

# **DIPLOMADOLGOZAT**

**Halek Mtys**

**2023**



Magyar Agrár- és Élettudományi Egyetem  
Élelmiszertudományi és -Technológiai Intézet  
Élelmiszeripari Méréstechnika és Automatizálás Tanszék

## **Mesterséges intelligencia alkalmazása az élelmiszeriparban**

Halek Mátvás

Budapest

2023

# Tartalom

1. Bevezetés .....	6
2. Célkitűzés.....	8
3. Irodalmi áttekintés .....	9
3.1. Mesterséges intelligencia .....	9
3.1.1. Mesterséges intelligencia szerepe és hatása a modern gazdaságokban .....	9
3.1.2. Mesterséges intelligencia az agrárszektorban .....	12
3.2. Mesterséges Intelligencia fajtái .....	14
3.2.1. Machine learning – Gépi tanulás.....	15
3.2.1.1. Gépi tanulás kategóriák.....	16
3.2.2. Mély Tanulás - Deep Learning.....	16
3.2.3. Mesterséges neurális hálózat - Artificial Neural Network.....	17
3.2.3.1. Bemeneti neurális réteg, Input Layer.....	18
3.2.3.2. Rejtett neurális réteg, Hidden Layer.....	18
3.2.3.3. Kimeneti neurális réteg, Output Layer.....	18
3.2.3.4. A mesterséges neuron műveletei .....	19
3.2.4. Természetes nyelvfeldolgozó hálózatok .....	20
3.2.5. Mély mesterséges neurális hálózatok fajtái .....	21
3.2.5.1. Előrecsatló neurális hálózatok.....	21
3.2.5.2. Rekurzív neurális hálózat.....	21
3.2.6. Konvolúciós neurális hálózat - Convolutional neural network.....	23
3.2.7. CNN algoritmus alkalmazásának előnyei.....	24
3.2.8. Mély mesterséges neurális hálók rétegei .....	24
3.2.8.1. Convolution Layer.....	24
3.2.8.2. Teljesen kapcsolt réteg .....	25
3.2.8.3. Aktivációs réteg.....	26
3.2.8.4. Dropout réteg.....	27

3.2.8.5.	Batch normalization.....	27
3.2.8.6.	Pooling réteg.....	27
3.2.8.7.	Flatten layer.....	28
3.2.8.8.	Softmax.....	28
3.2.8.9.	Klasszifikációs réteg.....	28
3.2.8.10.	Egyéb neurális hálóval kapcsolatos fogalmak.....	28
3.2.9.	Mesterséges Intelligencia előnyei és hátrányai.....	29
3.3.	Deep Learning és kemometria kapcsolata.....	30
3.3.1.	Elektronikus orr.....	30
3.3.2.	Elektronikus nyelv.....	31
3.3.3.	Gépi képfeldolgozás.....	31
3.3.4.	NIR.....	31
3.3.5.	NIR mérési eredmények elemzése mesterséges neurális hálózatok felhasználásával.....	32
3.3.5.1.	Előnyök és hátrányok.....	33
3.4.	Fehérjék hamisításának detektálása NIR módszerrel.....	33
4.	Anyagok és módszerek.....	35
4.1.	Szoftver környezet.....	35
4.1.1.	Neural Network designer.....	35
4.2.	Felhasznált adatok.....	35
4.2.1.	Iparból származó adatok.....	35
4.2.2.	Fehérje hamisítás adatsor.....	36
4.3.	Előkezelések.....	36
4.3.1.	Savitzky-Golay.....	37
4.3.2.	Multiplicative Scatter Correction.....	37
4.3.3.	Standard Normal Variate.....	37
4.3.4.	Principal Component Analysis.....	38

4.4.	Adatok particionálása.....	38
4.5.	Alkalmazott Neurális Hálók.....	38
4.5.1.	Darált marhahús hamisításának kimutatása .....	39
4.5.2.	Mély konvolúciós hálózat fejlesztés szenzoros adatok elemzésére .....	41
4.5.3.	Deep learning az analitikai kémia területén.....	43
5.	Eredmények és értékelés.....	45
5.1.	Előkezelések hatása .....	46
5.2.	Darált marhahús hamisításának kimutatása .....	46
5.3.	Deep learning az analitikai kémia területén .....	47
5.4.	Mély konvolúciós hálózat fejlesztés szenzoros adatok elemzésére.....	49
5.5.	Eredményeim összehasonlítása Zinia eredményeivel.....	52
6.	Összefoglalás.....	55
	Irodalomjegyzék.....	57
	Internetes források.....	61

# 1. Bevezetés

Az élelmiszeriparnak számos kihívással kell szembesülnie. Az iparnak olyan jelentős mennyiségű és magas minőségű terméket kell előállítania, amely megfelel a fogyasztók igényeinek, miközben gazdaságilag hatékony módon működik. A "termőföldtől az asztalig" kifejezés tökéletesen tükrözi az élelmiszeripar komplexitását. Az agrárszektor, az élelmiszert feldolgozóipar és az élelmiszer kereskedők láncja olyan tevékenységet folytat, amely kiemelkedő szerepet játszik mindennapi életünkben. Ezért az innováció és technológiai fejlődés ezekben a szektorokban kritikus fontosságú a különböző kihívások sikeres kezelésében.

Magyarországon ma már egyértelműen az Ipar 4.0 elnevezésű fejlődési út áll előttünk. A negyedik ipari forradalom során az ipar digitális átalakulását értjük, ami magában foglalja az adatalapú termelést, irányítást és előrejelzést. Ez a forradalmi folyamat jelentős mértékben növeli a gyártási rendszerek hatékonyságát, rugalmasságát és intelligenciáját. Ennek a fejlődésnek az alapját az egyre elterjedtebb mesterséges intelligencia alapú technológiák biztosítják. Az utóbbi években a mesterséges intelligencia kiemelkedik a fejlesztések középpontjából, és ez az újfajta technológia számos kihívást és kérdést vet fel.

A mesterséges intelligencia olyan számítástechnikai rendszerek összessége, amelyek magas szinten képesek a rendelkezésre álló információ alapján tanulni, dönteni és cselekedni. A mesterséges intelligencia elterjedésével, olyan lehetőség nyílik az ipari szereplők számára, amely egy újfajta térbe helyezi a megszokott módszereket, ezzel segítve az említett kihívások megoldását. Mind a termelékenység növelésében és ellenőrzésében, mind a termelés irányításában és optimalásában, mind a minőség ellenőrzésében és fejlesztésében új lehetőségeket érhetünk el. A mesterséges intelligencia célszerű használatával és annak helyes használatával, új szintet érhetnek el piaci szereplők.

A mesterséges intelligenciákon belül különleges helyett foglal el a Deep Learning. Ez egy olyan gépi tanulási módszer, amely úgynevezett mély mesterséges neurális hálózatokon keresztül képes összetett mintázattokat felismerni és megtanulni. Az ilyen fajta technológia szerteágazó tudományágakban alkalmazható és segítségével fejlesztések hajthatóak végre azokban. Eredményeink pontosabbak lehetnek, és ezeket az eredményeket gyorsabban érhetjük el. Emellett ennek segítségével a korábbi adatsorokban rejlő összefüggéseket is felfedezhetjük, amelyeket a hagyományos módszerekkel talán nem vettünk volna észre, így még tovább javítva a mérések megbízhatóságát.

Diploma dolgozatom témáját tanszéki és intézeti érdeklődés motiválta. A dolgozatomban bemutatott mély mesterséges neurális hálózattal történő adatfeldolgozás, egy jelenleg kifejlődő módszer, amelynek kutatása egy innovatív és előre mutató irányt képvisel. Alkalmazása egy új kutatási területet nyit meg, emellett az élelmiszeriparban való jelentősége nem elhanyagolható. A diploma dolgozat írása során, felismertem milyen gyors ütemben fejlődik ez a tudományág, egyes fogalmakra még magyar kifejezést se alkottunk. Diploma dolgozatommal be szeretném mutatni, milyen nagy potenciál rejlik a mesterséges intelligencia, élelmiszeripari használatában. Úgy gondolom a jelenleg zajló technológiai fejlődésből az élelmiszeriparnak minél jelentősebben részt kell vennie, így haladva a nagyobb mennyiségű, a jobb minőségű és stabilabb élelmiszer termelés felé.

## 2. Célkitűzés

Dolgozatom célja az volt, hogy bemutassam milyen kapcsolatban van és milyen lehetőségei vannak a mesterséges intelligencia alkalmazásának az élelmiszeriparban. Bemutattam az MI gazdasági hatását különböző gazdasági területeken. Sorra vettem az agráriumi és az élelmiszeripari felhasználásukat. Célom, hogy bemutassam mi az a mesterséges intelligencia és hogy kiemeljem annak fontosságát.

Kutatásom során a mesterséges intelligencia egyik alfajával, a Deep Learning csoportjába tartozó Mesterséges Neurális Hálóval dolgoztam fel spektrális adatokat.

