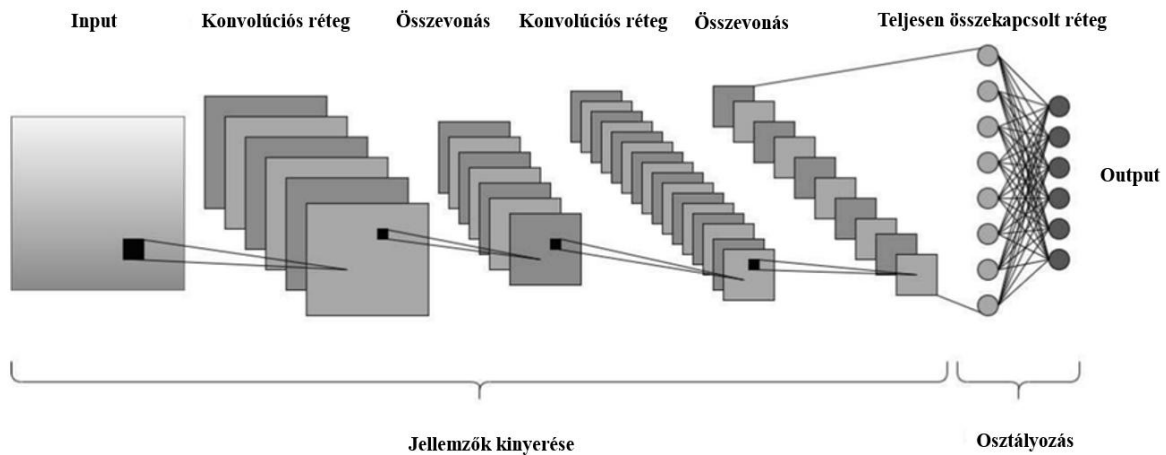
A konvolúciós hálózatok négy fajta rétegből állnak:

- *Bemeneti réteg (input layer):* A kép pixelértékeit tartalmazza.
- *Konvolúciós réteg (convolutional layer):* A képen szűrőket (kernels), azaz kis súlyú mátrixokat (small weight matrices) futtat végig, melynek segítségével különböző jellemzőket (pl. élek, sarkok, textúrák) nyer ki az adott képből. Minden szűrő létrehoz egy jellemzőtérképet (feature map), amely kiemeli az adott jellemzőt. A jellemzők között általában hierarchikus viszony van.
- *Összevonó rétegek (pooling layers):* Csökkentik a jellemzőtérképek méretét, a lényegtelen információk elvetésével. Így csökken a feldolgozandó adatok mennyisége, és a számítási komplexitás, miközben megmaradnak a feldolgozás szempontjából lényeges információk.
- *Teljesen összekapcsolt réteg (fully connected layer):* Ez köti össze az összes neuront, vagyis ez a réteg kombinálja a kinyert jellemzőket egy adott objektum azonosításához a vizsgált képen (O'Shea és Nash, 2015; http2).

A CNN-ek felépítését és a rétegek kapcsolatát a 3. ábra szemlélteti:

3. ábra: A konvolúciós neurális hálózatok felépítése

(Forrás: Yasavoli et al., (2025) lefordítva)



2.3. Korábbi kutatások az élesztősejtek képfeldolgozásos vizsgálatában

Az elmúlt években egyre népszerűbb kutatási témává vált főként az orvostudomány és biotechnológia területén a különböző sejtekről készült mikroszkópos képek mesterséges intelligenciával történő kiértékelése (Chai et al., 2024). Hasonló kutatások léteznek már élesztősejtek morfológiai vizsgálatára, számlálására és vitalitásának meghatározására is.

A hagyományos élesztősejt-számolási módszerek közé tartozik a Bürker-kamrás sejtszámlálás, a leoltásos (telepképző egység, TKE) módszer, és a laboratóriumok által gyakran alkalmazott áramlásos citometria. Az életképesség vizsgálatának leggyakoribb módszere pedig a vitális festések (pl. metilénkék festék) alkalmazása. A hagyományos metilénkék-festés, habár olcsó és egyszerű módszer, kiértékelésének eredményei sokszor megbízhatatlanok az emberi szubjektivitás miatt (Boyd et al., 2003).

A képalapú sejtszámlálás- és vitalitásvizsgálatokon alapuló kutatások egyik legnépszerűbb irányzata jelenleg a sejtek fluoreszcens festése után készült képek feldolgozása (Saldi et al., 2014; Atanasova et al., 2019; Hong et al., 2013). A módszer során a sejteket először megfestik fluoreszcens festékkel (pl. akridin narancs és propidium-jodid, vagy fluoreszcein-diacetát), amely csak a halott sejtekbe képes behatolni, majd a megfelelő körülmények között készült mikroszkópos képeket dolgozzák fel különböző módszerekkel. Haja et al. (2021) például mesterséges intelligenciát használtak egy teljesen automatizált élesztővizsgálati folyamat kidolgozásához, biológiai kutatások megkönnyítésére. A programhoz mélytanulós módszereket, azaz CNN-t, és a YOLOv4 objektumdetektálási modellt használták. Több kutatás azonban a hagyományos mikroszkópos fénykép (bright field) és fluoreszcens módszer kombinációját alkalmazza a sejtek vizsgálatára (http3; Hong et al., 2013). Hong et al. (2013) szerint a hagyományos képek azért szükségesek a fluoreszcens vizsgálat kiegészítésére, hogy a

sejtek méretének számítását is lehetővé tegyék, ugyanis a pusztán fluoreszkáló sejtek méretének érzékelése mindig adott megvilágítástól függ, így eredménye nem megbízható. A fluoreszcens festés és kimutatása hatékonynak bizonyul, ugyanakkor gyártásközi vizsgálatokban ritkán alkalmazható, mivel ezek a festékek jóval drágábbak a hagyományos festékeknél (pl. metilénkék), nem mellesleg egyes fajtáik (pl. propidium-jodid) karcinogén hatásúak, ezért ételkészítéskor való használatuk igen kockázatos (Thomson et al., 2015). Emiatt több kutatás csak a „hagyományos” mikroszkópos képek feldolgozását vizsgálja.

Hayashi et al. (2023) a mesterséges intelligencia alkalmazásának szükségességét vizsgálták sarjdzó élesztősejtek képalapú felismeréséhez. A kutatás során kiderült, hogy CNN-ek alkalmazásával nagyságrendileg jobb eredményt lehet elérni a hagyományos gépi tanulás felhasználásával szemben. Egy másik kutatás során, szintén sarjdzó sejtek felismerésére használtak konvolúciós neurális hálózatokat az áramlásos citometria vizsgálatok javítására (Han et al., 2025).

Több kutatási projekt fókuszál hordozható élesztőfelismerő rendszerek kialakítására. Kutatók olyan holografikus (lencse nélküli) hordozható eszközt hoztak létre, amely gépi tanulást alkalmazva pillanatok alatt ad visszajelzést a sejtek vitalitásáról (Feizi et al., 2017). Egy 2025-ös projekt során pedig egy olyan hordozható, okostelefonnal összekötött mikroszkóp-rendszert dolgoztak ki, amely mélytanulással lehetővé teszi a sejtek mobilis vizsgálatát (Wang et al., 2025).

Ahogy ezek a kutatások is mutatják, ez egy gyorsan fejlődő, és sokféle képfeldolgozási módszerrel megközelíthető terület, amelynek fejlesztésére nagy igény mutatkozik az alkoholos ital gyártás, bioetanol előállítás, és mikrobiológiai laborvizsgálatok oldaláról is. Az általam vizsgált cikkek alapján kutatásomban én is CNN-en alapuló képfeldolgozó modell létrehozása mellett döntöttem.

2.4. No-coding képfeldolgozó eszközök és alkalmasságuk vizsgálata

Az általam vizsgált képfeldolgozási probléma megoldására kódolást nem igénylő, azaz úgynevezett no-coding képfeldolgozó eszközt szerettem volna felhasználni. Ennek oka, hogy meg szerettem volna vizsgálni, hogy egy élelmiszeripari kis- vagy középvállalkozás a saját problémájának orvosolására képes lenne-e (komolyabb programozói háttér nélkül) prototípust, vagy akár kész megoldást fejleszteni. Véleményem szerint az élelmiszeripar számos területén lehetne alkalmazni ezeket a személyre szabható és rugalmasan skálázható eszközöket, támogatva ezzel a cégek kutatás-fejlesztési tevékenységeit. Ilyen területek például a minőségbiztosítási laborvizsgálatokban a mikrobiológiai módszerek kiértékelésének

digitalizálása, a minőség-ellenőrzés során a termékek felületi hibáinak, elszíneződésének vagy idegen anyagok jelenlétének azonosítása, illetve csomagolások minőségének (esetleg címkéinek és kódjainak) ellenőrzése. Emellett a saját projektemhez is szerettem volna kiválasztani a feladatra legmegfelelőbbnek ígérkező eszközt az alábbiakban bemutatott, piacon elérhető szolgáltatások közül.

- **Google Teachable Machine**

A Teachable Machine a Google kísérleti no-code platformja, amely képek, hangok vagy „pózatok” alapján tanít be egyszerű neurális hálózatokat. A platform gyors, és teljesen ingyenes, a kész eredmény pedig exportálható TensorFlow Lite vagy TensorFlow.js formátumban ([http4](#)). Az élesztősejtek felismerésére azonban számomra nem alkalmas, mivel csak képosztályozás (image classification) típusú problémák megoldása lehetséges vele, azaz nem képes egy képen többféle objektum egyidejű felismerésére (object detection). Alkalmas lehet azonban gyártósoron különböző terméktípusok osztályozására, illetve hibás termékek vagy sérült csomagolások megkülönböztetésére.

- **Microsoft Custom Vision (Azure Cognitive Services)**

A Custom Vision az Azure Cognitive Services-hez tartozik, és egy fejlett, de felhasználóbarát felületet biztosít képosztályozó, illetve objektumfelismerő modellek tréningjéhez egyaránt. A modell integrálható más Azure vagy Microsoft szolgáltatásokkal (IoT Hub, SQL Database, Power BI), amely segíti a felhasználáshoz szükséges infrastruktúra kiépítését ([http5](#)). Hátránya azonban, hogy a tréning és a predikció is pénzbe kerül, kivéve, ha rendelkezünk Azure Free fiókkal. Azonban az egy hónapos lejáratú idő mellett az ingyenes fiók felhasználásának is megvannak a modellépítési korlátai, amelyet később részletesen ismertetni fogok az *Alkalmazott módszerek* részben.

- **Microsoft Power Apps – AI Builder**

A Power Apps AI Builder egy olyan low-code környezet, amely lehetővé teszi, hogy a felhasználók mesterséges intelligencia-komponenseket illesszenek az üzleti alkalmazásaikhoz. Itt nem csak képfeldolgozási modellek (szövegkinyerés, képleírás, objektumfelismerés) találhatók, hanem főként különböző dokumentumfeldolgozó, szövegértelmező- és információkinyerő funkciókat kínál a platform a felhasználók számára. Jól integrálható a Power Platform ökoszisztémába (Power BI, Power Automate, Dataverse), viszont a tanítás és használat csak Power Platform licenccel lehetséges, illetve a finomhangolás és a predikciós pontosság is korlátozottabb, mint például a Custom Vision platformon ([http6](#)).

▪ **Lobe (Microsoft)**

A Lobe egy olyan no-code képfeldolgozó applikáció, ami kifejezetten objektumdetektálási és képosztályozási feladatokra készült. Offline fut, és ingyenes, illetve a modell exportálható többféle (pl. TensorFlow) formátumban is. Hátránya viszont, hogy nem skálázható, azaz nagyobb adatbázissal nem lehet feltanítani, emellett a modellek finomhangolása sem szabályozható ([http7](http://7)).

▪ **Roboflow**

A Roboflow igen fejlett, de továbbra is no-code vagy low-code megoldást nyújt objektumfelismerési, vagy képszegmentálási feladatokhoz. A platformon van kivonatoló (annotation) és adatnövelő (augmentation) felület is, így a képek előkészítését és feltanítását egy helyen el lehet végezni. A nagyobb adatbázisok és a felhőalapú tréningek pénzbe kerülnek, valamint a képfeldolgozási folyamat valamennyivel összetettebb lehet, mint az egyszerűbb no-code modelleké ([http8](http://8)).

A fentiek alapján a Custom Vision és a Roboflow platformokat találtam a legalkalmasabbnak a feladatra, mivel képesek az objektumdetektálásra, emellett kellően fejlettek ahhoz, hogy a nehezebben feldolgozható adatok (sűrű, nehezen kivehető sejtek) ne okozzanak problémát számukra. A Roboflow egyik erőssége az adatelőkészítésben és növelésben rejlik, amely nagyon hasznos funkció, de a projekt számára fontosabb volt, hogy a platform egy nagyobb, felhőalapú ökoszisztéma része legyen, így végül a Custom Visiont használtam az objektumdetektálási modell létrehozásához.

2.5. A felhőalapú számítástechnika

Az adatalapú döntéshozatali rendszerek létrehozásához elengedhetetlen a nagy mennyiségű adat tárolása, feldolgozása és valós idejű megjelenítése. Az élelmiszeriparban, ahol a keletkező adatok és feldolgozásuk jellege rendkívül változatos lehet, véleményem szerint a felhőszolgáltatások igénybevétele nyújthatja a legrugalmasabb megoldást. Ebben a részben szeretném tehát bemutatni a felhőalapú számítástechnika fogalmát, főbb tulajdonságait és típusait, illetve a vállalatok számára mérlegelendő előnyöket és hátrányokat.

2.5.1. A felhőalapú számítástechnika definíciója és főbb tulajdonságai

A felhőalapú számítástechnika (Cloud Computing) legfrissebb és legpontosabb definícióját 2011-ben az Amerikai Egyesült Államok Nemzeti Szabványosítási és Technológiai Intézete (NIST, National Institute of Standards and Technology) határozta meg. Ezen standard definíció szerint a felhőalapú számítástechnika egy olyan modell, amely lehetővé teszi az elérhető, kényelmes, igény szerinti hálózati hozzáférést egy megosztott, testre szabható számítási

erőforrás-készlethez (például hálózatokhoz, szoftverekhez, tárhelyekhez, alkalmazásokhoz és szolgáltatásokhoz), amelyek gyorsan rendelkezésre bocsáthatók és felszabadíthatók, minimális menedzsment-ráfordítással vagy a szolgáltatóval való interakcióval (Mell és Grance, 2011).