Dolgozatomban bemutattam, hogy a hagyományos mérésekhez hasonló, vagy akár jobb eredményeket is produkálhatunk a hálózatok alkalmazásával. Ennek érdekében a témában releváns kutatásokban használt mély mesterséges neurális hálózattokat gyűjtöttem és vizsgáltam. Az alkalmazott technikák eredményességét, Zinia méréseiből származó adatokkal vizsgáltam (Zinia, 2021). Kutatási eredményeit referenciaként használtam, általa végzett klasszifikációhoz hasonló osztályozást végeztem a hálózatokkal. Az adat előkezelések során, Zinia kutatásában található technikákat alkalmaztam. Összehasonlítottam, a különböző összetettségű mesterséges neurális hálózatok teljesítményét és azok pontosságát. Az összehasonlítás szempontjai a modell lefutási ideje, annak stacioner állapotának elérése és az adatok feldolgozása során történő adatvesztés. Legfontosabb szempontként vizsgáltam a klasszifikáció átlagos pontosságát és azt, hogy ezek milyen mértékben változnak egymáshoz képest. Az előbbi szempontok alapján megítéltem a hálózatok megbízhatóságát.



## 3. Irodalmi áttekintés

### 3.1. Mesterséges intelligencia

Mesterséges Intelligencia (MI), Angol nevén Artificial Intelligence (AI), olyan technológiai terület, ahol a gépek, olyan képességeket mutatnak, melyek normális esetben emberi intelligenciát igényelnek (Paschek et al., 2017). Azon technológiák gyűjtőneve, amelyek gépeknek emberihez hasonló gondolkodási képességet adnak. Lehetővé teszi a számítógépek számára, hogy tanuljanak az adatokból, felismerjék a mintákat és önálló döntéseket hozzanak, mindezt emberi beavatkozás nélkül. (Misra et al., 2022).

A mesterséges intelligenciára inkább, mint gyűjtőfogalomra tekinthetünk, mint egy konkrét módszerre.

A mesterséges intelligencia tehát nem csupán programok és algoritmusok halmaza, hanem azoknak az összetett rendszereknek a sorozata, amelyek képesek a környezetük észlelésére, adatok elemzésére, tanulásra, problémamegoldásra és a tanultak alapján cselekvésre vagy ajánlások megfogalmazására (Misra et al., 2022; Paschek et al., 2017).

#### 3.1.1. Mesterséges intelligencia szerepe és hatása a modern gazdaságokban

A mesterséges intelligencia (MI) rohamos fejlődése forradalmasítja a gazdaságot, súlyosan érinti a munkaerőpiacot és mélyen behálózza mindennapi életünket. Gazdasági átalakulás során egyes munkakörök feleslegessé válhatnak, míg mások új lehetőségeket teremthetnek vagy növekedést hozhatnak létre feladatkörökben (Selenko et al., 2022). A MI hatása nem csupán a munkaerőpiacra korlátozódik, hanem kiterjed a pénzügyi, energetikai és logisztikai területekre is, jelentős változásokat indukálva. Ezt támasztja alá, az Európai Parlament cikke (EP 2023) ami szerint a mesterséges intelligencia egy olyan terület, amely széles körben alkalmazható, és számos célra használják, például a gépi tanulásban, az automatizálásban és az adatelemzésben is. A technológia fejlődése potenciálisan forradalmasítja a munkahelyeket és a gazdaságot, amelyről a világszervezet is beszámolt, megvizsgálva a munkahelyek tömeges automatizálásának lehetséges következményeit.

A mesterséges intelligencia hatásai a munkaerőpiacra és a gazdaságra számos kutatás tárgyát képezik. Collins szerint a mesterséges intelligencia fejlesztésébe vett óriási energia okozta fejlődési ütem miatt, ma már nem években, hanem hónapokban vagy napokban érdemes

beszélni arról, milyen új fejlesztések és alkalmazások jelennek meg az MI területén (Collins et al., 2021). Emiatt fontos megérteni, hogy bár növelheti a hatékonyságot és új lehetőségeket teremthet, egyúttal változást is hoz, amelyhez a társadalomnak alkalmazkodnia kell. McKinsey tanulmánya szerint (Fine et al., 2018) a munkahelyek átalakulnak az automatizálás hatására, és fontos, hogy felkészüljünk az MI által hozott változásokra. A változások tehát szerteágazóak, és hatással lehetnek mindennapi életünkre a gazdasági környezet gyakorolt hatása mellett. Az emberi munka és az MI közötti együttműködés és alkalmazkodás kulcsfontosságú lesz a jövőben, hogy kihasználhassuk a technológia nyújtotta előnyöket és minimalizálhassuk a kihívásokat.

Az Európai Parlament szerint (EP, 2023) a jelenlegi munkakörök 14%-át kifejezetten könnyen lehet automatizálni, továbbiakat pedig egészen könnyen megváltoztathat az MI. Nagy Márton gazdaságfejlesztési miniszter szerint a munkahelyek 24%-a van veszélyben az MI-től, aminek jelentős része az úgy nevezett fehér galléros, irodai dolgozók között a legjelentősebb, 45 százalék (Rádi, 2023). Az amerikai Gartner informatikai piackutató vállalat adatai szerint 2020-ig a mesterséges intelligencia 2,3 millió új munkahelyet hozott létre és 1,8 millió munkahely szűnt meg a térnyerésének köszönhetően. Egyes kutatások szerint 2027-re ezek a számok drasztikusan megváltoznak. Az előrejelzések szerint 85 millió állás szűnik majd meg a mesterséges intelligencia fejlődése miatt, ugyanakkor 97 millió új munkahely jön létre (van der Meulen és Pettey, 2017).

Az MI hatásának vizsgálata a munkavállalókra, szorosan kapcsolódik az MI funkcionális képességeihez és annak módjához, ahogy a technológia konkrét munkafeladatokra hat. Funkcionálisan az MI három módon befolyásolja a munkát:

- kiegészítést vagy támogatást nyújt már meglévő emberi munkafeladathoz
- munkafolyamatban helyettesíti az emberi munkát
- teljesen új, korábban nem létező feladatot, munkakört képes létrehozni

Az MI képes meglévő emberi munkafeladatokat kiegészíteni és támogatni. Ez azt jelenti, hogy az MI rendszerek segíthetik és gyorsíthatják a munkavégzést, de nem helyettesítik teljesen az embereket (Selenko et al., 2022). Erre jó példa a mesterséges intelligencia beszivárgása a jogi életbe. Az úgynevezett legaltech alkalmazások lehetőségeket biztosítanak a jogi döntéshozók számára, hogy kevesebb idő alatt pontosabb, adat-vezérelt, szakmai válaszokat tudjanak nyújtani az ügyfeleiknek. Bíróságokon az ítélelhozatalt támogathatják vagy akár típus esetekben, dönthetnek is (Szabó, 2021; Villasenor, 2023).

A Mesterséges Intelligencia alkalmas meglévő emberi munka helyettesítésére. Például automatizálhatja a gyakran ismétlődő feladatokat, ami hatékonyabbá teheti a folyamatokat. A MI lehetővé teszi az ismétlődő időigényes feladatok automatizálását, például az adatfeldolgozást és az ügyfélszolgálatot. (Selenko et al., 2022). A hivatali ügyintézés során a megfelelő dokumentum megtalálásához, kitöltéséhez és beadásához akár MI vezérelt avatárok fogják a segítséget nyújtani a jövőben.

Az MI képes új emberi feladatokat létrehozni, és ennek következtében új munkaszerepeket teremteni. Ez lehetőséget teremthet a munkaerő bővítésére és új készségek kifejlesztésére. (Selenko et al., 2022). Az átalakuló gazdasági rendszer miatt kiszorult munkaerőnek lehetősége lesz a szolgáltató iparágakba átcsoportosulnia, ezáltal az oktatás, mentál higiéniával foglalkozó szakemberek száma bővíthet. Minden olyan szektor, ahol az emberi tevékenység nem mellőzhető, mint például az építőipar, képes lesz bővülni. Már meglévő munkakörökben az MI ismeretének és használatának képessége is megjelenik igényként. Természetesen a mesterséges intelligencia térnyerésével szükség lesz olyan szakemberekre, akik azt üzemeltetik, fejlesztik és védik, mint például kiber védelemmel foglalkozó szakemberek. (Bettina és Szabó Zs., 2022; Menedzsment és Controlling Portál, 2018)

A mesterséges intelligencia terjedése hatalmas gazdasági potenciált hordoz. Gartner cikke szerint (van der Meulen és Pettey, 2017) 2021-ben az MI használatának terjedése, vagyis az általa vagy segítségével elvégzett munka, 2,9 billiárd dollár értékű vállalati értéket generált, ami jelentős előnyöket eredményezett a vállalatok számára. Óriási mennyiségű munkaórát takarított meg, ami azt jelenti, hogy az MI segítette a munkaerő hatékonyságának növelésében és a munkavállalók produktivitásának javításában (van der Meulen és Pettey, 2017).