Mell és Grance (2011) szerint a technológia öt alappilléren nyugszik:

- *Igény szerinti és önkiszolgáló:* A felhasználó közvetlenül, egyoldalúan igényelhet szolgáltatásokat, melyek automatikusan, emberrel való kapcsolatba lépés nélkül rendelkezésre állnak.
- *Széles hálózati hozzáférés:* A szolgáltatások a hálózaton keresztül, általános mechanizmusok által elérhetőek, így bármilyen kliens platformról (pl. mobiltelefon, táblagép, laptop stb.) hozzáférhetőek.
- *Erőforrás-összevonás:* A szolgáltatók erőforrásait (pl. tárolás, feldolgozás, hálózati sávszélesség) összevonják úgy, hogy különböző fizikai és virtuális erőforrásokat dinamikusan rendelik hozzá az adott felhasználói problémához. A felhasználónak nincs tudomása ezekről a pontos folyamatokról, így legfeljebb a számítás fizikai helyszínét (ország, állam vagy adatközpont) tudja beállítani.
- *Gyors és rugalmas:* Az erőforrásokat a szolgáltatók (sokszor automatizáltan) rugalmasan biztosítják, felszabadítják vagy méretezik az éppen aktuális kereslethez igazítva, így azok a fogyasztók számára korlátlanul rendelkezésre állnak.
- *Mérhető szolgáltatások:* Az erőforrás-optimalizálás érdekében a felhőalapú rendszerek automatikusan szabályozzák és optimalizálják az erőforrásokat és szolgáltatásokat, melyek mérhetőek és nyomon követhetőek, ezzel biztosítva az átláthatóságot a felhasználók és szolgáltatók számára.

2.5.2. Felhőszámítási architektúrák

A felhőalapú szolgáltatások egyik osztályozási módja a felhasználási körökön alapuló csoportosítás. Ez alapján négy nagy csoportra oszthatjuk a felhőszolgáltatási modelleket: nyilvános-, privát-, hibrid- és közösségi felhő (Magoulés et al., 2013).

- *Nyilvános felhő (Public cloud):* A felhőalapú számítástechnika „alapértelmezett” esete, amelyben a szolgáltató az interneten keresztül tesz elérhetővé erőforrásokat (pl. alkalmazások, tárhely) a nyilvánosság számára. (pl. Microsoft Azure, Amazon Web Services)
- *Privát felhő (Private cloud):* Egy saját tulajdonú számítástechnikai létesítményt jelent, amely korlátozott számú felhasználó számára nyújt szolgáltatásokat belső hálózatokon. Olyan szervezetek részesítik előnyben, amelyek pontos ellenőrzést szeretnének végezni

az adataik felett, így a nyilvános felhő előnyeit (skálázhatóság, mérhetőség, rugalmasság) élvezhetik anélkül, hogy átengednék az irányítást, a biztonságot és a folyamatos költségeket egy külső szolgáltatónak. (pl. Microsoft Azure Stack, OpenStack)

- *Hibrid felhő (Hybrid cloud)*: Nyilvános-, privát- és akár helyi infrastruktúrák kombinációját használja, így nem véletlenül örvend a legnagyobb népszerűségnek a felhőalapú létesítmények között. A hibrid felhő lényege, hogy a munkaterheléseket a költségek, üzemeltetési- és megfelelési tényezők figyelembevételével helyezi el. (pl. Microsoft Azure Arc, IBM Hybrid Cloud)
- *Közösségi felhő (Community cloud)*: Olyan infrastruktúrát jelent, amelyet egy adott közösség több szervezete oszt meg. Ezek a szervezetek általában hasonló célokat, biztonsági követelményeket, szabályozási elveket és megfelelési szempontokat tartanak szem előtt. (pl. Microsoft Government Community Cloud, European Open Science Cloud)

2.5.3. Felhőszolgáltatási modellek összehasonlítása

Ahhoz, hogy értelmezni tudjuk a felhőszolgáltatási modelleket, először fontos tisztában lennünk a felhő-infrastruktúra fogalmával. A felhő-infrastruktúra olyan hardverek és szoftverek gyűjteménye, amelyek lehetővé teszik a felhőalapú számítástechnika (korábban említett) öt alappilléreinek, jellemzőjének megvalósulását. Ez magában foglal egy fizikai és egy úgynevezett absztrakciós réteget is. A fizikai réteg azokból a hardver erőforrásokból áll, amelyek szükségesek a nyújtott szolgáltatások támogatásához, és jellemzően tartalmazza a szerver-, tároló- és hálózati komponenseket. Az absztrakciós réteg a fizikai rétegre telepített szoftverekből áll, amelyek megvalósítják a felhő alapvető jellemzőit.

Háromféle felhőszolgáltatási modell létezik, attól függően, hogy milyen szolgáltatást nyújt az adott felhőalapú modell a felhasználó számára (Mell és Grance, 2011):

- *Szoftver, mint szolgáltatás (Software as a Service, SaaS)*: A felhasználó a szolgáltató azon alkalmazásait használja, amelyek a felhő-infrastruktúrán futnak. Ezek az alkalmazások különböző klienseszközökről érhetők el, például webböngészőn vagy programozási interfészen keresztül. Itt a felhasználó nem kezeli és nem is irányítja a felhő-infrastruktúrát (hálózat, szerverek, operációs rendszerek, tárolók stb.), csak néhány alkalmazáskonfigurációs beállításhoz van hozzáférése. (pl. Microsoft 365, Google Workspace)

- *Platform, mint szolgáltatás (Platform as a Service, PaaS)*: Itt a felhasználó a felhő-infrastruktúrára saját maga által fejlesztett vagy megszerzett alkalmazásokat telepíthet, amelyeket a szolgáltató által támogatott programozási nyelvek, könyvtárak, szolgáltatások és eszközök segítségével hoztak létre. A felhasználó a SaaS-hoz hasonlóan itt sem kezelheti az alapul szolgáló felhő-infrastruktúrát, ellenben irányíthatja a telepített alkalmazásokat, illetve az alkalmazások környezetének konfigurációs beállításait. (pl. Microsoft Azure App Service, Google App Engine)
- *Infrastruktúra, mint szolgáltatás (Infrastructure as a Service, IaaS)*: A felhasználó feldolgozási kapacitást, tárhelyet, hálózatot és egyéb alapvető számítási erőforrásokat hozhat létre, ahol tetszőleges szoftvereket futtathat, beleértve operációs rendszereket és alkalmazásokat. Ugyan itt sem kezelheti az alapot képző felhő-infrastruktúrát, de irányíthatja az operációs rendszereket, a tárolókat és a telepített alkalmazásokat, illetve bizonyos mértékig kezelhet egyes hálózati komponenseket, például tűzfalakat. (pl. Microsoft Azure Virtual Machines, Google Compute Engine)

2.5.4. A felhőalapú számítástechnika előnyei és nehézségei

Mielőtt egy vállalkozás a felhő alkalmazása mellett dönt, a tervezés első szakaszában fontos mérlegelnie a technológia előnyeit és hátrányait:

A felhőalapú technológiák előnyei

Egwutuoha et al. (2013) munkája alapján a felhőalapú szolgáltatások legfőbb előnyeként három tényezőt szeretnék kiemelni:

- *Költségcsökkentés és rugalmas pénzügyi modell*: A felhőszolgáltatások lehetővé teszik, hogy a vállalkozások kis tőkével is működésbe léphessenek, mivel nem szükséges nagy kezdeti beruházás hardverbe és infrastruktúrába, mert az erőforrások bérlet alapján, rugalmasan változnak.
- *Skálázhatóság és rugalmasság*: A felhőben könnyen hozhatók létre vagy szüntethetők meg erőforrások a változó igényeknek megfelelően, legyen szó csúcsterhelésről vagy méretezési igényről.
- *Magas rendelkezésre állás és hozzáférhetőség*: Mivel egy szolgáltató általában több földrajzi területen is rendelkezik adatközponttal, biztosítani tudja szolgáltatásainak állandó rendelkezésre állását. Az internet segítségével pedig a felhőszolgáltatások szinte bármilyen eszközről (okostelefon, táblagép, számítógép) elérhetők.

A technológia hátrányai

Mivel ez egy viszonylag új és gyorsan fejlődő technológia, sok nehézség, megoldandó probléma áll még a fejlesztők előtt. A pozitív tulajdonságok ismertetése mellett tehát fontos kitérni a felhőszolgáltatások hátrányaira is. A technológia hátulütőit négy fő részre bontottam:

- *Adatbiztonsági kockázatok:* A felhőalapú technológiák hátrányairól szinte mindenkinek az adatvédelemmel kapcsolatos aggályok jutnak eszébe először. Mivel ezekben a rendszerekben az érzékeny vállalati adatok harmadik fél kezébe kerülnek, ez bizalmi, jogi és szabályozási problémákat okozhat. Az infrastruktúra sebezhetősége helytelen konfigurációkból, nem biztonságos API-k használatából, jogosulatlan hozzáférésekből, és belső (insider) támadásokból adódhat (Fernandes et al., 2014). Az adatvédelmi problémák tekintetében jelenleg a jogi szabályozás nehézségei is közrejátszanak, ugyanis az adatok országok között mozognak, így kezelésükre nehéz egységes, univerzális jogszabályokat bevezetni.
- *Technikai és működési akadályok:* A felhőszolgáltatások technológiai összetettsége számos működési problémát vethet fel. Az együttműködés (interoperabilitás) és a szolgáltatók közötti átjárhatóság hiánya megnehezíthetik a rendszerek integrálását, így a szolgáltatói függőség hosszú távon korlátozhatja a rugalmasságot. A hálózati késleltetés, a sávszélesség és az elérhetőségi hibák tovább növelhetik az üzemi kockázatokat (Armbrust et al., 2010).
- *Gazdasági és költségvetési kérdések:* Bár a felhőalapú modellek kezdetben költséghatékonyak, a hosszú távú működés során a használat alapú díjazás (pl. Azure: Pay-as-you-go) miatt nehezen tervezhetők. A tárolás, adatforgalom és API-hívások után fizetett díjak gyorsan növekedhetnek, különösen nagy adatmennyiség esetén, ezért a felhő gazdasági előnye csak megfelelően optimalizált használat mellett érvényesülhet.
- *Környezeti hatások:* A felhőalapú infrastruktúra működtetése jelentős energia- és vízfelhasználással jár. Az adatközpontok folyamatos hűtése és energiaellátása növeli a szén-dioxid-kibocsátást, így hozzájárul a klímaváltozáshoz. Emellett az eszközök gyártása és leselejtezése növeli az elektronikai hulladék mennyiségét. A fenntartható adatközpontok és a megújuló energiaforrások használata csökkentheti, de nem szünteti meg teljesen a környezeti hatásokat (Silvis, 2024).

2.6. A felhőalapú számítástechnika jelenlegi trendjei a magyar kis- és középvállalkozások körében


A felhőalapú számítástechnika gyors tempóban, napról-napra fejlődik, mivel egyre több vállalat ismeri fel az általa kínált szolgáltatások versenyképességnövelő hatását. A jövőben megjelenő újdonságokat tehát nagyban fogják befolyásolni a vállalkozások által támasztott igények és elvárások.

Hazánkban a felhőalapú szolgáltatások bevezetését elsődlegesen hátráltató tényezők közé sorolható a dolgozók bizalmatlansága, az adatvédelmi aggályok, illetve a felhasználói ismeretek elégtelensége, vagy teljes hiánya. Szerencsére ez a trend enyhülni látszik, mivel napjainkban egyre több a magánfelhasználók körében elterjedt felhőszolgáltatás, mint például a fájlok tárolása (Nagy-Borsy, 2020).

A 4. ábrán látható, hogy az Európai Bizottság által évente közzétett Digitális Gazdaság és Társadalom Index szerint, mely az uniós tagállamok digitális felkészültségét monitorozza 2014 óta, Magyarország kis- és középvállalkozási szektorában (a pénzügyi szektor nélkül) a vállalkozások 36%-a használt felhőszolgáltatásokat 2023-ban (http9). Ez csak két százalékkal kevesebb, mint az uniós átlag ugyanebben az évben, illetve pont a fele a legfejlettebbnek mutató Finnország mutatójának.

4. ábra: Felhőszolgáltatások használata az európai kkv-szektorban (2023)

(Forrás: http9)

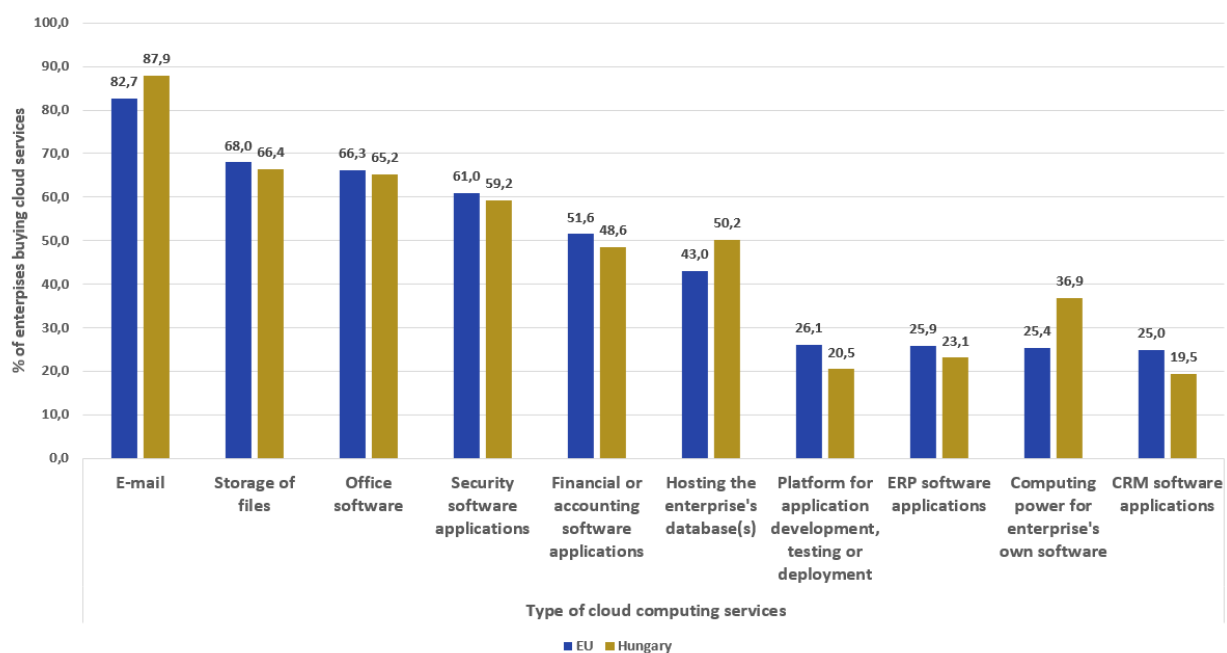


Ahogy az 5. ábra is szemlélteti, az Eurostat 2023 évi kimutatásából megállapítható, hogy Magyarország három felhőszolgáltatási területen, név szerint az email szolgáltatásokban, a vállalati adatbázisok tárolásában és a számítási kapacitás igénybevételében múlja felül az uniós

átlagot. A legtöbb vizsgált alkalmazási területen (fájlok tárolása, irodai szoftverek, biztonsági szoftveralkalmazások, pénzügyi vagy könyvelési szoftveralkalmazások, ERP rendszerek) maximum 2,8%-os lemaradás tapasztalható az európai átlagtól, míg a legnagyobb (5,5 és 5,6 százalékos) elmaradás az alkalmazásfejlesztési-, tesztelési- és telepítési platformok, illetve a CRM (Customer Relationship Management, azaz ügyfélkapcsolat-kezelő) szoftverek felhasználásánál érzékelhető. Megállapítható, hogy Magyarországon még mindig inkább az egyszerű, „alap” felhőszolgáltatások örvendenek nagyobb népszerűségnek (email szolgáltatások, fájlok tárolása, irodai szoftverek, biztonsági szoftveralkalmazások). A vállalkozások közel fele használ pénzügyi, könyvelési vagy adatbázistároló felhőalapú technológiákat, míg szinte csak minden ötödik vállalat alkalmaz CRM szoftvereket, vagy fejleszt felhőalapú alkalmazásokat (http10).