Az MI képes olyan feladatokat elvégezni, amelyeket emberi erőforrásokkal nehéz lenne vagy nem lehetne megtenni. Ennek eredményeként időt és pénzt takaríthatunk meg. Egyre nagyobb elterjedése hajtóerőként hat más innovációk bevezetésére is. Nagy Márton az AI Summit konferencián mondta el, hogy az MI a GDP 15 százalékát képes lesz előállítani 26 százalékos termelésnövekedés mellett (Rádi, 2023). Állítását alátámasztja, hogy világszinten a mesterséges intelligencia hatékonyságot növelő ereje, valamint katalizáló hatása az innovációk bevezetésére a globális gazdasági növekedés 16 százalékkal felgyorsul 2030-ig (Bihari, 2019).

Az új technológiák bevezetése a kutatásfejlesztésbe és az ipari környezetbe eredményezi és szükségessé teszi a nagymennyiségű adatgyűjtést és azok kezelését. Ezt a nagymennyiségű

adathalmazt, amit mesterséges intelligenciával vagyunk képesek kezelni, nevezzük Big Data-nak. A World Health Organization, WHO szerint a Big Data gyorsan összegyűjtött komplex adatok hatalmas mennyisége (Chowdhary, 2020). Ideális esetben a Big Data-át alkotó adatok tudatosan és célszerűen gyűjtöttek, azonban feltételezzük, hogy az alacsony szinten vagy nem megfelelően digitalizált környezetben is hatalmas mennyiségű információ "bányák" rejtőznek. A Big Data tárhelye elérheti a terrabite ( $10^{12}$  bite), etabite ( $10^{15}$  bite) vagy akár a zettabite ( $10^{21}$  bites) méretet is. Az összegyűjtött adatoknak háromfajta karakterisztikáját különböztetjük meg, volumenitás nagysága, ami az adat mennyiségét jelenti, sebesség nagysága, ami az információ keletkezésének és feldolgozásának nagyságát jelenti és a fajta nagysága, ami az adatok formátumának különbözőségét írja le. Ezek fölött álló alapvető megkülönböztethetőség, hogy az adatok strukturáltak vagy strukturálatlanok (Q. Zhou et al., 2022). Egy másik mesterséges intelligenciára épülő technológiai ág az Internet of Things (IoT), Dolgok Internete. Legtágabb értelemben azokat az eszközöket értjük, amelyek az internet segítségével képesek egymással és felhasználójával kommunikálni, legyen az egy kávéfőző vagy egy épület fűtési rendszere. (Misra et al., 2022)

### 3.1.2. Mesterséges intelligencia az agrárszektorban

A mesterséges intelligencia jelentős hatással van az élelmiszeriparra és a mezőgazdasági termelésre. Az MI segítségével az élelmiszeripar és a mezőgazdaság számos területén innovatív megoldások és automatizációk valósulnak meg. Az agráriumban már a termelés egészen korai szakaszába csatlakoztatható a mesterséges intelligencia (Jia et al., 2019). A levegőből működő drónok segítségével képesek vagyunk meghatározni egy terület termőképességét. Ez a technológia képi és ultrahangos eszközök felhasználásával működik, amelyek segítségével feltérképezzük a talaj vízmegtartó képességét és tápanyag összetételét. Globálisan nézve, ez a technológia olyan hatékony, hogy előrejelzések szerint a mezőgazdaságban használt drónok piaca 2019-es 1 millió dolláros szintjéről várhatóan 2027-re 3,7 millió dollárra növekszik (Ayed és Hanana, 2021). Az olyan nagy vállalatok is, mint a Google vagy a Microsoft beszállt az élelmiszer ipari MI fejlesztésekbe. Habár a Google a Project Mineral néven még csak előkészíti a mezőgazdasági és földművelési területeken történő kutatásait (Markets and Markets, 2023), addig a Microsoft a FarmBeats nevű projektet fejlesztette ki, amely az MI, az Edge és az IoT technológiákra összpontosít a mezőgazdaságban. A céljuk, hogy az agrárfolyamatokat elemezzék, automatizálják és végső soron javítsák azokat, adat alapú megközelítéssel (Vasisht

et al., 2017). Az élelmiszeripar automatizációjának előnyei közé tartozik a termelékenység növekedése és a munkaerőköltségek csökkenése. A növénytermesztésben optimalással képesek ezek a technológiák, növelni a terméshozamot. Az időjárás elemzéssel a megfelelő vetés és aratás időpontját határozzák meg, ezenkívül megtervezik a területek öntözését és egyéb időjáráshoz szorosan kapcsolódó tevékenységet. Robotizált földművelő eszközökkel hatékonyabban, alacsonyabb költséggel képesek megművelni a területeket. Az MI képes felismerni a minőségi hibákat és a termékek állapotát, ezáltal javítva a termékek minőségét és csökkentve a selejtezést. Big Data rendszerek alkalmazásával olyan „okos gazdaságokat” hozhatnak létre a gazdák, amelyben az adat vezérelt tervezéssel és működéssel nő a termelési kapacitás és csökken a termelési költség. Az élelmiszeriparban a Big Data alapú elemző rendszerek piaca 2026-ra eléri a 9,28 billió dollárt (Taneja et al., 2023).

Az élelmiszeriparban a technológiai fejlődés egyre nagyobb szerepet játszik, és ebben az összefüggésben a mesterséges intelligencia és az érzékelő technológiák kiemelkedő fontosságúak. A modern élelmiszeriparban különböző intelligens rendszerek segítenek abban, hogy jobban megértsük az élelmiszerek tulajdonságait és minőségét. Egyik ilyen rendszer például képes arra, hogy a különböző érzékszervi tulajdonságokat, mint az íz vagy az illat, rangsorolja és értékelje. További rendszerek segítenek a vállalatoknak abban, hogy okos döntéseket hozzanak, például, hogy melyik alapanyagot érdemes megvásárolni vagy hogyan lehetne az eljárásokat hatékonyabbá tenni (Mavani et al., 2022; Zhang et al., 2022). Ezen kívül vannak olyan intelligens rendszerek is, amelyek képesek tanulni az adott feladatokból. Ezek a rendszerek nagyon fontosak lehetnek abban, hogy például előre jelezzék egy élelmiszer minőségét vagy eltarthatóságát. Van, ami felügyelet mellett tanul, vagyis egy szakértő irányítása alatt, míg más rendszerek maguktól, anélkül, hogy be kellene programozni őket, találnak megoldásokat az adott problémákra. (Misra et al., 2022)

A gépi tanulás technikák ideálisak bonyolult és változó környezetben, ahol az előre definiált szabályok és képletek hiányoznak. A gépi tanulás és a mesterséges idegi hálózatok az élelmiszer-feldolgozás és az élelmiszer-mérnöki tudomány területén is segítik az adatok pontos feldolgozását, különösen, amikor több bemeneti és kimeneti változóval kell dolgozni. (Guiné, 2019; Mavani et al., 2022)

Az élelmiszeriparban (ahogyan más iparágakban is) az új technológiák és a digitalizáció egyre szélesebb körű bevezetésével olyan mennyiségű adatok keletkeznek, amelyek létrejöttéhez, igen nagy kapacitású számítástechnikai rendszereket kell létrehozunk. A jelenleg zajló ipar 4.0, vagyis a negyedik ipari forradalom, melynek lényege az intelligens

automatizálás, legjelentősebben az autóiiparban, elektronikai iparban terjedt el, azonban lassan az élelmiszeriparba is beszivárog. Becslések szerint az élelmiszeriparban alkalmazott technológiák 80%-a más iparágakban alkalmazott automatizált technológiákkal már megoldhatóak és csak a maradék 20% esetében lenne szükség teljesen új kutatás-fejlesztésre (FÉSZ, 2019). A termelés közben nyert adatok lehetőséget biztosítanak a termékfejlesztésben, a minőségbiztosításban a folyamatok optimalizálásában és felgyorsításában. (Zhang et al., 2022)

Összefoglalva, az MI és az érzékelő technológiák összehangolása lehetővé teszi a komplex élelmiszeripari problémák megoldását, a minőség javítását és a hatékonyság növelését, és ebben a mesterséges neurális hálózatok széleskörű alkalmazásokat mutat. A jövőben a mesterséges intelligencia tovább fog terjedni, és tovább erősíti az élelmiszeripar versenyképességét.