5. ábra: Felhőalapú szolgáltatások használata a magyar és európai kkv-szektorban (2023)

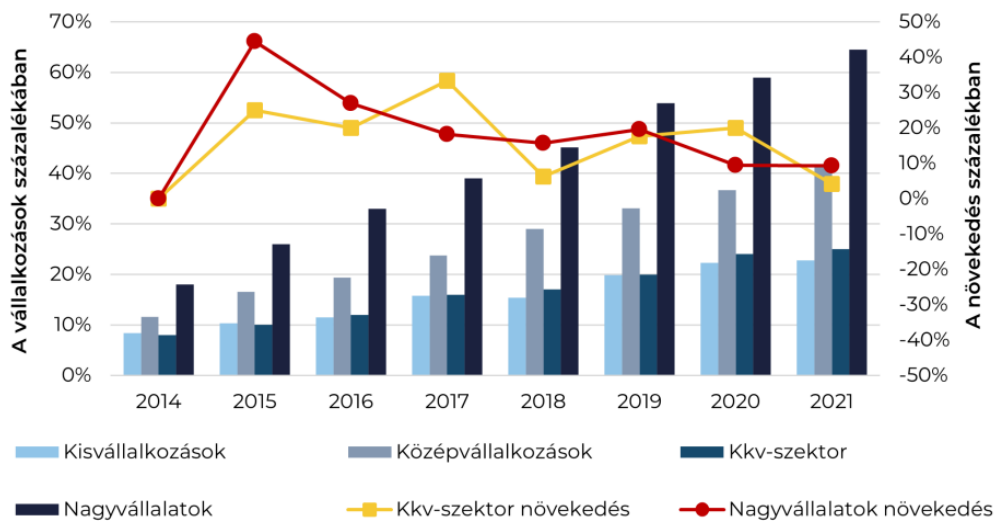
(Forrás: http10)



Ahogy a 6. ábra is mutatja, hazánkban a felhőalapú számítástechnika felhasználásának mértékében a kis- és középvállalkozások sektora jelentősen lemaradt a nagyvállalatokétól. Ez a jelenség Nagy-Borsy (2023) szerint részben a nagyvállalatok dolgozói létszámából, illetve gazdasági működéséből fakadhat, és habár a felhőtechnológiák kínálta előnyök nagyban illeszkednek a kis- és középvállalatok heterogenitásához és változékonyágához, a szektor lemaradása nemcsak hazai, hanem uniós szinten is számottevő.

6. ábra: Felhőszolgáltatások használata a magyar vállalatok körében (2014-2021)

(Forrás: Nagy-Borsy, 2023)



Ezekből az adatokból is látható, hogy a hazai kis- és középvállalkozásoknak még van hova fejlődniük a felhőalapú technológiák alkalmazásában. A felhő által nyújtott rugalmas és skálázható alkalmazások könnyen elérhető megoldásokat kínálhatnak a szektornak, de ennek eléréséhez fontos lépés lenne a felhőszolgáltatások lehetőségeinek megismertetése a szektor vezetőivel és kutatás-fejlesztésért felelős fejlesztőivel.

2.7. Microsoft Azure

A Microsoft Azure a Microsoft felhőplatformja, amely infrastruktúra-, platform- és szolgáltatás-szintű felhőmegoldásokat nyújt. A platform célja, hogy támogatást nyújtson innovatív alkalmazások létrehozásához, szolgáltatások felhőalapú üzemeltetéséhez és skálázásához (http11). Az Azure számos mesterséges intelligencia és gépi tanulás alapú szolgáltatást kínál, melyek több szinten integrálhatók: Az *Azure AI Services*-be előre épített alkalmazásprogramozási felületek (Application Programming Interface, API) tartoznak bele (pl. látás, beszéd, nyelvi, döntési és keresési modellek), amelyek lehetővé teszik, hogy fejlesztők mély szakértelem nélkül is tudjanak képfelismerő, beszédfeldolgozó, fordító stb. modelleket alkalmazni. Az *Azure Machine Learning* egy olyan modellfejlesztési, tanítási és üzembe helyezési környezet, amely támogatja a pipeline alapú folyamatok létrehozását, verziókezelést, és modellek regisztrálását. Az *Azure AI Foundry* célja pedig, hogy intelligens alkalmazásokat lehessen építeni nagyvállalati méretekben, kombinálva az AI Services-t, Machine Learninget és egyéb Azure komponenseket.

Az Azure-t sokféle ipari és kutatási területen alkalmazzák, például web- és alkalmazásszolgáltatások üzemeltetésére, IoT integrációra és adatfeldolgozásra (big data

analitika), intelligens alkalmazások és automatizált feladatok fejlesztésére, üzleti alkalmazások és ERP/CRM integrációra, illetve kutatási és fejlesztési célokra, prototípusok létrehozására.

Ha Azure-ról van szó, az általános felhőszolgáltatási előnyök (skálázhatóság, rugalmasság, magas rendelkezésre állás stb.) mellett pozitívumként a rendkívül széles szolgáltatásportfóliót, a biztonságosságot (a platform sok szabványt támogat), illetve Microsoftos eszközök (pl. Office 365) integrálhatóságát lehet felhozni. Ugyanakkor fontos megemlíteni, hogy a szolgáltatásokban való eligazodás és konfigurációk kezelése bizonyos előképzettséget igényel. Másik negatívum, hogy a komplex árstruktúrák miatt a díjazási modell nehezen átlátható, előrejelezhető, illetve a rosszul méretezett erőforrások vagy inaktív VM-ek (virtual machine, virtuális gép) futtatása nagy költségeket eredményezhet ([http12](http://12)).

3. Alkalmazott módszerek

Ebben a részben szeretném bemutatni a képfeldolgozó rendszer létrehozásához használt anyagokat, eszközöket és módszereket. A 3.1- és 3.2.-es alfejezetben tárgyalt mintavételezés, mintaelőkészítés és a mikroszkópos képek elkészítésének folyamatát a 7. ábra szemlélteti:

7. ábra: A mintavétel, mintaelőkészítés, illetve mikroszkópos képek elkészítésének folyamata, anyagai és eszközei (Forrás: saját munka)



3.1. A sörlesztő-tartalmú minták előkészítése

A mikroszkópos képek elkészítéséhez először ki kellett választanom a célnak megfelelő tulajdonságokkal rendelkező, sörlesztő-tartalmú mintákat. A kiválasztáshoz több szempontot kellett figyelembe vennem. Az egyik legfontosabb az volt, hogy az élő és holt sejtek aránya különböző legyen, ezzel biztosítva a modell feltanításához használt képek sokféleségét. Ez alapján három, különböző erjesztőtartályban erjedő sörléből vett mintát, illetve egy, az erjesztés végén elvett, leülepedett élesztő-szuspenzióból vett mintát választottam. A négy kiválasztott minta tulajdonságait és információit az 1. táblázat tartalmazza:

1. táblázat: A sörlesztő-tartalmú minták tulajdonságai

(Forrás: saját munka)


minta neve	minta jellege	élesztő típusa	erjedés fázisa	hígítás (minta:H ₂ O)	élő sejtek mennyisége
B890	leülepedett élesztő	alsóerjesztésű	erjedés vége	1:14	kevés
B897	sörlé	felsőerjesztésű	8.nap	1:1	körülbelül 50 – 70%
B898	sörlé	alsóerjesztésű	5.nap	1:9	nincs
B905	sörlé	alsóerjesztésű	9.nap	1:2, 1:3, 1:4	körülbelül 25%

Fontos volt még emellett, hogy a sarjadzó sejteket különböző fázisaikban meg tudjam örökíteni, hogy a program fel tudja ismerni őket ilyen formában is. Erre a B890-es minta tökéletes volt. Az alsóerjesztésű mintákban található sejtflokkulációk megörökítése is fontos volt a modell

sejtfelismerési képességeinek növeléséhez. Az alsó- és felsőerjesztésű minták közötti különbség a 8. ábrán jól látható:

8. ábra: A minták sokfélesége: alsóerjesztésű minta sejtflokkulációkkal (B890), illetve felsőerjesztésű minta (B897) (megfestés után)

(Forrás: saját munka)



Mind a négy mintát úgy hígítottam (lásd: 1. táblázat), hogy a róla készült képen a modell számára feldolgozható, de a valós, ipari körülményeknek megfelelően reprodukálható, változatos mennyiségű sejt legyen. A mintavétel és az előkészítés első lépése a 9. ábrán látható:

9. ábra: Mintavételezés, különböző minták és előkészítésük (hígítás)


(Forrás: saját munka)



A kiválasztott minták előkészítése a következő lépésekből állt: adott mintából 1 ml mennyiséget pipetta segítségével, desztillált vízzel megfelelő arányúra (lásd: 1. táblázat) hígítottam 100 ml-es főzőpohárban. Hosszabb kísérletezés után a hígított minták megfestésére azt a módszert találtam a legalkalmasabbnak, hogy a tiszta tárgylemezre 4 csepp (1csepp = 10 μ l) jól összerázott, hígított mintát pipettáztam, majd 1 csepp metilénkék festéket cseppentettem rá. Erre helyeztem rá a fedőlemezt, amelynek használata elengedhetetlen volt, ugyanis segítségével a sejtek jobban elkülönültek egymástól, és a háttér is tisztábbá, kivehetőbbé vált (lásd: 10. ábra).

10. ábra: Festetlen sejtek fedőlemez nélkül, illetve fedőlemezzel

(Forrás: saját munka)



3.2. Mikroszkópos képek elkészítése

A mikroszkópos képek elkészítéséhez VWR (eredetileg: Optika Italy B-293) fénymikroszkópot használtam, melynek képét egy VWR VisiCam HDMI 8 -típusú kamera kiegészítővel digitalizáltam. Ahogyan a *11. ábrán* is látható, a kamera egy HDMI kábelen keresztül volt összekötve a számítógéppel, amelyen a mikroszkópos kamera képét a WaveImage (gyártó: Gfai Tech) szoftverrel jelenítettem meg (verzió: x64, 4.11.19529.20210908).

11. ábra: Az összeszerelt rendszer: mikroszkóp, kamera, laptop és megjelenítő szoftver

(Forrás: saját munka)



A szoftverben valós idejűen, egy nagy keretben jelenik meg a mikroszkóp által készített felvétel. A keret (grid) eredetileg pixelbeosztással rendelkezik, ezért mivel a méreteket milliméterben szerettem volna nyomon követni, a kalibráló tárgylemez segítségével a kameraszoftvert először kalibrálnom kellett.

A korábban (*3.1. fejezetben*) leírt módon előkészített mintát tartalmazó tárgylemezt a mikroszkóp tárgyasztalára helyezve, a következő lépés a képbeállítás volt. A mikroszkóp fényerejét 100%-ra, illetve a WaveImage szoftverben az *Exposure&Gain* fül alatt az exponálást automatikusra állítottam, mert így tudtam elérni, hogy a sejtek a lehető legjobban

elkülönüljenek a háttértől. A fókuszt a képek készítése közben folyamatosan úgy állítottam, hogy a sejtek élesen elkülönüljenek a háttértől, illetve a színük (kék vagy átlátszó) is felismerhető legyen. A képek készítése során viszont figyeltem arra is, hogy legyen néhány „hibás” kép is, melyek nincsenek annyira fókuszbán, vagy nagyobb szennyeződések találhatók rajtuk, ezzel növelve a feltanítási adatok változatosságát. A fenti beállítások után a képeket manuálisan, egyesével mentettem el.

Az adott mintát kétszer vittem fel a tárgylemezre, és minden alkalommal pásztázás közben készítettem 50 db képet 40x-es objektív lencsével és 50 db-ot 10x-es lencsével. Így készítettem összesen $3 \cdot 2 \cdot (50 + 50) = 600$ db képet a megfestett sejtekről, illetve készítettem még 200 db képet 10x-es lencsével megfestett sejtekről Bürker kamrában, a modell jövőbeli továbbfejlesztése céljából. A modellhez végül a 40x-es objektív lencsével készült képeket használtam fel. A mikroszkóp szemlencséjének (okulár) nagyítása 10x-es volt, így a modell összességében 400x-os nagyítású képeken alapult. A képeket kiválogatva 22 db képet homályosság, szennyeződés vagy túl sűrű sejt sokaság miatt alkalmatlannak találtam a modell feltanítására. A maradék 278 képből 30 db-ot (mind a három mintából 10-10 db-ot) félretettem a modell tesztelésére. Így első körben összesen 248 db képet használtam fel a modell feltanítására. Egy későbbi alkalommal készítettem még 419 db képet (a B905-ös minta különböző hígításaiból), melyekből 50 db-ot félretettem tesztelésre. Így a modell végleges verziója $248 + 369 = 617$ db feltanított képen alapult.

3.3. A modell elkészítésének eszköze: Custom Vision

A modell elkészítéséhez a Microsoft Azure felhőalapú szolgáltatásai közül a Custom Vision elnevezésű felületet használtam. Ez a szolgáltatás lehetővé teszi, hogy a felhasználók mélyebb programozási szakértelem nélkül, a saját képi adathalmazukat felhasználva egyedi képfeldolgozási modellt hozzanak létre.


A Microsoft Azure Custom Vision szolgáltatás a felügyelt tanulás (supervised learning) kategóriájába tartozik, ugyanis használatakor a felhasználó feltölt és felcímkéz képeket, majd a rendszer egy konvolúciós neurális hálózat (CNN) segítségével megtanulja a kategóriák közti különbségeket, így később ez alapján képes új, ismeretlen képek elemeit felismerni és besorolni a megfelelő csoportokba. A Custom Vision az Azure AI Services egyik szolgáltatása, amely elsődlegesen Szoftver, mint szolgáltatás (SaaS), mert kész alkalmazásként is használható, ugyanakkor Platform, mint szolgáltatás (PaaS) jelleget is mutat, amikor fejlesztői API (Application Programming Interface) segítségével integrálják más alkalmazásokba.

A szolgáltatás a gyakorlatban két fő funkcióval rendelkezik: *osztályozás (classification)* és *objektumdetektálás (object detection)*. Az osztályozás a teljes képhez rendel hozzá címkét, azaz meghatározza, hogy melyik, felhasználó által előre definiált kategóriába tartozik a vizsgált kép. Az objektumdetektálás kicsit összetettebb funkció, mely során a modell a képen belül adott objektumok helyét és kiterjedését is felismeri, az objektumot kijelölő határolódobozok (bounding box) segítségével. Az általam megoldani kívánt problémára tehát az Azure Custom Vision utóbbi, objektumdetektáló funkciója volt alkalmas.

A modellt a Custom Vision platformon a 12. ábrán látható lépések mentén készítettem el:

12. ábra: Az objektumdetektáló modell elkészítésének folyamata a Custom Vision platformon

(Forrás: saját munka)



A platform használatának előkészületei: A Custom Vision használatához először készítenem kellett egy ingyenes Azure-fiókot (Azure free account), amellyel 200 dollárnyi kredithez és rengeteg ingyenes szolgáltatáshoz juthattam hozzá az Azure platformon belül, egy hónapon keresztül. Erre az előfizetésre azért is volt szükség, hogy hozzá tudjam rendelni a projektemhez az erőforrásokat, amelyek a modell működéséhez szükségesek. Az Azure free account használatával a Custom Visionon belül két darab projekt hozható létre. Projektenként 5000 db kép tölthető fel, illetve maximum 50 féle címkét (tag) lehet létrehozni és összesen húsz iterációt szabad lefuttatni. Az előfizetés összesen két órányi tréninget tesz lehetővé a projektek létrehozása során.

Az ingyenes Azure-fiók elkészítése után először létre kellett hoznom két erőforrást az Azure platformon. Az első a tanítási erőforrás (training resource) a tanítási folyamatokhoz szükséges, a második pedig az előrejelzési erőforrás (prediction resource), amely a modell éles használatához, illetve API-val való lekérdezéséhez szükséges.

Ehhez az Azure Portalon belül a 13. ábrán látható specifikációkat beállítva létrehoztam a Custom Vision erőforrásokat, majd az Azure Custom Vision Portalon belül, a fiókomba való bejelentkezés után a -szintén a 13. ábrán látható- beállítások szerint létrehoztam egy új projektet.

13. ábra: Custom Vision erőforrások és a projekt létrehozásának beállításai

(Forrás: Azure Portal és Azure Custom Vision Portal)

The screenshot shows the 'Create new project' form in the Azure Portal. The form is in the 'Review + create' step. It includes the following fields and options:

- Name:** EloHoltSejtarany
- Description:** Enter project description
- Resource:** ElesztoVision [F0] (with a 'create new' link)
- Project Types:** Classification, Object Detection (selected)
- Domains:** General [A1], General, Logo, Products on Shelves, General (compact) [S1] (selected), General (compact)

At the bottom, there are three buttons: 'Previous', 'Next', and 'Create'.

Objektumdetektálás hatékonyságának mutatói: A Custom Vision a modell teljesítményének értékelésére három mutatót számol ki automatikusan: pontosság (precision), visszahívás vagy lefedettség (recall) és átlagos átlagpontosság (mean average precision, mAP).

Az értékelésénél kétféle határértéket lehet beállítani, amely alapján a modell a három mutatót (Precision, recall, mAP) kiszámolja. Az egyik határérték a valószínűségi küszöbérték (probability threshold) a másik az átfedési küszöbérték (overlap threshold).

- *Valószínűségi küszöbérték:* A modell minden felismeréshez hozzárendel egy úgynevezett valószínűségi értéket (confidence score), amely azt mutatja, hogy mennyire „biztos” abban, hogy az adott objektum ténylegesen az általa állított osztályhoz tartozik. A valószínűségi küszöbérték meghatározza azt a minimum értéket, amely felett a találatot érvényesnek tekintjük, azaz csak a beállított küszöbérték feletti valószínűségi értékkel rendelkező objektumok számítanak felismerésnek. Az alacsonyabb valószínűségi küszöb növeli az észlelt objektumok számát (magasabb recall érték keletkezik), de több téves találatot is eredményezhet (alacsonyabb precision) (Davis és Goadrich, 2006).
- *Átfedési küszöbérték:* Az objektumdetektálás során a modell a detektált objektumot (jelen esetben sejtet) megjelöli egy határolódobozzal, amely sokszor csak részben fedi le a feltanítási képen levő (felhasználó által megadott) határolódobozt. Ezt az átfedést az úgynevezett IoU (Intersection over Union) mutatóval fejezzük ki, amely két doboz közös területének és egyesített területének arányát fejezi ki (http13). Az átfedési

küszöbérték azt szabályozza, hogy minimum milyen mértékű átfedés esetén tekintünk egy predikciót valós pozitív, azaz helyes találatnak.

A Custom Vision által számolt három mutató:

a) *Pontosság (Precision)*: Azt méri, hogy a modell által pozitívnak jelölt esetek közül mennyi volt valóban helyes. A pontosság képlete:

$$Precision = \frac{TP}{TP+FP} * 100 [\%]$$

ahol:

- *Valós pozitív (True positive, TP)*: a modell által helyesen pozitívnak (adott osztályhoz tartozónak) jelölt példák száma
- *Hamis pozitív (False positive, FP)*: a modell által tévesen pozitívnak jelölt példák száma

b) *Visszahívás, lefedettség (Recall)*: Azt mutatja meg, hogy a valós pozitív esetek közül mennyit talált meg a modell. A visszahívás képlete:

$$Recall = \frac{TP}{TP+FN} * 100 [\%]$$

ahol:

- *Hamis negatív (False negative, FN)*: a modell által figyelmen kívül hagyott, de valójában pozitív példák száma

c) *Átlagos átlagpontosság (mean Average Precision, mAP)*: A mAP mutatót főként modellek teljesítményének összehasonlítására használják, értékét az egyes osztályokra (címkékre) számított átlagpontosság (Average Precision, AP) átlaga adja meg. Az AP egyenlő a pontosság-visszahívás (precision-recall, PR) görbe alatti területtel (egy adott osztályra vonatkozóan), azaz a különböző valószínűségi küszöbértékeknél mért pontossági (precision) értékek átlagát adja meg a visszahívás (recall) tartományában, így a modellt a pontosság és a visszahívás együttes figyelembevételével értékeli. Az AP és mAP képletei:

$$AP = \int_0^1 Precision(Recall) dRecall$$

$$mAP = \left(\frac{1}{C} \sum_{C=1}^C AP_C \right) * 100 [\%]$$

ahol:

- C: az osztályok száma

3.4. A modell felhasználásának környezete: Google Colaboratory (Colab)

A Custom Visionben elkészített modellt a Google Colab felhőalapú platformján API (Application Programming Interface, alkalmazásprogramozási felület) integráción keresztül tettem a cég számára könnyen hozzáférhetővé és felhasználhatóvá.

A Google Colab egy Google Research által fejlesztett, ingyenesen elérhető, felhőalapú fejlesztői környezet, amely lehetővé teszi Python alapú programok futtatását és megosztását webböngészőn keresztül. A Colab egy Jupyter Notebook-szerű felületet biztosít, ahol a felhasználók egyetlen dokumentumban kezelhetnek kódokat, szöveges magyarázatokat, képleteket és grafikus kimeneteket. A platform célja, hogy elősegítse az adatfeldolgozási, gépi tanulási és mesterséges intelligencia-fejlesztési folyamatok kivitelezését saját fejlesztői környezet vagy nagy számítási kapacitás nélkül ([http14](http://14)).

A Colab környezet a Google Cloud infrastruktúráján alapul, és (a Custom Vision-hez hasonlóan) SaaS és PaaS jelleget is mutat. A felhasználók a kész jegyzeteket a Google Drive-ban tárolhatják és oszthatják meg másokkal. A program nem igényel helyi telepítést, emellett könnyen hozzáférhető, ezért szerintem jól illeszkedik a sörfözde környezetébe. A Colab integrálható külső forrásokkal (pl. GitHub) és képes REST API-k meghívására, így könnyen össze lehetett kötni a Custom Vision modellemmel.

3.5. A platformokat összekötő REST API működése

A REST API (Representational State Transfer Application Programming Interface) egy olyan alkalmazásprogramozási felület, amely lehetővé teszi a különböző alkalmazások vagy rendszerek közötti adatcserét a HTTP (HyperText Transfer Protocol) -protokollon keresztül. A REST API segítségével a kliensek (pl. Google Colab) lekérdezéseket küldenek a szerver (Custom Vision) felé, amely válaszokat ad, általában JSON (JavaScript Object Notation) formátumban.

Működésének alapjai az úgynevezett endpointok (végpontok), vagyis olyan egyedi URL (Uniform Resource Locator) -címek, melyek egy adott erőforrást képviselnek a szerveren. A kliens ezekre a végpontokra küldi a kéréseket (pl. POST, azaz új adatok feltöltése).

A REST API-k általában hitelesítést igényelnek, hogy a szolgáltatáshoz csak jogosult felhasználók férjenek hozzá. Ez leggyakrabban egy API-kulcs használatával történik, melyet a kliens minden kéréshez a fejlécekben (*headers*) mellékel az azonosítás érdekében ([http15](http://15)).

4. Eredmények és értékelésük

4.1. A modell létrehozása az Azure Custom Vision platformon

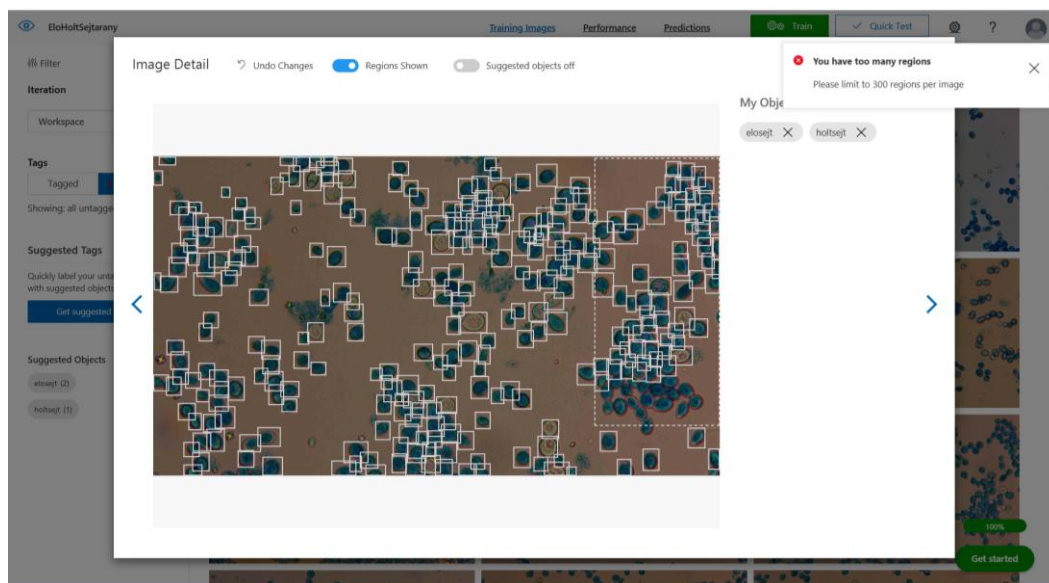
A modell elkészítéséhez a Microsoft Azure Custom Vision platformját használtam, ahol a sörfőzdében elkészített képeket feltöltve, felcímkézve és feltanítva, több verzió megalkotása után létrejött a CNN-en alapuló objektumdetektáló modell.

1. A felület előzetes tesztelésének eredménye

A Custom Vision projekt létrehozása után 15 darab, 40x és 10x-es nagyítású objektívvel készült képekkel vegyesen feltanítva először kipróbáltam a Custom Vision képességeit, és megállapítottam, hogy a felület nem alkalmas a 10x-es képek feldolgozására, mert egy képen belül maximum csak 300 db határolódobozt lehet berajzolni (lásd: 14. ábra), így a nagy sejt számú 10x-es képek feldolgozása ellehetetlenült.

14. ábra: A Custom Vision korlátai: határolódobozok számának limitációja

(Forrás: Custom Vision Portal)




2. A képek címkézésének tesztelése és eredményei

A címkézés megkezdése előtt létre kellett hoznom két taget (címkét) „holtsejt” és „elosejt” névvel. Ezután következett a folyamat legidőigényesebb része, a feltanítás. A felületre feltöltöttem a tanító képeket és minden képen egyesével bejelöltem az élő és holt sejteket. Ezt a címkézni kívánt objektumok (sejtek) köré rajzolt határolódobozokkal tettem meg. A 15. ábrán a sejtek kijelölésének folyamata látható:

15. ábra: A címkézés folyamata: sejt kijelölése és a megfelelő címke hozzárendelése

(Forrás: Custom Vision Portal)



A Custom Vision egyik sajátossága, hogy már a feltanítás közben is tanul a modell, és próbálja a címkézés folyamatát megkönnyíteni úgy, hogy az egeret az objektum fölé tartva magától bekeretezi a kijelölni vélt tárgyat. Ez a funkció a feltanítás elején még nehézkesen működött, mert a modell nem nagyon ismerte fel a sejteket, de később igen hasznosnak bizonyult. Persze az általa ajánlott kereteket fontos szerkeszteni, szűkíteni és pontosítani, elkerülve a későbbi, pontatlan keretezésből adódó hibákat.