### 3.2. Mesterséges Intelligencia fajtái

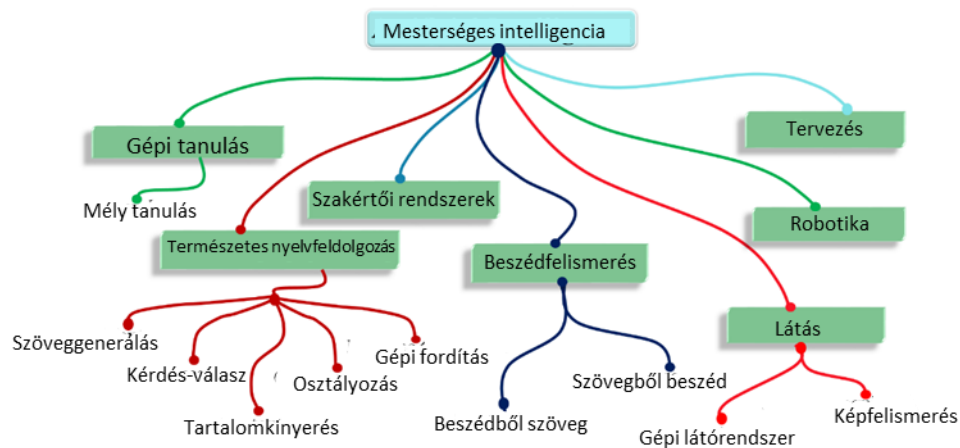
Mivel a hatalmas mennyiségű adatot, változatos forrásból és különböző módszerrel nyerjük ki szükség van fejlett, nagyhatékonyságú adatfeldolgozásra. Adatainkat különböző eljárásokkal tehetjük könnyebben vagy egyáltalán értelmezhetővé. Ezeket a matematikai modelleket és eljárásokat olyan magas szinten, elvégezni, ami belátható időn belül számunkra értékes információt nyújtanak, csakis az adatfeldolgozás már régóta kutatott módszerével lehetséges. A mesterséges intelligencia irányába mutató kutatások a számítógép megjelenésével egyidejűen kezdődtek el. A mesterséges intelligenciák olyan programok, amelynek létrehozói arra törekednek, hogy a program az emberi gondolkodáshoz felérjen és azt utánozza. (Misra et al., 2022; Q. Zhou et al., 2022)

Két csoportba kategorizálhatjuk a MI-t erős és gyenge mesterséges intelligencia. Míg az igazi sci-fi -ből ismert „erős” MI nem létezik, amely képes lenne, olyan módon, önállóan gondolkodni és döntéseket, hozni, mint egy emberi lény, mára igen magas szintre jutottak a keresőmotorokat alkalmazó, szöveget és grafikát alkotó programok (Gülen, 2023).

Ahogy korábban jellemeztem a mesterséges intelligenciát, a gyenge MI vagy Narrow AI már létezik és mindennapjaink része. Fontos tulajdonságai, hogy adott környezetben korlátozott feladatokat képes önállóan elvégezni, emberi beavatkozás nélkül, amelynek

eredménye nagyban függ a bemenő adatok mennyiségétől és minőségétől. Nem képes általános feladatokat vagy ismereteket elsajátítani (Gülen, 2023). Mivel a mesterséges intelligencia egy régóta és sokrétűen kutatott tudományág, különböző fajtáját/módját különböztetjük meg, ezek különböző szinteket is érnek el.

A mesterséges intelligencia fogalma alá, összetettségük alapján több technológiát is besorolhatunk. (1. ábra) A gépi tanulás a mesterséges intelligencia egy olyan területe, amely algoritmusok segítségével hajt végre adatbányászati feladatokat. A mesterséges neurális hálózatok agyunk idegsejtjeinek működését imitáló rendszerek, melyek képesek bonyolult összefüggéseket dekódolni.



1. ábra Mesterséges Intelligencia alá tartozó fogalmak (Misra et al., 2022)

### 3.2.1. Machine learning – Gépi tanulás

Olyan számítógépes algoritmus, amely működése során szerzett "tapasztalatai" alapján fejlődik (Mavani et al., 2022). Az algoritmus tapasztalatai a bemeneti adatok, így a gépi tanulás adatok perspektívájára épül fel. A gépi tanulási hálózatok bemenetére rendezetlen adatok érkeznek, amelyből a korábbi tanítások alapján, "rendezett" adathalmazt – számunkra értelmezhető információt ad vissza (Q. Zhou et al., 2022). A gépi tanulás algoritmusai nem csak adatok feldolgozására képesek, de képesek "tanulni" és fejlődni. Azonban az algoritmus hatékonysága és alkalmazhatósága különböző faktoroktól függ (Mahesh, 2018). A különféle problémák és változók egyedi algoritmusokat és modelleket igényelnek.

### 3.2.1.1. Gépi tanulás kategóriák

A felügyelt tanulás célja, hogy a meglévő bemeneti eszközkészletből jósolja meg a kívánt kimenetet, így bemeneti adatai megcímzett adatok míg a validálást ismeretlen adathalmazon végezzük. A felügyeletlen tanulás során, nincsen előre jelezhető kimenet, a tanulást ismeretlen adatokon történik és a kimenete az adatokat előfordulása alapján osztályozza szintén ismeretlen adatokon való gyakorlással. A megerősítő tanulás során a környezet és a program között kölcsönhatás van. A tanulás során visszajelzést kap a rendszer, ami, létrehozza a kapcsolatot a program és a környezet között (Mavani et al., 2022; Q. Zhou et al., 2022). A reprezentációs tanulás során az algoritmus automatikusan megjelenít az osztályozáshoz vagy észleléshez tartozó nyers adatokból, jellemző tanulásként is ismert (Q. Zhou et al., 2022).

### 3.2.2. Mély Tanulás - Deep Learning

A Mélytanulás (ML) angolul Deep Learning (DP) a gépi tanulás mostanra legelterjedtebb ága, ami olyan kimagasló eredményeket képes elérni, ami lekörözi az emberi teljesítményt. A nagyobb számítási képességekkel rendelkező berendezéseink kapacitásával, új lehetőségek nyíltak az adatfeldolgozásra, ami mélyebb ábrázolásra ad lehetőséget, a gépi tanulás terén (Alzubaidi et al., 2021). A reprezentációs tanulás nem ad lehetőséget arra, hogy a gép a nyers adatokból érzékeljen, klasszifikációt vagy regressziót végezzen. A Deep Learning (DL, vagy Mély tanulás) egy olyan többszintű reprezentációs gépi tanulás, ami kihasználja a neurális hálóok összetettségét és hatalmas adat mennyiséget képes feldolgozni és megismerni. Ez a különböző szintű és mélységű összetettség adja a Deep Learning előnyeit (L. Zhou et al., 2019).


Egy Deep Learning rendszerében a bemeneti réteg minden mintát egy pontként ír le az adott dimenzióban. Az első hidden, rejtett réteg erről a bemeneti jelről képez egy absztraktabb mintát azzal, hogy a réteg csomópontjai bináris alapon felosztják az input dimenziókat pontokra, a neuronok régióiban. Vagyis elosztódnak a réteg neuronjai között, ezután a második rejtett réteg az előző réteg alapján a különböző neuron csoportokra került inputok alapján, információkat generálnak, így az információ már valamilyen szemantikával bír, vagyis jelentésük van, például a minta milyen spektrum csoportba tartozhat. (Theodoridis, 2015). Ezen logikát követve a további rejtett rétegek további információval látják el a kezdeti bementi jelet, így pontosítva annak tulajdonágát.



Olyan területeken sikeres a DL, mint a kép felismerés, kép szegmentálás, tárgy felismerés vagy klasszifikációs, vagy regressziós feladatok (Q. Zhou et al., 2022).

### 3.2.3. Mesterséges neurális hálózat - Artificial Neural Network

A mesterséges neurális hálózat, angolul Artificial Neural Network (ANN), vagy Deep Artificial Neural Network (DANN) (Theodoridis, 2015). Olyan hálózatba szervezett számítások összessége, amellyel a tervezői arra törekednek, hogy egy adathalmazból hasznos információkat nyerjenek ki, ami más eszközökkel, hosszabb és nehezebb lenne. Nevét az agyunkat felépítő neuronokhoz hasonló összetettsége és számítási kapacitásából fakadóan kapta (Q. Zhou et al., 2022). Egy neurális hálózat egy algoritmusokból álló sorozat, amelynek célja, hogy felismerje az adatok mögött meghúzódó kapcsolatokat, egy olyan folyamat során, ami az emberi agy működését utánozza. Ebben az értelemben a neurális hálózatok rendszereket jelentenek, amelyek neuronokból állnak, legyenek azok organikusak vagy mesterségesek (Mahesh, 2018). A mesterséges neurális hálózatok három fő rétegből állnak: bemeneti, rejtett és kimeneti réteg, amelyek együttműködve képesek változó bemeneti adatokhoz alkalmazkodni (2. ábra).



2. ábra Mesterséges Neurális Hálózat ábrája e(Alzubaidi et al., 2021)

A rejtett réteg feldolgozza a bemeneti adatokat, míg a kimeneti réteg a számított eredményt továbbítja (Guiné, 2019; Mahesh, 2018). A neurális hálózatok mesterséges intelligencia alapú módszerek, amelyek gyorsan terjednek és a lehető legjobb eredményeket nyújtják, a megfelelő tervezéssel.