A címkézés közben lehet futtatni úgynevezett iterációkat is, melyek során az addig felcímkézett képekkel feltanítjuk a modellt. Ez a modell fejlődésének vizsgálata mellett arra is jó, hogy a Custom Vision egyik címkézést segítő funkcióját aktiválhassuk. A funkció az első iteráció lefuttatása után válik elérhetővé és az aktuális, címkézni kívánt képen megpróbálja kijelölni az összes felismert objektumot, így a felhasználónak elég csak egészében, vagy egyesével, objektumonként elfogadni, avagy elutasítani a felajánlott címkézést. Ezt a funkciót én sajnos egyáltalán nem használtam, mivel a felületnek csak nagyon ritkán sikerült jól bekereteznie az objektumokat, és általában akkor sem vette észre az összes sejtet a képen.


A címkézés során a tanító képek jellegéből adódóan (lásd: 16. ábra) többféle problémát is tapasztaltam, amelyek nehezítették a feltanítási folyamatot, illetve észrevehetően gondot okoztak a modellnek. Ezt a modell által korábban említett, feltanítást segítő funkció (objektumok automatikus kijelölése) hatékonyságából és pontatlanságából érzékelttem.

A nehezítő tényezők a következők voltak:

1. *Összetapadt sejtek, sejtflokkulációk:* A szorosan összetapadt sejtcsoportokban nehéz volt elkülöníteni és pontosan bejelölni a sejtek határait, főleg, hogy ezt kizárólag négyzet és téglalap alakú határolódobozokkal tehettem meg.
2. *Sarjadzó sejtek:* Az American Society of Brewing Chemists (ASBC) szerint a sarjadzó sejt esetében a sarjat (bimbót) akkor kell külön sejtnek számolni, ha annak területe nagyobb, mint az anyasejt fele (<http://16>). Feltanításkor eszerint jártam el, de a modell sokszor a kisebb sarjakat is kijelölte, és külön sejtnek számította.

3. *Homályos sejtek:* Az elkészült képen előfordult, hogy néhány sejt nem volt fókuszban, nem rendelkezett éles határolóvonallal. Ez nehézséget jelentett a modellnek, mert sokszor nehéz volt elkülönítenie az életlen sejteket az egyéb szennyeződésektől.
4. *Szennyeződések:* A sörlé összetételéből adódóan nem pusztán élesztősejtek találhatóak meg benne, hanem egyéb, úgynevezett nem-sejtes törmelékek (pl. komló maradványai) is. Ha a sejtek ilyen szennyeződésekkel átfedésben lettek lefotózva, sokszor nehezen kivehetővé váltak, ami nehezítette a felismerést.

16. ábra: Címkézést nehezítő esetek (balról jobbra): összetapadt-, sarjadzó-, homályos sejtek és szennyeződések (Forrás: saját munka)



3. A modell fejlesztése és az iterációk eredményei

A képek felcímkézése után a tréning következett. Az iterációkat (modellverziókat) úgy terveztem meg, hogy minden lefuttatás között csak egy tényezőt változtassak. Így a kapott eredmények magyarázatát ideális esetben csak egy, az éppen megváltoztatott tényezőben (adatmennyiség növelése vagy a tréning hatékonyabb típusának alkalmazása) kereshetem.

Összesen öt iterációt futtattam le, az elsőt a modell kipróbálásakor 15 db képpel, a másodikat 248 db képpel, majd mivel ennek eredményeivel nem voltam megelégedve, újabb képeket készítve és feltanítva lefuttattam két iterációt 567 db feltanított képpel is, majd egy utolsót 617 db képpel.

A Custom Vision kétféle tréning funkcióval rendelkezik: *gyors tréning (quick training)*, illetve *haladó tréning (advanced training)*. A gyors tréning prototípusok készítésére és a modell gyors tesztelésére alkalmas, illetve kevésbé összetett feladatok feltanítására akár elegendő is lehet. A komplexebb problémák megoldásához viszont a haladó tréninget kell használni, amely pontosabb modellt hoz létre. Lefuttatása ugyan hosszabb időt vesz igénybe és magasabb számítási költségeket generál, de be lehet állítani rajta a maximális tréning időt, a kerettülpés megakadályozásának céljából. Kíváncsi voltam a két tréningtípus hatékonysága közötti különbségre, ezért az 567 db képpel először végigfuttattam egy gyors tréninget, majd 2 óra maximális tréningidő beállításával egy haladó tréninget is. A modell végleges verziójához (617

képpel) már csak haladó tréninget futtattam le, melynek lefuttatása (szintén 2 óra limit beállításával) 55 percet vett igénybe.

Az öt lefuttatott iteráció eredményeit 50%-os valószínűségi- és 30%-os átfedési küszöbérték beállításával a 2. táblázat mutatja be:

2. táblázat: Az iterációk adatai és eredményei 50% valószínűségi- és 30% átfedési küszöbérték beállítása esetén (Forrás: saját munka)

	Feltanított képek száma [db]	Tréning típusa	Pontosság (Precision) [%]	Visszahívás (Recall) [%]	mAP [%]
<i>Iteration 1</i>	15	gyors	77,8	6,8	9,9
<i>Iteration 2</i>	248	gyors	78,3	46,4	58,4
<i>Iteration 3</i>	567	gyors	75,6	46,0	48,6
<i>Iteration 4</i>	567	haladó	87,4	40,9	64,5
<i>Iteration 5</i>	617	haladó	85,5	47,4	63,8

A visszaadott mutatók értéke persze függ a beállított küszöbértékektől. (Például az *Iteration 5* esetén, 30% helyett 15%-os átfedési küszöbértékkel a mutatók: pontosság: 89,9%, visszahívás: 49,9%, mAP: 70,5%).

Mivel az *Iteration 1* csak egy próbafuttatás volt 15 darab képpel (ilyen mennyiséggel nem lehet jó modellt létrehozni), ennek eredményeit külön nem értékelném. Az utána következő négy iteráció eredményei azonban érdekes tendenciákat mutatnak.

Amikor jobb eredmények reményében a tanító adathalmaz mennyiségét 248-ról 567 darab képre emeltem (*Iteration 2* → *Iteration 3*), meglepetésemre a modell összes mutatója romlott, legfőképpen a mAP, majdnem 10 százalékkal.

A jelenség oka lehet, hogy a tréning típusának elégtelenségében gyökerezik, ugyanis amikor ugyanannyi feltanító adatmennyiséggel (567 darab kép) a gyors tréningről haladóra váltottam (*Iteration 3* → *Iteration 4*) a pontosság és mAP értékei jelentősen megnövekedtek (11,8-, illetve 15,9 százalékkal). Így lehetséges, hogy az *Iteration 3*-ban megnövelt adatmennyiséghez a gyors tréning funkciója már kevésnek bizonyult, és szükség volt a több ideig történő tanításra, a mélyebb neurális hálók kialakításának érdekében, hogy a modell pontossága látványosan javulhasson.

Ugyanakkor az *Iteration 3* és *Iteration 4* között a visszahívás mintegy 5,1 százalékos visszaesése arra enged következtetni, hogy habár ami sejtet a modell detektált, annak típusát általában jól felismerte (pontosság), viszont a haladó tréning alkalmazásával több sejtet nem vett észre, mint a gyors tréning során.



Ha a Custom Vision tréningjének pontos folyamatait nyilvánosságra hozná a Microsoft, az segítene a fenti jelenség megértésében. Ugyanis, ha a Custom Vision a tréning során az adathalmazt felosztja tréning és tesztelő adathalmazra (pl. 80% - 20% arányban), akkor egy ilyen eredmény során jogosan lehetne az overfitting (túlillesztés) jelenségére következtetni, ami azt jelentené, hogy a modell a haladó tréning során a tanulásra használt képek mintázatát „megjegyezte”, és ezt a (még sosem látott) teszt képekre nem tudta alkalmazni, ezért nem talált meg sok sejtet. A túlillesztés során a modell nem általánosít a tanult mintázatokból, hanem „memorizálja” azokat, amely rontja az ismeretlen képek elemzésének eredményeit. Azonban a Custom Vision valószínűleg nem különít el külön tesztelési adatrészletet, mivel az iteráció eredményei alatt a címkék (tagek) különálló eredményeinek kijelzésekor (az „*Image count*” fül alatt – lásd: *17. ábra*) az összes feltöltött (és adott címkét tartalmazó) kép mennyisége szerepel. Ez arra enged következtetni, hogy a Custom Vision mutatói az összes feltöltött képen végrehajtott teszt alapján kerülnek kiszámításra, így ezek az értékek potenciálisan optimistábbak lehetnek, mintha még sosem látott, elkülönített tesztkészleten tesztelnék a teljesítményt.

A következő lépésben (*Iteration 4* → *Iteration 5*) ismét a feltanító adathalmaz mennyiségét növeltem 567-ről 617 darab képre. Annak érdekében, hogy csak egy tényező változzon a két iteráció között, ezzel az adatmennyiséggel gyors tréninget már nem futtattam le, csak haladót. Érdekes módon a pontosság és mAP értékeiben enyhe (1,9- illetve 0,7 százalékos) visszaesés történt, míg a visszahívás értéke az összes iteráció közül itt lett a legmagasabb, 47,4 százalékos, így ebben a lépésben az adathalmaz növelése javította a modellt a sejtek megtalálásában.

A tanító adathalmaz növelésekor az eredmények változása természetesen (az újonnan) feltöltött képek és a címkézés minőségétől, illetve a címkék arányának megoszlásától is függ. Ahogyan a *17. ábrán* is látszik, az általam használt adathalmazban a címkék előfordulása nem volt kiegyenlített. Halott sejt az összes képen meg volt jelölve (és adott képen belül is a címkék általában nagyobb arányban holt sejteket jelöltek), míg élő sejt 88 darabbal kevesebb tanító képen volt megtalálható. Emiatt nem meglepő, hogy a holt sejtek mutatói jobbak az élő sejtekénél. A visszahívás (recall) értékét például az *Iteration 5* esetén az élő sejtek ritkás felismerése jelentősen lerontja. Az élő sejtek észrevétele emellett azért is lehet nehezebb a modellnek, mert az átlátszó szín miatt a sejt sokszor nehezebben észlelhető, mint a sötétké, halott sejtek.

17. ábra: A címkék különálló eredményei (Iteration 5, 50% valószínűségi- és 30% átfedési küszöbérték beállítása esetén)

(Forrás: Azure Custom Vision Portal)

Tag	Precision	Recall	A.P.	Image count
holtsejt	85.8%	49.3%	69.9%	617 
elosejt	82.5%	32.0%	57.7%	529 

Összességében megállapítható, hogy a modell teljesítményének javításához a tanító adathalmaz mellett a hosszabb (haladó) tréning alkalmazása egyaránt fontos volt, mivel a nagyobb mennyiségű kép feltanításához elengedhetetlen az alaposabb, összetettebb tréning futtatása.


4. Modell tesztelése

Fontos volt, hogy a modellt számára ismeretlen képeken is teszteljem. Ebben segített a Custom Vision egyik beépített funkciója a Quick Test, melynek segítségével a felületen egyesével, saját képeken lehet tesztelni a létrehozott modellt. A Quick Test során a modell a beállított valószínűségi küszöbértéknél (probability threshold) magasabb valószínűségi értékkel (confidence score) rendelkező objektumdetektálásokat jelzi a feltöltött képen.

A funkciót én is több, tesztelésre félretett képen kipróbáltam és nem tökéletes, de egészen jó eredményeket tapasztaltam. Ahogy a *18. ábrán* is látszik, a modell általában megtalálta az élesztősejteket, de a rájuk helyezett határolódobozok sokszor pontatlanok voltak (a teszt 15%-os valószínűségi küszöbindex beállításával történt). Előfordult, hogy a modell egy sejtre több dobozt helyezett, vagy több, összetapadt sejt esetén nem vette észre az összeset, így kevesebb sejtet jelölt meg a kelleténél, illetve néha a háttérben található törmelékeket, apró szennyeződések is sejtnak érzékelt. A modell pontossága viszont kimagasló volt, például az alábbi képen a megtalált, valódi sejtek típusát (élő vagy holt) az összes esetben helyesen ismerte fel.

18. ábra: *Iteration 5* - Quick Test eredménye 15%-os valószínűségi küszöbértékkel

(Forrás: Custom Vision Portal)



5. A modell közzététele és exportálási lehetőségei

Az iterációk közül végül az *Iteration 5*-t tettem közzé (publikáltam), ami elég nehezen ment, ugyanis az Azure először az erőforrásokkal kapcsolatos hibakódot jelzett, majd az ügyfelszolgálattal kapcsolatba lépve körülbelül két nap múlva szűnt csak meg a probléma. A publikálás után megkaptam a modell külső felhasználásához szükséges kulcsokat. Emellett a modellt az összes elérhető módon exportáltam (CoreML, TensorFlow, ONNX, Dockerfile, Vision AI Dev Kit, OpenVino), későbbi felhasználás céljából.

A Custom Vision jó eszköz arra, hogy a felhasználó a saját feltanító képein, manuálisan be tudja jelölni a detektálni kívánt objektumokat, és különösebb kép-előfeldolgozások és kód írása nélkül egy jó teljesítményű modellt hozhasson létre. Amit azonban nagy hiányosságnak éreztem, hogy a Microsoft eltörölte a felcímkézett képek exportálásának funkcióját (valószínűleg azzal a céllal, hogy a modellt inkább főként API-n keresztül ériék el a felhasználók, így részesei maradnak az Azure-infrastruktúrának és továbbra is fizessenek a szolgáltatásért). Így a képek és tagek exportálása csak nehezebb úton, külön környezet (pl. Python) segítségével valósítható meg a Get Tagged Images API használatával.

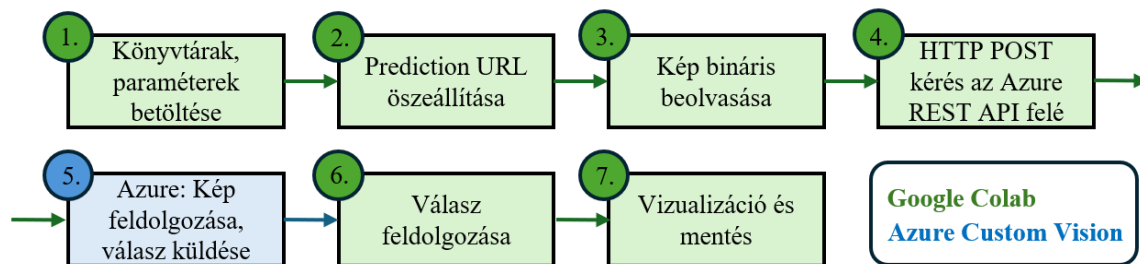
5.2. A kész modell integrálása a Google Colaboratory platformba

Mivel a Custom Vision platform csak a detektálást, kategóriákba sorolást és a határolódobozok bejelölését végzi el, a képeken detektált élő-, illetve holt sejtek számát és az ebből számolt vitalitás értékét egy másik felület segítségével tudtam csak megjeleníteni. Erre a Google Colab

platformot használtam, amelyet a Custom Visionnel összekötve egy felhőalapú, felhasználóbarát képfeldolgozó rendszer jött létre.

A Colab felületén futó, Python alapú (Jupyter Notebook-hoz hasonló) környezetbe írt kód megírásában a Google Colab AI-asszisztált kódíró eszköze segített. A következő részben részletesen kifejtett programkód felépítését a 19. ábra szemlélteti:

19. ábra: A Google Colab platformon levő program lefutásának folyamata (jelölések: zöld-Google, kék-Azure)
(Forrás: saját munka)



A program részeinek magyarázata, különös tekintettel a két platform összekötésének lépéseire:

1.) A futtatáshoz szükséges könyvtárak betöltése után a Custom Vision API eléréséhez szükséges adatokat kellett megadni, amelyek a következők: ENDPOINT (az Azure regionális API-címe), PREDICTION_KEY (kulcs az API hitelesítéséhez), PROJECT_ID (a Custom Vision projekt egyedi azonosítója), PUBLISHED_NAME (a modell publikált verziójának neve).

2.) A Predikciós API végpont teljes URL-jének létrehozása során állítottam össze a Custom Vision REST API végpontot, amelyen keresztül a Colab a feltöltött képet elküldi a modellnek. Ez az URL a Custom Vision REST API-nak azt a részét hívja meg, amely bináris formátumú képfájlokat vár és objektumdetektálást végez rajtuk: `URL=f" {ENDPOINT}customvision/v3.0/Prediction/{PROJECT_ID}/detect/iterations/{PUBLISHED_NAME}/image"`.

3.) A harmadik lépésben a felhasználó által feltöltött képet a program bináris fájlá alakítja.

4.) A Custom Vision modell meghívása POST kéréssel: Ebben a lépésben a Colab a `request.post()` függvénnyel egy HTTP POST kérést küld a 2. lépésben felépített URL-re. A kérés fejlécében (headers) a PREDICTION_KEY (a hitelesítéshez) és a „Content-Type” (jelöli, hogy bináris adatot továbbít) -információk szerepelnek. A kód a `with open(IMAGE_PATH, „rb”)` utasítással megnyitja a feldolgozandó képet, majd tartalmát elküldi a REST API-nak.

5.) A Custom Vision a szerveren feldolgozza a képet, majd a detektálás eredményét (határolódobozok, címkék, valószínűségek) JSON formátumban küldi vissza a Colabnak.

6.) A kapott választ a Colab dekódolja, majd megszámolja a címkéket, amely alapján kiírja az élő és a holt sejtek számát külön, majd kiszámolja a mintában található sejtek vitalitását.

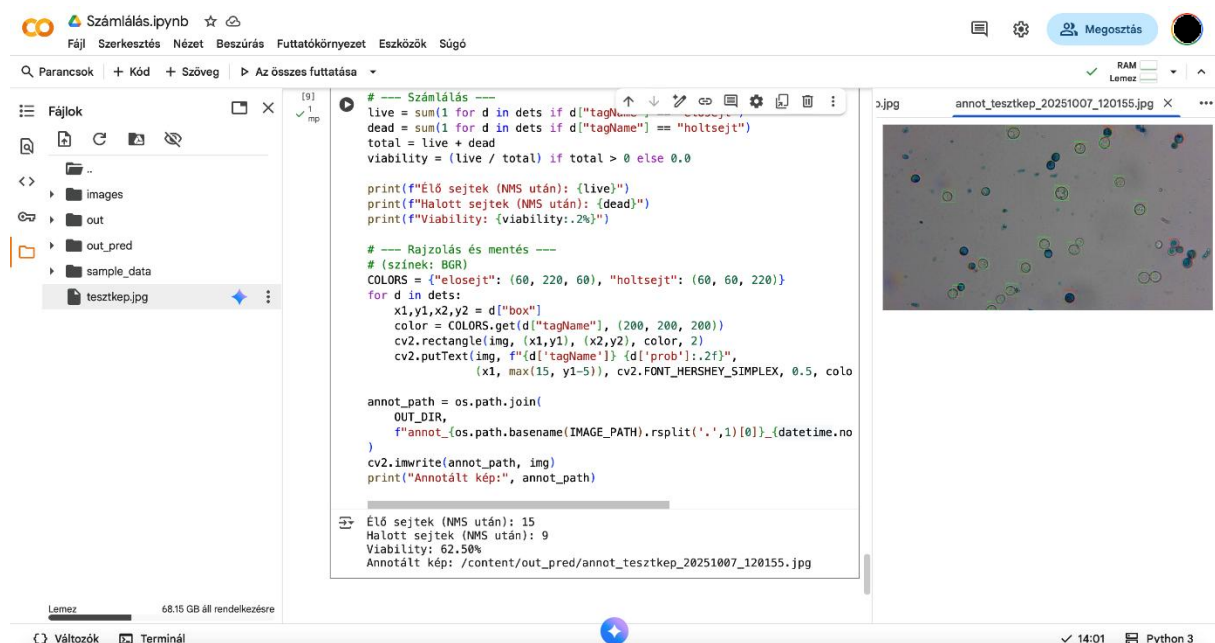
7.) Ezután a program a felhasználónak visszaküldi a feltöltött képet is, amin határolódobozokkal bejelölte a sejteket.

Így tehát egy hitelesített REST API híváson alapuló kapcsolat jött létre a Colab, mint kliens és a Custom Vision szerver oldali, felhőben futó modellje között. Véleményem szerint a felhőalapú no-coding eszközökkel készült modellek továbbfejlesztésének ez az egyik legjobb módja, hiszen néhány paraméter (végpont, kulcs, projektazonosító) megadásával egy biztonságos és rugalmas kapcsolat alakítható ki a két platform között, lehetővé téve az Azure-ban létrehozott modell távoli elérését és integrálását a Google Colab helyi fejlesztői környezetébe. A létrehozott rendszer felhőszolgáltatási modell szempontjából hibrid megoldás. A Custom Vision ugyanis egy SaaS komponens, mivel egy kész szolgáltatás érhető el REST API-n keresztül, a Google Colab viszont PaaS jellegű, mivel egy előre elkészített, de saját kód futtatására alkalmas platformot biztosít.

A 20. ábrán a Colabon lefutott program és az általa visszaadott értékek láthatók. Itt éppen 40%-os valószínűségi küszöbértékkel futtattam le a kódot, ami miatt -a visszaadott képen jól látható módon- a modell sok sejtet nem detektált.

20. ábra: A Google Colabon készült program felülete

(Forrás: Google Colab)



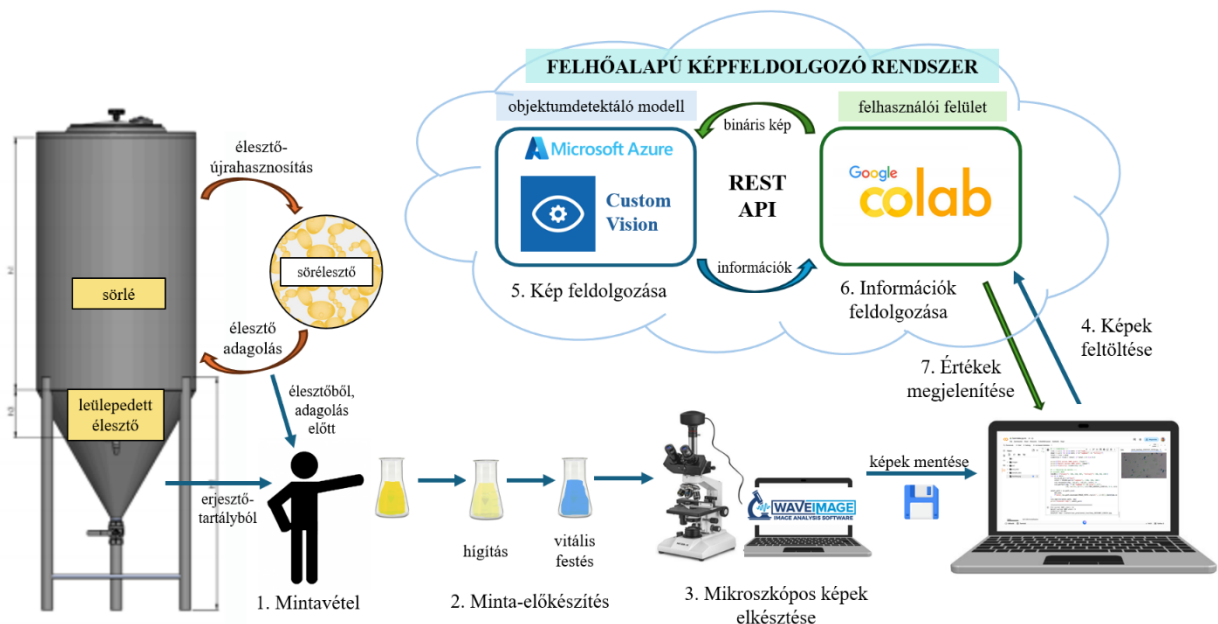
A Google Colab segítségével tehát a sörfőzdében bármilyen internetkapcsolattal rendelkező eszköztől elérhetik és futtathatják a modellt, így a feltöltött képek feldolgozott adatai és eredményei valós időben megjeleníthetők. Ez jelenleg egy jó átmeneti megoldás a program

futtatására, de a rendszert még tovább szeretném fejleszteni és tökéletesíteni, melynek ötleteit a *Következtetések és javaslatok* fejezetben ismertetem.

A WaveImage képmegjelenítő szoftver felépítése miatt a rendszer nem alkalmas a mikroszkóp által éppen vizsgált minta valós idejű elemzésére, azonban a kép megjelenítése és a képfeldolgozó rendszer egy eszközzel, egyszerre elérhető. Így az előkészített mintáról a felhasználónak 10 db, különböző látótérben fényképezett képet kell készítenie, és elmentenie, majd feltöltenie a Google Colab platformra, amely a keresett értékeket (élő sejtek száma, holt sejtek száma, számolt vitalitás, képen bejelölt eredmények) adja vissza. A kész rendszer felhasználásának és működésének folyamatát a 21. ábra szemlélteti:

21. ábra: A felhőalapú képfeldolgozó rendszer felhasználásának és működésének folyamata

(Forrás: saját munka)



5. Következtetések és javaslatok

A kérdésre, hogy vajon alkalmasak-e a kódolást nem igénylő (no-coding) eszközök élelmiszeripari fejlesztésekre, a válasz egyértelműen igen. A megoldás kellő megtervezésével és a megfelelő eszköz kiválasztásával az API integrációknak és modell-exportálási lehetőségeknek köszönhetően könnyen létrehozhatóak személyre szabott programok, amelyeket felhőalapú adatbázisokkal integrálva adatalapú döntéshozatali rendszerek kiépítése válik lehetővé.

A megfelelő no-coding eszköz megválasztása ugyanakkor elengedhetetlen. Véleményem szerint a mikroszkópos képek jellegéből adódóan (háttérszennyeződések, összetapadt sejtek) az Azure Custom Vision önmagában nem elegendő ahhoz, hogy iparban felhasználható minőségű sejtfelismerő modellt létrehozzon, de egyszerűbb feladatokra (például termékek, hibák felismerése) elegendő lehet. Munkám során az alábbi észrevételeket gyűjtöttem össze az Azure Custom Vision feladatra való alkalmassága kapcsán:

- Nincsenek pontos információk a modellfejlesztés során lezajló folyamatokról és a program által beállított paramétereikről, így a tréning nem finomhangolható.
- Nagyon jó címkéző eszköz, de a határolódobozok csak négyzet alakúak lehetnek, ami a sejtek bejelölése esetén nehézséget okozhat (összetapadt sejtek pontos kijelölése).
- A felcímkézett képek nem exportálhatók közvetlenül, csak külső környezetből (pl. Python) hívhatók meg vagy tölthetők le, ez némiképp nehezíti a felhasználást.
- Ha a modellt API-n keresztül használjuk fel, számolni kell az Azure költségeivel, ezért, ha a program nem egy nagyobb infrastruktúra része, érdemesebb inkább exportálni.
- A platform objektumdetektálás során csak a prediktált határolódobozokat és címkéket, illetve az ezekhez tartozó valószínűségi értékeket adja vissza, az objektumok számát nem, így ezt az információt is csak külső felület segítségével tudjuk kinyerni.

A másik kérdésre, hogy a mesterséges intelligenciát használó modell milyen eredménnyel képes az ember vizuális kiértékelési feladatainak ellátására, a modellem mutatói adják meg részben a választ (85,5% pontosság; 47,4% visszahívás; 63,8% mAP). Modellemben a mesterséges intelligencia (50%-os valószínűségi- és 30%-os átfedési küszöbértékkel) a képen levő sejteknek csak kevesebb, mint felét veszi észre, viszont a felismert sejtek típusát 85,5%-ban eltalálja. A modell teljesítménye összességében 63,8%-ra tehető, amin bőven van még mit fejleszteni. Másrészt viszont a kérdésre egy olyan, fejlettebb platform használata során adhatnék pontosabb választ, amelynek tréning-beállításai hozzáférhetők és finomhangolhatók.