A Neurális Hálók (NH) típusától függetlenül egy bemeneti (INPUT) és egy kimeneti (OUTPUT) réteggel (layer) rendelkeznek. Ezek között találhatóak meg a rejtett rétegek (hidden layer), amelyek lényegében meghatározzák neurális hálók tulajdonságait, ami igen sokrétű az adatelemzéstől a képfeldolgozásig. Használatuk széleskörűen elterjedt különböző tudományágakban mivel nemlineáris, nagy pontosságú, modellektől független, könnyen alkalmazható és általánosítható.(Mavani et al., 2022)

#### 3.2.3.1. Bemeneti neurális réteg, Input Layer

Ez a réteg felelős az információk, jelek, jellemzők vagy mérések fogadásáért a külső környezetből. Ezeket a bemeneteket, amelyek minták vagy sablonok lehetnek, általában normalizálják az aktivációs függvény határain belül. Ez a normalizáció javítja a hálózat által végzett matematikai műveletek numerikus pontosságát (Demuth és Beale, 1992).

#### 3.2.3.2. Rejtett neurális réteg, Hidden Layer

Egy neurális hálózatban lehet egy vagy több elrejtett réteg. Az elrejtett rétegek kulcsfontosságú szerepet játszanak a neurális hálózatok kiváló teljesítményének és komplexitásának kialakításában. A hálózat belső feldolgozásának nagy részét ezek a rétegek végzik. Ezen rétegek egyidejűleg több feladatot végeznek el, mint például az adattranszformáció és automatikus jellemzők generálása (Demuth és Beale, 1992).

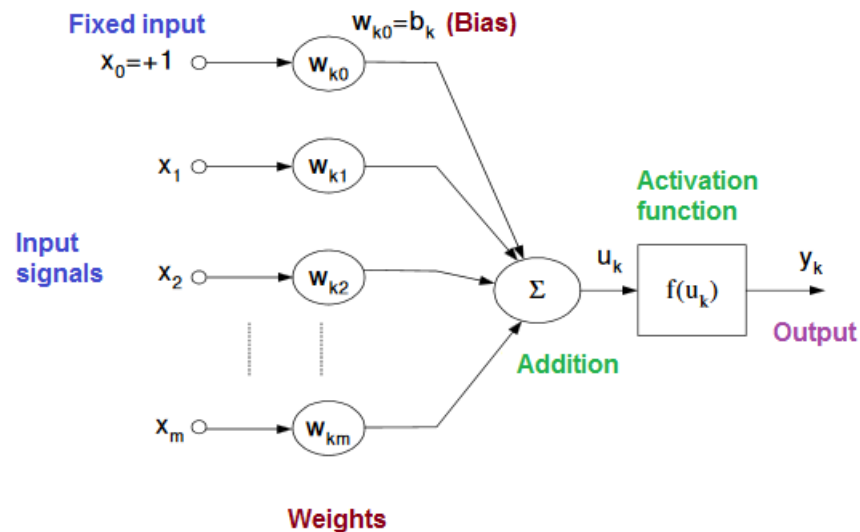
#### 3.2.3.3. Kimeneti neurális réteg, Output Layer

Az utolsó réteg típusa a kimeneti réteg. A kimeneti réteg tartalmazza a probléma eredményét vagy kimenetét. A nyers jelek a bemeneti rétegen haladnak át, és a kimeneti rétegen kapjuk meg az eredményt. Ez a réteg szintén neuronokból áll, ez a réteg felelős a végső hálózati kimenetek előállításáért és bemutatásáért, amelyek az előző rétegekben található neuronok által végzett feldolgozás eredményei. (Demuth és Beale, 1992)

### 3.2.3.4. A mesterséges neuron műveletei

A mesterséges idegi hálózat egy számítási modell (3. ábra), amelyben különböző, mélységével összefüggő számú kapcsolatok találhatóak, a kapcsolatok, meghatározott súllyal rendelkeznek. A kapcsolatok bemeneteiből érkező jelek az adott súlyozási tényezővel beszorzódnak majd összeadódnak más jelekkel, amik a megfelelő súlyozási tényezőkkel szorozódtak meg. A súlyok lehetnek pozitív vagy negatív valós számok (Guiné, 2019).

- A jel megjelenik, mint bemenet (input) ( $X_1$  -től  $X_m$ )
- Minden jel megszorozódik a súllyal ( $W_k$ ), amely jelzi a hatását a kimeneti egységben
- Minden jel súlyozott és hozzáadott aktivitást eredményez ( $U_k$ )
- Az aktiváló funkció  $f(U_k)$  korlátozza a kimenetet és bevezeti a nemlinearitást a modellbe
- Az állítható paraméter (bias) ( $b_k$ ) feladata, hogy növelje vagy csökkentse a bemenetek befolyását. A bias egy bemeneti állandó érték amely egyenlő 1-gyel, megszorozva a  $b_k$  -súlyával (Guiné, 2019).



3. ábra Neuronok működése (Guiné, 2019)

Számos réteg található egy hálózatban, amelyek, önálló változónak felelnek meg. Általában a rejtett rétegek száma nő az input egységek számának növekedésével és a probléma komplexitásának növekedésével. Túl sok rejtett réteg túlillesztéshez vezethet, amíg a túl kevés, alacsony pontosságú modelleket eredményez. Az output réteg egy vagy több kimeneti egységgel rendelkezhet, és a függő változókhoz társul (Guiné, 2019).

### 3.2.4. Természetes nyelvfeldolgozó hálózatok

Angolul Natural Language Processing, NLP olyan neurális hálózatok, amely a nyelvtudományok terén mutatnak kimagasló teljesítményeket. Beszédfelismerés, szöveg generálás és írott dokumentumok feldolgozására és ellenőrzésére képesek (Chowdhary, 2020). Térnyerésük, látványos a hang alapon vezérelhető alkalmazások, automatizált ügyfélkezelő rendszerekben. Az egyik és népszerű példája, a ChatGPT.

ChatGPT-t a vezető, mesterséges intelligencia kutatási szervezet, az OpenAI alapította. ChatGPT fejlesztése egy jelentős mérföldkövet jelent az AI-alapú természetes nyelvfeldolgozás fejlődésében, 2022 novemberében vált elérhetővé (Lo, 2023). Az OpenAI először a GPT, Generative Pre-trained Transformer, sorozat kiadásával vált ismertté, amely az alapját adta ChatGPT-nek. A ChatGPT kifejezetten a beszélgetésalapú MI képességek fejlesztésére összpontosít. Felhasználása kiterjed az egyszerűszövegek megfogalmazásától, ami magába foglalja a vers írást és tudományos szövegek megfogalmazását, a program kódok generálásáig. A már megírt programkódok javítását is képes elvégezni. Képes segíteni az online keresésben, fogalmazásban és komplex fogalmak értelmezésében, különböző nyelveken. (Deng és Lin, 2022)

A ChatGPT egy olyan neurális hálózatot alkalmaz, amelynek fő célja a szöveg generálása. A Természetes Nyelvfeldolgozás (NLP) egy olyan terület, amely a számítástechnika és nyelvészeti tudományok közötti kapcsolatból született. Az NLP célja, hogy lehetővé tegye számítógépek számára az emberi nyelv megértését, feldolgozását és válaszadását. (Chowdhary, 2020). A ChatGPT olyan neurális hálózat, ami képes pontosabb válaszokat generálni, mint a manuális beszélgetések. Ennek az az oka, hogy egy nagy beszélgetési adathalmazon van trénelve, ami lehetővé teszi számára a beszélgetés kontextusának megértését és megfelelő válaszok generálását. (Deng és Lin, 2022)


A ChatGPT és a hozzá hasonló alkalmazások hatása sokrétű. Az oktatásban igen elterjedt a diákok körében. Egyrészt megkönnyíti a kutatást és segíti a tanulást, mivel igen hatékonyan tud több témában is választ adni. Azonban nem szabad elfelejteni a veszélyét, hogy válaszai nem mindig pontosak, sőt akár megtévesztőek is lehetnek (Lo, 2023). Kiváló fogalmazó képessége miatt azonban elősegíti a diákok nem éppen igazságos előnyhöz jutását. Használatával akár egy 1000 szavas esszét is létre lehet hozni, bármilyen témában. A gondosan megfogalmazott szövegből pedig nem lehet megítélni milyen mértékben a diák saját munkája. (Lo, 2023), (Deng és Lin, 2022). Hasonló jelenség látható a munka világában is.