Azt vizsgálva, hogy az élesztők vitalitásvizsgálatának folyamatát vajon milyen mértékig lehet automatizálni arra jutottam, hogy a kisüzemi sörgyártás jellegéből adódóan az erjesztés során történő mintavételezés csak szakaszosan valósítható meg, és célszerű embernek végeznie. A minta hígítását lehetne automatizálni, de mivel a hígítás mértéke általában az adott minta sejtsűrűségétől függ, egy automata hígító-rendszer létrehozása komoly fejlesztést igényelne. A vitális festés lépését szintén lehetne automatizálni, de a hígításhoz hasonlóan ez -főként kisüzemi szinten- nem lenne megtérülő befektetés. A mikroszkópos kép elmentése és a kiértékelő platformba illesztése nálam manuális lépésekből állt, ám a rendszer további fejlesztésével létre lehetne hozni egy olyan programot, amely képes a mikroszkópos felvétel valós idejű, teljesen automatizált kiértékelésére.

A modell jövőbeli fejlesztésére emellett számos tervem van:

A kiegyenlítettebb tanító-adathalmaz létrehozásának érdekében több, nagy arányban élő sejtet ábrázoló mikroszkópos képet szeretnék készíteni és hozzáadni a feltanító képek halmazához, így növelve a visszahívás értékét, azaz a sejtek megtalálásának eredményességét.

Emellett a teljesítmény javításának érdekében az exportált modellel szeretném a YOLO (You Only Look Once) konvolúciós neurális hálózatokon alapuló objektumdetektáló algoritmussal „feljavítani”, a szakirodalmi részben bemutatott Haja et al. (2021) kutatásához hasonlóan. A tréning finomhangolásával és elmélyítésével, illetve a sejt-morfológiai sajátosságokhoz illeszkedő hálóstruktúrák létrehozásával elérhetném, hogy a kisüzemi sörfőzde egy megbízható modellt használhasson fel.

Ha a modell javítása megtörtént, a kész programot szeretném a cég által használt felhő-infrastruktúrába integrálni, hogy a vitalitás-adatok egy adatbázisban tárolhatók és visszakövethetők legyenek, ezzel segítve a céget az adatalapú döntéshozatalban.

Az eredeti terveim szerint a sejtek vitalitásának meghatározásához Bürker-kamrás képeket szerettem volna feldolgozni, ám ezt a Custom Vision platformon nem tudtam megtenni (kis sejtek felismerésére nem alkalmas, limitált határolódoboz-kijelölés). Így a no-coding eszközök további feltérképezésének céljából az elkészített mikroszkópos képeim alapján a szakirodalmi részben bemutatott, és a Custom Vision mellett a feladatra legalkalmasabbnak ítélt Roboflow platform kipróbálásával szeretnék egy Bürker-kamrás számlálásra és vitalitás-vizsgálatra alkalmas modellt is létrehozni, hogy az életképesség-vizsgálat és sejt-koncentráció-meghatározás feladatát egyetlen rendszer végezze el.

6. Összefoglalás

A mesterséges intelligencia és a képfeldolgozási módszerek az utóbbi években jelentős fejlődésen mentek keresztül, emiatt egyre szélesebb körben alkalmazzák őket biotechnológiai és élelmiszeripari kutatásokban. Dolgozatom egyik célja az volt, hogy bemutassam, miként alkalmazható a felhőalapú mesterséges intelligencia a sörgyártás egyik fontos minőségellenőrzési folyamatában: az élesztők vitalitásának, vagyis az élő és holt sejtek arányának meghatározásában. Emellett fontos szempont volt számomra, hogy megvizsgáljam: a kódolást nem igénylő eszközök alkalmasak-e élelmiszeripari fejlesztések megvalósítására.

Kutatásom során egy felhőalapú képfeldolgozó modellt hoztam létre a Microsoft Azure Custom Vision szolgáltatásának segítségével. A modell mikroszkópos képeken automatikusan azonosítja és kategorizálja az élesztősejteket „élő” és „holt” csoportokba. A képeket több iterációban tanítottam fel, és mindegyik futtatás után az eredményeket a pontosság (precision), visszahívás (recall) és átlagos átlagpontosság (mean average precision) mérőszámokkal értékeltem. A fejlesztés során, a tanító adathalmaz mennyiségét és a tanítási folyamat komplexitását növelve a modell fokozatosan javuló eredményeket mutatott, amely bizonyította, hogy a mélytanuláson alapuló, konvolúciós neurális hálózatokat alkalmazó képfeldolgozási módszerek alkalmasak az élesztősejtek vitalitásának meghatározására.

A kifejlesztett modellt ezt követően a Google Colab felületébe integráltam az Azure API (Application Programming Interface) segítségével, így egy olyan interaktív, felhasználóbarát platformot létrehozva, amely a felhasználó által feltöltött mikroszkópos képeken automatikusan meghatározza az élő és holt sejtek számát, illetve megadja a minta vitalitását.

A kutatásom eredményei igazolják, hogy a mesterséges intelligencia és a felhőalapú megoldások a söripari minőségellenőrzésben is hatékonyan alkalmazhatók. A kódolást nem igénylő eszközzel létrehozott modell egyszerűsíti és gyorsítja az élesztővitalitási méréseket, emellett objektív és reprodukálható eredményeket biztosít. A módszert a jövőben szeretném továbbfejleszteni fejlettebb konvolúciós neurális hálózatokon alapuló algoritmusok felhasználásával, és az eredmények felhőalapú adatbázisba történő integrálásával, így hozzájárulva a sörgyártási folyamatok adatalapú döntéshozatali rendszereinek kiépítéséhez és a termelés hatékonyságnöveléséhez.

7. Irodalomjegyzék

- Armbrust, M., Fox, A., Griffith, R., Joseph, A. D., Katz, R., Konwinski, A., Lee, G., Patterson, D., Babkin, A., Stoica, I., Zaharia, M. (2010): A View of Cloud Computing. *Communications of the ACM*, 53(4), 50–58. DOI:[10.1145/1721654.1721672](https://doi.org/10.1145/1721654.1721672)
- Atanasova, M., Yordanova, G., Nenkova, R., Ivanov, Y., Godjevargova, T., Dinev, D. (2019): Brewing yeast viability measured using a novel fluorescent dye and image cytometer. *Biotechnology & Biotechnological Equipment*, 33(1), 548–558. <https://doi.org/10.1080/13102818.2019.1593053>
- Bottari, B., Campari, G., Gatti, M. (2014): Live/dead yeast viability staining as a tool for improving artisanal pilsner beer production. *Journal of Microbiology Biotechnology and Food Sciences* 4(2), 174-178. DOI:[10.15414/jmbfs.2014.4.2.174-178](https://doi.org/10.15414/jmbfs.2014.4.2.174-178)
- Boyd, A. R., Gunasekera, T. S., Attfield, P. V., Simic, K., Vincent, S. F., Veal, D. A. (2003): A flow-cytometric method for determination of yeast viability and cell number in a brewery, *FEMS Yeast Research*, 3(1), 11–16. <https://doi.org/10.1111/j.1567-1364.2003.tb00133.x>
- Chai, B., Efstathiou, C., Yue, H., Draviam, V. M. (2024): Opportunities and challenges for deep learning in cell dynamics research. *Trends in Cell Biology*. 34(11). 955–967. DOI: [10.1016/j.tcb.2023.10.010](https://doi.org/10.1016/j.tcb.2023.10.010)
- Chaturvedi, A., Pathak, N. (2024): Introduction and types of machine learning. *Artificial intelligence and their applications*. Letöltés dátuma: 2025. 10. 19. forrás: <https://iipseries.org/assets/docupload/rs1202467DF4A0306B437B.pdf>
- Davis, J., Goadrich, M. (2006): The relationship between Precision-Recall and ROC curves. *Proceedings of the 23rd International Conference on Machine Learning*, 233–240. <https://doi.org/10.1145/1143844.1143874>
- Deák T., Kiskó G., Maráz A., Mohácsiné Farkas Cs. (2006). *Élelmiszer-mikrobiológia*. Letöltés dátuma: 2025. 10. 19. forrás: <https://www.scribd.com/document/478671019/Élelmiszer-mikrobiologia20-pdf#page=205>
- Egwuotuoha, I. P., Schragl, D., Calvo, R. (2013): A Brief Review of Cloud Computing, Challenges and Potential Solutions. *Parallel & Cloud Computing*, 2(1), 7-14. Letöltés dátuma: 2025. 10. 19. forrás: https://www.researchgate.net/publication/330912856_A_Brief_Review_of_Cloud_Computing_Challenges_and_Potential_Solutions
- Eßlinger H. M. (2009): *Handbook of Brewing*. Weinheim: Wiley-VCH. Letöltés dátuma: 2025. 10. 19. forrás: https://vebrianangrya.wordpress.com/wp-content/uploads/2013/09/handbook_of_brewing_processes_technology_markets.pdf
- Feizi, A., Zhang, Y., Greenbaum, A., Guziak, A., Luong, M., Chan, R. Y. L., Berg, B., Ozkan, H., Luo, W., Wu, M., Wu, Y., Ozcan, A. (2017): Yeast viability and concentration analysis using lens-free computational microscopy and machine learning. *Proc. SPIE 10055, Optics and Biophotonics in Low-Resource Settings III*, 1005508. <https://doi.org/10.1117/12.2252731>
- Fernandes, D. A. B., Soares, L. F. B., Gomes, J. V., Freire, M. M., Inácio, P. R. M. (2014): Security issues in cloud environments: A survey. *International Journal of Information Security*, 13(2), 113–170. DOI:[10.1007/s10207-013-0208-7](https://doi.org/10.1007/s10207-013-0208-7)
- Gonzalez, R. C., Woods, R. E. (2018): *Digital Image Processing* (4th ed.). Harlow, UK: Pearson. Letöltés dátuma: 2025.09.26. forrás: <https://www.cl72.org/090imagePLib/books/Gonzales.Woods-Digital.Image.Processing.4th.Edition.pdf>
- György É. (2020): *Élelmiszer-mikrobiológia laboratóriumi gyakorlatok*. Jegyzet. Kolozsvár: Scientia Kiadó. Letöltés dátuma: 2025.09.25. forrás: https://real.mtak.hu/118351/1/GyorgyEva_ElelmiszerMikrobiologia_REAL.pdf
- Haja A., Schomaker L. R. B. (2021): A fully automated end-to-end process for fluorescence microscopy images of yeast cells: From segmentation to detection and classification. *Proceedings of 2021 International Conference on Medical Imaging and Computer-Aided Diagnosis (MICAD 2021)* (pp.37-46) <https://doi.org/10.48550/arXiv.2104.02793>

- Han, Y., Li, Q., Sun, P., Ma, X., Yang, Y., Zhang, N., Feng, J., Sa, Y. (2025): Fusion of microscopic and diffraction images with VGG net for budding yeast recognition in imaging flow cytometry. *Scientific Reports* **15**, Paper 25820. <https://doi.org/10.1038/s41598-025-09320-4>
- Hayashi, M., Ohnuki, S., Tsai, Y., Kondo, N., Zhou, Y., Thang, H., Ishii, N. T., Ding, T., Herbig, M., Isozaki, A., Ohya, Y., Goda, K. (2023): Is AI essential? Examining the need for deep learning in image-activated sorting of *Saccharomyces cerevisiae*. *Lab on a Chip*, **23**, 4232–4244. <https://doi.org/10.1039/D3LC00556A>.
- Hong, D., Lee, G., Jung, N.C. Jeon, M. (2013): Fast automated yeast cell counting algorithm using bright-field and fluorescence microscopic images. *Biol Proced Online* **15**, 13. <https://doi.org/10.1186/1480-9222-15-13>
- http1: White Labs (2021): *The Life of Brewers Yeast*. White Labs honlapja. Letöltés dátuma: 2025. 10. 19. forrás: <https://blog.whitelabs.com/the-life-of-brewers-yeast>
- http2: IONOS editorial team (2024): What is a convolutional neural network (CNN)?. *IONOS Digital Guide* honlapja. Letöltés dátuma: 2025. 10. 19. forrás: <https://www.ionos.co.uk/digitalguide/websites/web-development/convolutional-neural-networks/>
- http3: Revvity – Application note (2023): Yeast concentration and viability using image-based fluorescence analysis. Letöltés dátuma: 2025. 10. 19. forrás: <https://resources.revvity.com/pdfs/app-yeast-concentration-and-viability-using-image-based-fluorescence-analysis.pdf>
- http4: Teachable Machine honlapja. Letöltés dátuma: 2025. 10. 19. forrás: <https://teachablemachine.withgoogle.com/>
- http5: Custom Vision documentation. Microsoft Learn honlapja. Letöltés dátuma: 2025. 10. 19. forrás: <https://learn.microsoft.com/en-us/azure/ai-services/custom-vision-service/>
- http6: Microsoft: *Overview of AI Builder*. Microsoft honlapja. Letöltés dátuma: 2025. 10. 19. forrás: <https://learn.microsoft.com/en-us/ai-builder/overview>
- http7: Scribe (2025): *Best No-Code AI Tools in 2025*. Scribe honlapja. Letöltés dátuma: 2025. 10. 19. forrás: <https://scribehov.com/library/no-code-ai-tools>
- http8: Roboflow honlapja. Letöltés dátuma: 2025. 10. 19. forrás: <https://roboflow.com/>
- http9: Digital Decade DESI visualisation tool – *DESI indicators (2023)*. European Commission honlapja. Letöltés dátuma: 2025. 08. 22. forrás: https://digital-decade-desi.digital-strategy.ec.europa.eu/datasets/desi/charts/desi-indicators?period=desi_2024&indicator=desi_cloud&breakdown=ent_sm_xfin&unit=pc_ent&country=AT,BE,BG,HR,CY,CZ,DK,EE,EU,FI,FR,DE,EL,HU,IE,IT,LV,LT,LU,MT,NL,PL,PT,RO,SK,SI,ES,SE
- http10: Eurostat (2023): *Digital economy and society - Cloud computing – statistics on the use by enterprises*. Eurostat honlapja. Letöltés dátuma: 2025. 08. 22. forrás: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Cloud_computing_statistics_on_the_use_by_enterprises
- http11: Microsoft - What is Azure?. Microsoft Azure honlapja. Letöltés dátuma: 2025. 10. 19. forrás: <https://azure.microsoft.com/en-us/resources/cloud-computing-dictionary/what-is-azure/>
- http12: BCA.Inc. (2023). Pros and Cons of Microsoft Azure. BCA.Inc honlapja. Letöltés dátuma: 2025. 10. 03. forrás: <https://bcainc.com/blog/pros-and-cons-of-microsoft-azure/>
- http13: LearnOpenCV (2022): *Intersection over Union (IoU) in Object Detection & Segmentation*. Letöltés dátuma: 2025. 09. 24. forrás: <https://learnopencv.com/intersection-over-union-iou-in-object-detection-and-segmentation/>
- http14: Google (2023): *Welcome to Colaboratory*. Letöltés dátuma: 2025. 10. 21. forrás: <https://colab.research.google.com>
- http15: Microsoft. (2024). What is a REST API? Letöltés dátuma: 2025. 10. 21. forrás: <https://learn.microsoft.com/en-us/azure/architecture/best-practices/api-design>
- http16: American Society of Brewing Chemists (2011): *Microscopic Yeast Cell Counting*. Letöltés dátuma: 2025. 09. 24. forrás: <https://www.asbcnet.org/lab/getstarted/Documents/Yeast-4.pdf>