A ChatGPT megjelenésével, bizonyos munkakörök is megváltoznak. Egyre több munkahely használja adatok rendszerezésére, információk gyűjtésére, esszék megírására vagy akár programozásra. Bizonyos képességeket, mint az alacsonyabb szintű programozások, a ChatGPT segítségével mindenki számára elérhetővé váltak, a gyors és hatékony adatgyűjtése miatt pedig nagymértékben leeredukálható az adatkezeléssel kapcsolatos feladatok. (Deng és Lin, 2022; Zarifhonarvar, 2023)

### 3.2.5. Mély mesterséges neurális hálózatok fajtái

#### 3.2.5.1. Előrecsatló neurális hálózatok

Ezek a hálózatok gyakran kerülnek alkalmazásra mintaosztályozási és lineáris szűrési problémákban. Az információ mindig egyetlen irányba halad, vagyis a bemeneti rétegtől a kimeneti rétegig ciklusok nélkül (da Silva et al., 2017). Adott bemeneti adatokat az előre csatolt hálózatok egy meghatározott, korlátozott számú lépésben dolgozzák fel az információvá. A 4. ábrán látható, hogy a  $v_1$  és  $v_2$  neuron a bemeneti réteg, ezért ezeknél inicializációra van szükség. A neuronok között nincsen visszacsatolás. A csomópontokat rétegekben lehet elrendezni, amit az szabályoz, hogy egy adott réteg csomópontjai csak az azt megelőző rétegtől kaphatnak bemeneteket. (Hrycej et al., 2023)




4. ábra Feedforward neurális hálózat (Hrycej et al., 2023)

#### 3.2.5.2. Rekurzív neurális hálózat

Az RvNN, más néven Feedback hálózatok, a mesterséges neurális hálózatok egy speciális kategóriáját képezik, amelyeket kifejezetten komplex struktúrák, például fák vagy gráfok

elemzésére tervezték. A visszacsatolt hálózatok különösen előnyösek dinamikus folyamatok, mint a beszélt nyelv, vagy fizikai és gazdasági rendszerek modellezésében. Ellentétben a feedforward neuális hálózatokkal, amelyek szigorú sorrend szerint dolgozzák fel az adatokat, a hálózatot egy ismert vissza-terjesztett struktúrán keresztül tanítjuk. A hálózat egy autoasszociációs módszerrel tanul, vagyis megpróbálja az input rétegben látható mintázatot az output rétegben reprodukálni, alkalmazva ugyanazt az architektúrát a bemenet különböző szegmenseire. (Alzubaidi et al., 2021)




5. ábra Feedback Network (Hrycej et al., 2023)

Egy ilyen hálózatot például úgy kaphatunk, ha egy előre csatolt hálózatot módosítunk: kapcsolatot teremtünk  $v_3$  és  $v_4$  csomópontok közé, és megfordítjuk  $v_3$  és  $v_5$  közötti kapcsolatot. Ezzel a módosítással létrejön egy ciklus a  $v_3$ ,  $v_4$  és  $v_5$  csomópontok között, ami megsérti az előre csatolt hálózatokra vonatkozó, nincs-ciklus szabályt. A hálózat továbbá nemlineáris jellegű, és az ilyen rendszerek viselkedése rendkívül komplex lehet. A  $v_1$  és  $v_2$  csomópontoknak nincsenek elődjei, ezért nekik kezdeti értékeket kell hozzárendelni (Hrycej et al., 2023).

Amennyiben a bemeneti adatok nem állandóak, például egy változó vektorminták sorozatát kapja a hálózat, a csomópontok reakcióideje is ingadozhat. Ezt a változó késleltetést a minták variációja befolyásolja, és a dinamikus rendszerek terminológiájában ezt a fázist jelátvitelnek nevezik (Hrycej et al., 2023). A rekurzív neurális hálózatok (RvN) képesek változó méretű és lépésszámú bemenetek feldolgozására. különösen hasznosak a természetes nyelvfeldolgozó hálózatok területén (Alzubaidi et al., 2021).

### 3.2.6. Konvolúciós neurális hálózat - Convolutional neural network

A konvolúciós neurális hálózat, vagy angolul CNN, egy felügyelt mélytanulási algoritmus, amely különösen hatékony bonyolult és ismétlődő adatok, valamint magasrendű szerkezeti jellemzők kezelésében (Jiang et al., 2021). Az algoritmus egyik legnagyobb előnye, hogy képes automatikusan kiválasztani a releváns jellemzőket és paramétereiket megosztani, mindezt emberi beavatkozás nélkül. Ezen tulajdonságoknak köszönhetően a CNN helyi kapcsolatokkal és megosztott súlyozásokkal dolgozik, ami alkalmassá teszi 2D bemeneti adatok, például képek feldolgozására. Az algoritmus hatékonyan működik még alacsony adatsűrűség mellett is, így egyszerűsítve a tanulási folyamatot és gyorsítva a hálózatot (Alzubaidi et al., 2021). A Konvolúciós neurális hálózat felépülését a 6. ábrán mutatom be.



6. ábra Convolutional Neural Network felépülése (da Silva et al., 2017)

Ez a fajta automatizált jellemzőfelismerés és adatredukció teszi a CNN-t kiválóan alkalmassá komplex adatok feldolgozására is, így például a kemometriában alkalmazott mérési eredmények elemzésére (Debus et al., 2021). A hálózat kis magmátrixai képesek az adathalmaz specifikus részeinek kiemelésére és elemzésére, ami különösen hasznos lehet többváltozós, összetett adatoknál. A CNN ezen tulajdonságai révén gyors és pontos analízist tesz lehetővé, ami elengedhetetlen a kemometriai alkalmazásokban. (Alzubaidi et al., 2021) A konvolúciós réteg nagyban hozzájárul a neurális hálózatok mélységéhez, ezért a deep learning szóból és a convolution neural network szavakból DCNN monogramként is szoktak rá hivatkozni. A 7.

ábrán láthatjuk, a konvolúciós neurális hálózat elhelyezkedését a mesterséges intelligencián belül.



7. ábra CNN elhelyezkedése az MI-ben, saját.

### 3.2.7. CNN algoritmus alkalmazásának előnyei

1. Megosztott súlyozások, csökkentik a hálózat tanítható paramétereinek számát, és ezzel segítik a hálózat általánosításának javításában és az overfitting elkerülésében (Alzubaidi et al., 2021).
2. A tulajdonság kinyerő (feature extraction) réteg és az osztályozó réteg párhuzamos tanítása miatt a modell kimenete rendkívül szervezett és erősen támaszkodik a kinyert tulajdonságokra (Alzubaidi et al., 2021).
3. A nagyméretű hálózatok megvalósítása sokkal egyszerűbb a CNN-ekkel, mint más neurális hálózatokkal (Alzubaidi et al., 2021).

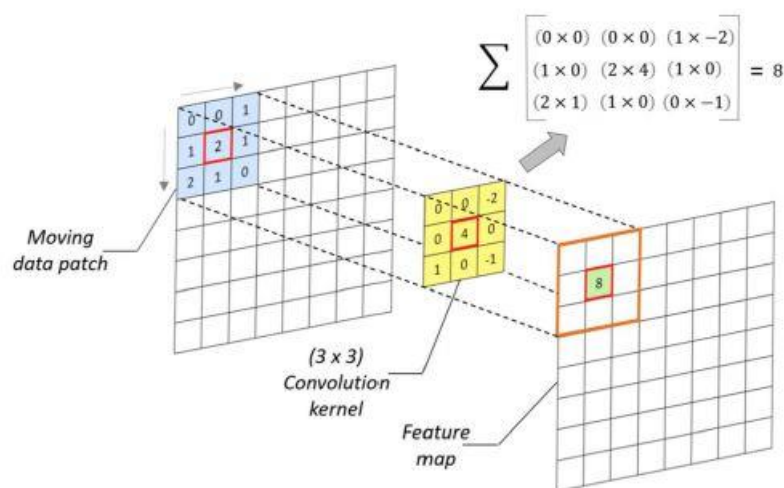
### 3.2.8. Mély mesterséges neurális hálók rétegei

#### 3.2.8.1. Convolution Layer

A konvolúciós réteg alapvetően két módon működik: a rétegek közötti kapcsolódások szigorúan meghatározott módon kerülnek korlátozásra, a paraméterek közösek és megosztottak



az egész rétegben. (Hrycej et al., 2023). A hálózaton belül több konvolúciós réteg előrehaladásán keresztül mind a helyi, mind a globális jellemzők pontosan azonosíthatóak és kinyerhetőek (Jiang et al., 2021). A konvolúciós réteg egy meghatározott méretű mátrixot (szűrő vagy kernel), ismételve továbbít egy bemeneten, amit a kernelből kapott értékek alapján átalakít. Az ismételt „feltérképezés” egy olyan aktivizációs térképet eredményez, ami az észlelt bemeneti jel erősségeit jelöli (Benson et al., 2023). Az 8. ábrán egy 3x3-as kernel működése látható. A konvolúciós réteg egy olyan operátor segítségével van definiálva, amely egy véletlenszerűen inicializált súlyparaméterekkel rendelkező szűrőként van implementálva. Ez az operátor azonos paraméterekkel ismétlődik minden egyes pixel környezetére az előző réteg kimenetéből (Debus et al., 2021).



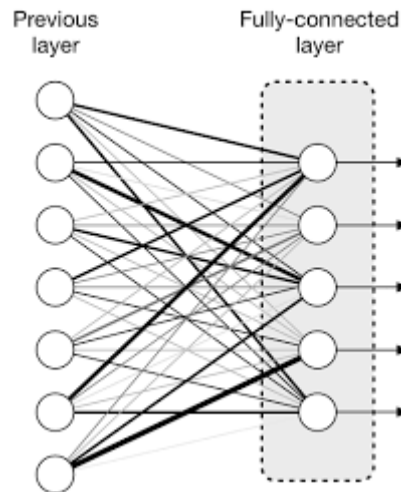
8. ábra CNN kernel szűrő működése 3x3-as méret esetén. (Debus et al., 2021)

Ez a mechanizmus hasonló egy matematikai konvolúciós művelethez, amelyik egyik függvényt elcsúsztatja a másik fölött, majd kiszámolja a pontonkénti szorzásuk integrálját (Benson et al., 2023). Részben a kernelek ismétlődő működése miatt rendelkeznek a konvolúciós réteg a korábban jellemzett előnyökkel, mint a megosztott súlyozás.

### 3.2.8.2. Teljesen kapcsolt réteg

Dense Layer, magyar fordításban teljes kapcsolatú réteg. Működése során lineárisan leképezi a bemeneti vektort egy másikra súlymátrix segítségével. A két szomszédos réteg közötti neuronok páronként kapcsolódnak egymáshoz, így minden neuronját összekapcsolja a szomszédos rétegekben található neuronokkal. (Cui és Fearn, 2018). A rétegek közötti


kapcsolatok teljesen közvetettek, ami azt jelenti, hogy nincs speciális mintázatfelismerés vagy konvolúció alkalmazva. Minden bemenet kapcsolódik minden kimenethez. A fully connected neural network rendszerint a bemeneti rétegből, egy vagy több rejtett rétegből és a kimeneti rétegből áll. A kimeneti réteg szokásosan a várt eredményeket vagy predikciókat generálja. (Debus et al., 2021; Jiang et al., 2021)



9. ábra Teljesen kötött réteg működési ábrája. Előző réteg (Previous layer) Teljesen kötött réteg (Fully-connected layer) (Jiang et al., 2021)

### 3.2.8.3. Aktivációs réteg

A Fully connected és Convolution Layer-t is aktivációs réteg követ, ennek célja a nem linearitás elérése, ezt az adott kimenet szabályozásával érik el az alapján, hogy a bemenet milyen értéket vesz fel (Cui és Fearn, 2018). Rectified linear units, ReLU a negatív bemeneti értékeket nullára állítja, míg a pozitív értékek változatlanok maradnak, egyszerűsége miatt elterjedt a használata, azonban, ha egyes neuronok bemenete mindig negatív, ez a funkció hibát okozhat (Debus et al., 2021). Ehhez hasonlóan működik az Exponential linear units, ELU ami a 0 értékkel alakítás helyett, exponensé alakítja az értékeket (Cui és Fearn, 2018).



10. ábra Aktivációs rétegek működése ReLU esetében (Debus et al., 2021)

#### 3.2.8.4. Dropout réteg


A túltanulás, vagy az overfitting elkerülésének érdekében, jellemzően a fully connected réteg esetében, Dropout réteget használunk. Feladata, hogy eltávolítsa a kevésbé informatív, tanulható paramétereket, úgy, hogy bizonyos valószínűséggel, aminek jellemző értéke 0,5 (50%), leállítja a neuronok működését (Wang et al., 2020a). A neurális hálózatok rejtelmességéhez a dropout rétegek kiemelten hozzájárulnak. Mivel nem ismerjük, pontosan melyik neuronokat kapcsolják ki ezért növelik a hálózat eredményének változékonyságát.

#### 3.2.8.5. Batch normalization

Batch normalizálás, célja a nagy adathalmazok feldolgozásának gyorsítása és a túlillesztés megelőzése. Aktivációs rétegek előtt használjuk. Alapelve az, hogy a tanító adathalmazt kisebb részegységekre, batch-ekre bontja, minden egyes batch segítségével a modell paraméterei frissülnek (Cui és Fearn, 2018).

#### 3.2.8.6. Pooling réteg

Pooling Layer, összehúzó réteg feladata az, hogy összefoglalja a hasonló tulajdonságokat egyetlen tulajdonságban, általában úgy, hogy kiválasztja a helyi tulajdonságok közül a maximális vagy átlag értékeket. Ennek az eljárásnak az eredményeként a tulajdonságok dimenziója tovább csökken, és rendezettség, hoz létre (Yang et al., 2019a). Ilyen az általam is alkalmazott Max-pooling, amely, eltávolítja a dimenzió egy meghatározott mennyiségét. Ennek eredményeként csökken a feldolgozandó adatok mennyisége, ami gyorsítja a hálónkat, emellett kiszűri a nem használható adatok mennyiségét (Debus et al., 2021).



11. ábra Max-pooling működése (Debus et al., 2021)

### 3.2.8.7. Flatten layer

Flatten layer, laposító réteg, alkalmassá teszi a bemeneti adatokat olyan formává, amely alkalmas a további rétegek számára. Fully Connected rétegek után elengedhetetlen és általában az utolsó rétegek között helyezkedik el (Debus et al., 2021).

### 3.2.8.8. Softmax

Softmax rétegek is az aktivációs rétegek közé tartozik, használata igen gyakori a klasszifikációs kimenetek előtt. Ez a réteg valószínűségi eloszlást hoz létre, az előre meghatározott csoportok szerint (Debus et al., 2021).

### 3.2.8.9. Klasszifikációs réteg

Classificationlayer, végzi el a valós klasszifikációt az előzőleg feldolgozott adatok alapján. Ez egy kimeneti réteg, amely az eredményt adja számunkra és meghatározza, milyen pontossággal történik az osztályozás (Wang et al., 2020b).

### 3.2.8.10. Egyéb neurális hálóval kapcsolatos fogalmak

Epoch, kifejezést használjuk az iteráció vagy ciklus kifejezés helyett, a tanító folyamat jelzésére. Egy epoch azt jelenti, hogy minden tanító mintának van egy előre-és hátrafelé irányuló átvonulása (Cui és Fearn, 2018).

Batchsize, vagy MiniBatchSize magyarul adott adat tételnek fordíthatjuk. A tanító adathalmaz részhalmaza a gradiens kiértékeléséhez és a súlyok frissítéséhez. Meghatározza az adatmennyiséget, amely egyszerre kerül átadásra a hálózatnak a tanulási fázisban (Cui és Fearn, 2018).

Tanulás rátája, Learning Rate meghatározza, milyen gyorsan frissítjük a hálózat súlyait. Túl magas tanulási rátával a modell nem tanul megfelelően, míg túl alacsony értékkel a tanítási folyamat túl lassú lehet (Demuth és Beale, 1992).

Hiperparaméterek, angolul hyperparameters, olyan paraméterek, amelyeket a tanítási folyamat előtt kell beállítani egy neurális hálózatban, és nem változnak meg a tanítási folyamat során. Ezek a paraméterek befolyásolják a tanítási dinamikát és a modell teljesítményét (Demuth és Beale, 1992).

Overfitting, vagy is a túlillesztés, gyakori kihívás a modell illesztés során. Ez a hiba fent áll, ha az ANN modell túlságosan szorosan illeszkedik a tanító adatokhoz. Ennek eredményeként pontos előrejelzéseket ad a tanító adatokra, de gyenge teljesítményt nyújt új, ismeretlen adatokkal szemben, eredményeként a modell inkább a tanító adatokat memorizálja, mintsem általánosítani próbálna belőlük. Az ilyen túlillesztett modelleknek nehézséget okoz pontos előrejelzések nyújtása az új adatok számára, végül is aláásva ezáltal hasznosságukat (Ying, 2019).

### 3.2.9. Mesterséges Intelligencia előnyei és hátrányai

A neurális hálózatok a mesterséges intelligencia egyik legígéretesebb területei, amelyek széles körben használtak komplex problémák megoldására. Ugyanakkor, mint minden technológia, a neurális hálózatoknak is vannak előnyei és hátrányai, amelyeket alaposan meg kell vizsgálni.

Az egyik legnagyobb előny, hogy a neurális hálózatok képesek pontosan és könnyedén modellezni komplex függvényeket és problémákat, miközben rezisztensek a zavarokra és a zajra. Ezen kívül, képesek tanulni a mintákból és példákból, rendelkeznek általánosítási képességgel, és megfizethető, könnyű és rugalmas módszert kínálnak (Theodoridis, 2015). Különösen hasznosak nemlineáris problémák megoldásában, amelyek más módszerekkel nehezebben kezelhetők (Paschek et al., 2017).