- Kucharczyk, K., Żyła, K., Tuszyński, T. (2025): Optimization of Fermentation Parameters in a Brewery: Modulation of Yeast Growth and Yeast Cell Viability. *Processes*, 13(3), 906. <https://doi.org/10.3390/pr13030906>
- Magoulés, F., Pan J., Teng F., (2013): *Cloud Computing – Data-Intensive Computing and Scheduling*. Boca Raton: CRC Press, Taylor&Francis Group. Letöltés dátuma: 2025. 08. 22. forrás: file:///C:/Users/user/Downloads/10.1201_b12720_previewpdf.pdf
- Mell, P., Grance, T. (2011): The NIST Definition of Cloud Computing - Recommendations of the National Institute of Standards and Technology. Gaithersburg: National Institute of Standards and Technology. Letöltés dátuma: 2025. 10. 19. forrás: <https://faculty.winthrop.edu/domanm/csci411/Handouts/NIST.pdf>
- Nagy-Borsy V. (2020): Felhő alapú szolgáltatások használata a hazai kkv-szektorban. *Studia Mundi – Economica*, 7(3), 39-59. <https://doi.org/10.18531/Studia.Mundi.2020.07.03.39-59>
- Nagy-Borsy, V. (2023): A cloud computing elterjedése Magyarországon. *Köz-gazdaság*, 18 (3). 47-70. DOI <https://doi.org/10.14267/RETP2023.03.04>
- O’Shea, K., Nash, R. (2015): An Introduction to Convolutional Neural Networks. *arXiv:1511.08458* <https://doi.org/10.48550/arXiv.1511.08458>
- Rumelhart D. E., Hinton G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://gwern.net/doc/ai/nn/1986-rumelhart-2.pdf>
- Saldi, S., Driscoll, D., Kuksin, D., Chan, L. L. Y. (2014): Image-Based Cytometric Analysis of Fluorescent Viability and Vitality Staining Methods for Ale and Lager Fermentation Yeast. *Journal of the American Society of Brewing Chemists*, 72(4), 253–260. <https://doi.org/10.1094/ASBCJ-2014-1015-01>
- Silvis J. (2024): Cloud Server's Impact: The Environment and Supply Chain. *Sustainable Supply Chain Management*. 1. Letöltés dátuma: 2025. 08. 22. forrás: <https://digital.sandiego.edu/ksb-sscml/1>
- Thomson, K., Bhat, A., Carvell, J. (2015): Comparison of a new digital imaging technique for yeast cell counting and viability assessments with traditional methods. *Journal of the Institute of Brewing* Volume 121, Issue 2 pp. 231-23. <https://doi.org/10.1002/jib.224>
- Turing A. M., (1950). Computing machinery and intelligence. *Mind*, 59(236), 433–460. <https://doi.org/10.1093/mind/LIX.236.433>
- Wang, W., Zhang, X., Li, R., Xin, H., Cai, Y. (2025): Deep-learning-enhanced portable microscopy for yeast cell viability quantification in small dataset. *Optics & Laser Technology*, Volume 192, Part F, 114092. <https://doi.org/10.1016/j.optlastec.2025.114092>.
- Yasavoli, B., Habibirad, A., Javanshiri, Z. (2025): A hybrid deep learning model in predicting weather temperature, *Earth Science Informatics*, 18(3). DOI:[10.1007/s12145-025-01963-1](https://doi.org/10.1007/s12145-025-01963-1)

Rövidítések jegyzéke:

- CNN: Convolutional Neural Network - konvolúciós neurális hálózat
- SaaS: Software as a Service - szoftver, mint szolgáltatás
- PaaS: Platform as a Service - platform, mint szolgáltatás
- API: Application Programming Interface - alkalmazásprogramozási felület

8. Táblázatok és ábrák jegyzéke

8.1. Táblázatok jegyzéke

1. táblázat: A sörélesztő-tartalmú minták tulajdonságai	22
2. táblázat: Az iterációk adatai és eredményei 50% valószínűségi- és 30% átfedési küszöbérték beállítása esetén.....	33

8.2. Ábrák jegyzéke

1. ábra: A sörgyártás lépései és az élesztő helye a folyamatban	5
2. ábra: A sörlé egyes összetevőinek és néhány jellemző paraméter változása a fermentáció során	6
3. ábra: A konvolúciós neurális hálózatok felépítése	10
4. ábra: Felhőszolgáltatások használata az európai kkv-szektorban (2023).....	18
5. ábra: Felhőalapú szolgáltatások használata a magyar és európai kkv-szektorban (2023).....	19
6. ábra: Felhőszolgáltatások használata a magyar vállalatok körében (2014-2021)	20
7. ábra: A mintavétel, mintaelőkészítés, illetve mikroszkópos képek elkészítésének folyamata, anyagai és eszközei	22
8. ábra: A minták sokfélesége: alsóerjesztésű minta sejtflokkulációkkal (B890), illetve felsőerjesztésű minta (B897) (<i>megfestés után</i>)	23
9. ábra: Mintavételezés, különböző minták és előkészítésük (hígítás)	23
10. ábra: Festetlen sejtek fedőlemez nélkül, illetve fedőlemezzel	24
11. ábra: Az összeszerelt rendszer: mikroszkóp, kamera, laptop és megjelenítő szoftver	24
12. ábra: Az objektumdetektáló modell elkészítésének folyamata a Custom Vision platformon.....	26
13. ábra: Custom Vision erőforrások és a projekt létrehozásának beállításai	27
14. ábra: A Custom Vision korlátai: határolódobozok számának limitációja.....	30
15. ábra: A címkézés folyamata: sejt kijelölése és a megfelelő címke hozzárendelése	31
16. ábra: Címkézést nehezítő esetek (balról jobbra): összetapadt-, sarjadzó-, homályos sejtek és szennyeződések	32
17. ábra: A címkék különálló eredményei (Iteration 5, 50% valószínűségi- és 30% átfedési küszöbérték beállítása esetén)	35
18. ábra: <i>Iteration 5</i> - Quick Test eredménye 15%-os valószínűségi küszöbértékkel	36
19. ábra: A Google Colab platformon levő program lefutásának folyamata (jelölések: zöld-Google, kék-Azure).....	37
20. ábra: A Google Colabon készült program felülete.....	38
21. ábra: A felhőalapú képfeldolgozó rendszer felhasználásának és működésének folyamata	39

MATE Szervezeti és Működési Szabályzat

III. Hallgatói Követelményrendszer

III.1. Tanulmányi és Vizsgaszabályzat

6.13. sz. függelék: A MATE egységes szakdolgozat / diplomadolgozat / záródolgozat / portfólió készítési útmutatója

4.2. sz. melléklete: Nyilatkozat a záródolgozat/szakdolgozat/diplomadolgozat/portfólió nyilvános hozzáféréséről és eredetiségéről (módosítva: 2025. október 16.)

NYILATKOZAT

a szakdolgozat¹ nyilvános hozzáféréséről és eredetiségéről

A hallgató neve: Ilyefalvi Hanga Klára
A Hallgató Neptun kódja: H89QA4
A dolgozat címe: Sörélesztő sejtek vitalitásának meghatározása felhőalapú, mesterséges intelligenciát alkalmazó képfeldolgozással
A megjelenés éve: 2025
A konzulens intézetének neve: Élelmiszertudományi és Technológiai Intézet
A konzulens tanszékének a neve: Élelmiszeripari Méréstechnika és Automatizálás Tanszék

Kijelentem, hogy az általam benyújtott szakdolgozat² egyéni, eredeti jellegű, saját szellemi alkotásom. Azon részeket, melyeket más szerzők munkájából vettem át, egyértelműen megjelöltem, és az irodalomjegyzékben szerepeltettem. Továbbá kijelentem, hogy a dolgozat elkészítése során alkalmazott mesterséges intelligencia-eszközök (pl. szöveggenerálás, nyelvi javítás, fordítás, adatelemzés) használata nem helyettesítette a saját kutatási és alkotói munkámat, azok alkalmazását a források között vagy a módszertani részben feltüntettem, és a szakmai-etikai elvárásoknak megfelelően jártam el.

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.

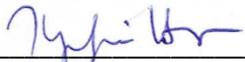
Tudomásul veszem, hogy az általam készített dolgozatra, mint szellemi alkotás felhasználására, hasznosítására a Magyar Agrár- és Élettudományi Egyetem mindenkor szellemi tulajdon-kezelési szabályzatában megfogalmazottak érvényesek.

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 eltelté után

nyilvánosan elérhető és kereshető lesz az Egyetem könyvtári repozitori rendszerében.

Kelt: Budapest, 2025 év 11. hó 03. nap


Hallgató aláírása

¹ A megfelelő dolgozattípus meghagyása mellett a többi típus törlendő.

² A megfelelő dolgozattípus meghagyása mellett a többi típus törlendő.

MATE Szervezeti és Működési Szabályzat

III. Hallgatói Követelményrendszer

III.1. Tanulmányi és Vizsgaszabályzat

6.13. sz. függelék: A MATE egységes szakdolgozat /
diplomadolgozat / záródolgozat / portfólió készítési útmutatója

4.1. sz. melléklete: Konzulensi nyilatkozat

NYILATKOZAT

Ilyefalvi Hanna Klára (név) (hallgató Neptun azonosítója: H89QA4)
konzulenseként nyilatkozom arról, hogy a
~~záródolgozatot/szakdolgozatot/diplomadolgozatot/portfóliót~~¹ áttekintettem, a hallgatót az
irodalmi források korrekt kezelésének követelményeiről, jogi és etikai szabályairól
tájékoztattam.

A záródolgozatot/~~szakdolgozatot/diplomadolgozatot/portfóliót~~ a záróvizsgán történő
védésre javaslom / nem javaslom².

A dolgozat állam- vagy szolgálati titkot tartalmaz: igen nem³

Kelt: Budapest év 2025. 11. hó 03 nap


belső konzulens

¹ A megfelelő dolgozattípus meghagyása mellett a többi típus törlendő.

² A megfelelő aláhúzendó.

³ A megfelelő aláhúzendó.

Hallgatók, doktoranduszok nyilatkozata mesterséges intelligencia (MI) alkalmazásáról

1. Általános adatok

Hallgató neve:	Ilyefalvi Hanga Klára
Neptun-kódja:	H89QA4
Képzési szint (a megfelelőt jelölje X-szel):	<input checked="" type="checkbox"/> BSc/BA <input type="checkbox"/> MSc/MA <input type="checkbox"/> Doktori (PhD) <input type="checkbox"/> Egyéb: TDK
Tantárgy neve/kódja*:	Szakedolgozat
A munka címe:	Sörélesztő sejtek vitalitásának meghatározása felhőalapú, mesterséges intelligenciát alkalmazó képfeldolgozással

* doktori értekezés esetén nem kitöltendő

2. Nyilatkozat az MI használatáról

Alulírott, etikai felelősségem teljes tudatában az alábbi nyilatkozatot teszem:

(Kérjük, válasszon egyet az alábbi lehetőségek közül!)

A) Nem alkalmaztam mesterséges intelligencia rendszert vagy szolgáltatást.

(Amennyiben ezt jelölte, a további táblázatok kitöltése nem szükséges.)

B) Alkalmaztam mesterséges intelligencia rendszert vagy szolgáltatást.

(Kérjük, töltsse ki a vonatkozó táblázatokat!)

3. A mesterséges intelligencia használatának részletezése

I. TÁBLÁZAT: Asszisztensi vagy kisebb mértékű felhasználás (pl. fordítás, nyelvi korrektúra, ötletelés stb.)

(Ezen felhasználások esetében a konkrét promptok és válaszok csatolása nem szükséges.)

A felhasználás célja	Alkalmazott MI-eszköz neve és verziója	Érintett rész (ha nem a szöveg egészére vonatkozik)
szakszavak fordítása, releváns tudományos cikkek keresése	ChatGPT 5	szakirodalmi áttekintés

II. TÁBLÁZAT: Jelentős tartalmi hozzájárulás (pl. egy teljes ábra vagy egy hosszabb szövegrész generálása)

(Ezekben az esetekben a felhasznált kulcsfontosságú promptok és az MI által adott nyers válaszok dokumentálása és a munka **mellékletében való csatolása szükséges.**)

A felhasználás célja	Alkalmazott MI- eszköz neve, verziója, elérhetősége	Az érintett fejezet / ábra / táblázat pontos sorszáma	A prompt-naplót tartalmazó melléklet bejegyzésének sorszáma

3/A. Oktató által előírt kiegészítő szabályok (ha vannak)

Amennyiben az adott tantárgy oktatója vagy témavezetője az MI-eszközök használatára vonatkozóan külön szabályokat vagy elvárásokat határozott meg, kérjük, az alábbi mezőben foglalja össze ezeket:

Pl. az MI használatának tilalma bizonyos feladattípusokra; csak konkrét eszköz használata engedélyezett; eltérő hivatkozási elvárások; dokumentációs forma stb.

Oktató vagy témavezető által előírt szabályok:

.....

.....

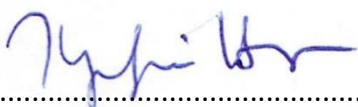
.....

.....

4. Minden hallgatóra vonatkozó nyilatkozat:

Kijelentem, hogy az MI által esetlegesen generált tartalmakat minden esetben kritikailag felülvizsgáltam, szerkesztettem és a munkába illesztettem. A leadott munka minden eleméért, annak eredetiségéért és tudományos helytállóságáért teljes körű felelősséget vállalok. Tudomásul veszem, hogy a Magyar Agrár- és Élettudományi Egyetem a benyújtott munkát mesterséges intelligencia detektorral ellenőrizheti, és eljárást kezdeményezhet, amennyiben a nyilatkozatom valótlan vagy hiányos.

Kelt: Budapest, 2025. október hó 27. nap



Hallgató aláírása



Konzulens/Témavezető aláírása