Ugyanakkor, van néhány hátránya is. Például, a modell teljesítménye nehezen magyarázható meg, mivel gyakran "fekete doboz" modelleknek számítanak, amelyek belsejébe nehezen lehet betekinteni. Továbbá, több időt és erőforrást igényelnek a megfelelő számú réteg meghatározásához, és elegendő, megbízható adatra van szükségük az optimális működéshez. (Mavani et al., 2022; L. Zhou et al., 2019).

### 3.3. Deep Learning és kemometria kapcsolata

Az bizonyos, hogy a neurális hálózatok felhasználása különböző tudományágakból származó adatok feldolgozására is alkalmas. Az élelmiszertudományok területén, a kemometriában kifejezetten alkalmas, mély mesterséges neurális hálózatok alkalmazása. Kemometria a többváltozós kémiai vagy hasonló jellegű mérési adatok kiértékelésére szolgáló módszerek összességét jelenti.

Neurális hálózattokat gyakran társítanak különböző mérési módszerekkel, akár valós idejű adatfeldolgozásra is, így rövid idejű nagy pontosságú elemzéseket hajthatunk végre. Ilyen technológiák lehetnek az élelmiszeriparban is gyakran használt elektronikus orr (E-nose), elektronikus nyelv (E-tounge), gépi képfeldolgozás (CVS), vagy közeli infravörös spektroszkópia (NIR).

#### 3.3.1. Elektronikus orr

Az elektronikus orr (E-nose), egy eszköz, amely az emberi orrhoz hasonlóan képes szagokat vagy ízeket érzékelni. Elektronikus vegyi szenzorok sorából áll, amelyek képesek egyszerű és összetett szagokat is felismerni. Az elektronikus orr gázelemzésben is használják, ahol a gázok/párák egyes komponenseinek vagy keverékeinek elemzése szükséges. Emellett fontos szerepet játszik az élelmiszeriparban a termékek minőségének ellenőrzésében. Komplex szagok érzékelésének képessége miatt környezetvédelmi eszközként is alkalmazzák, valamint robbanóanyagok észlelésére (Mavani et al., 2022).

Az elektronikus orr három fő részre osztható, mintaszállító rendszer, egy érzékelő rendszer és egy számítási rendszer. Az elektronikus orr széles körben használják az élelmiszeriparban a minőségellenőrzésben és minőségbiztosításban (Mavani et al., 2022).

### 3.3.2. Elektronikus nyelv

Az elektronikus nyelv (E-nyelv) segítségével számos kémiai anyagot lehet elkülöníteni a folyadékfázisú mintákban. Az E-nyelvben hét elektronikus eszköz érzékelője található, amelyek lehetővé teszik a szerves és szervetlen vegyületek azonosítását. Az összes érzékelő kombinációjából egy egyedi ujjlenyomat alakul ki, amely reakció spektruma eltér egymástól. Az E-nyelv statisztikai szoftvere lehetővé teszi az íz felismerését és észlelését. Jellemzően az elektronikus nyelv három elemet tartalmaz, a mintaadagoló kamrát vagy automatikus mintaadagolót, különböző szelektivitású érzékelők tömbjét és képfelismerő rendszert az adatfeldolgozáshoz (Mavani et al., 2022).

A folyadék formájú mintákat közvetlenül lehet analizálni bármilyen előkészítés nélkül, míg a szilárd formájú mintákat előzetes feloldásnak kell alávetni a mérés előtt. A képesség, hogy érzékeli az ízeket, mint egy emberi orr, az élelmiszeriparban, különösen az élelmiszerek és italok minőségellenőrzésében és minőségbiztosításában, teszi fontossá (Mavani et al., 2022).

### 3.3.3. Gépi képfeldolgozás

A számítógépes látási rendszer, CVS az MI egy ága, amely ötvözi a képfeldolgozás és a mintafelismerési technikákat. Ez egy nem roncsolási módszer, amely lehetővé teszi a képek jellemzőinek vizsgálatát és elemzését, hogy klasszifikációs mintát alkossunk. Hatékony eszközként szolgál a külső tulajdonságok, például a méret, alak, szín és hibák elemzéséhez. Általában tartalmaz egy digitális kamerát, világítórendszert és egy szoftvert a képek feldolgozásához és elemzéséhez (Mavani et al., 2022).

### 3.3.4. NIR

A Közeli-Infravörös Spektroszkópia, angol monogramja NIR, egy olyan roncsolás és segédanyagokat nem igénylő kemometriai eljárás, amely a 750-2500 nm hullámhosszú, közeli infravörös tartományban lévő elektromágneses spektrum és az anyag kölcsönhatásával foglalkozik (Cozzolino, 2021). A módszer során a mintákban található molekulák kötéseinek fény visszaverő és elnyelő képességét mérjük. A molekulák kötése, különböző frekvenciákon rezegnek, típusuktól függően. A közeli infravörös tartományban a legmeghatározóbb kötések, a C-H, N-H és O-H rezgő kötések, ezek határozzák meg az adott minta spektrumának alakját.

(Cozzolino, 2021; Mavani et al., 2022). Az élelmiszerek alapvető összetevőinek koncentrációja meghatározható klasszikus abszorpciometriai mérésekkel, azonban kémiai tulajdonságaiknak meghatározása a legtöbb esetben az élelmiszer fizikai jellege miatt nem lehetséges. Ilyenkor a közeli infravörös spektroszkópia alkalmas, mivel ez a technika kiemelkedően érzékeny az olyan molekulák vibrációs átmeneteire, amelyek tartalmaznak hidrogénatomokat, így lehetővé teszi számos szerves és néhány szervetlen vegyület gyors és hatékony azonosítását. (Vas, 2019)

A NIR berendezés általános főbb részei az infravörös fényforrás, amely kibocsátja a fényt a mintára, a mintavételi rendszer ez a részegység gyűjti össze a visszaverődő vagy átmenő fényt a mintából, a monokromátor vagy szűrőrendszer feladata a hasznos hullámhosszú fényt továbbítani a detektorhoz. A detektor érzékeli és regisztrálja a fény intenzitását a különböző hullámhosszokon, az adatok feldolgozását és elemzését végül pedig szoftveres alkalmazással végzik (Német, 2010).

A NIR előnye, hogy vizsgálat elvégzése nagyon gyors és termelési folyamatokba is beépíthető, (Vas, 2019), azonban közvetett mérési eljárásként a spektrumok feldolgozásához kvantitatív módszerek szükségesek (Csapó et al., 2020).

A közeli infravörös spektroszkópia az élelmiszertudományok területén egy széles körben használt vizsgálati módszer. Wang kutatásában, dohányleveleket vizsgáltak annak érdekében, hogy megkülönböztessék azokat termőterületük szerint. (Wang et al., 2020b) Weng és kutatótársai Ziniához hasonlóan élelmiszerek hamisításának detektálását vizsgálták NIR módszerrel. (Weng et al., 2020; Zinia, 2021).

### 3.3.5. NIR mérési eredmények elemzése mesterséges neurális hálózatok felhasználásával

A közeli infravörös spektroszkópiai mérések során keletkező adatok komplexitása és sokszínűsége összetétele, pontosan azt a típusú kihívást jelenti, amelyre a neurális hálózatok megoldást kínálhatnak (Alzubaidi et al., 2021b). Az NIR mérések és a neurális hálók kombinációja a kemometriai mérések eredményeinek kiértékelésében hatalmas potenciált rejt. A mesterséges neurális hálózatok kiemelkedő szerepet játszanak a minták összetételének meghatározásában, lehetővé teszik a minták és anyagok pontosabb, gyorsabb és megbízhatóbb azonosítását és elemzését (Zhang et al., 2022).



Cui és kutatótársai a következőt jelentették ki kutatások eredményeként: „1D-CNN modellnek jó tanulási képessége van a NIRS adatokra, és hatékonyan képes kivonni az 1D jellemzőit, amelyek a hasznos hullámhosszú-változók.” (Cui és Fearn, 2018)

Ezek a hálózatok, a mély tanulási algoritmusokon alapulva, képesek felismerni és modellezni a komplex, nem-lineáris kapcsolatokat a mérési adatok között. Az adatfeldolgozási lépés során a neurális hálózatok alkalmazásával a rendszer megtanulja azonosítani azokat a spektrális jellemzőket, amelyek döntő fontosságúak a kémiai összetevők detektálásához és kvantifikálásához (Weng et al., 2020; Jiang et al., 2021).

#### 3.3.5.1. Előnyök és hátrányok

A NIR spektroszkópia egyre inkább előtérbe kerül, amikor az élelmiszerek minőségét és biztonságát kell ellenőrizni. Ennek egyik nagy előnye, hogy gyorsan és egyszerűen lehet vele méréseket végezni, mivel nem kell bonyolult előkészítési folyamatokon átesnie a mintáknak. Ráadásul az eljárás sem károsítja, se nem változtatja meg az élelmiszermintákat. Speciális matematikai módszerek, úgynevezett nem-lineáris algoritmusok segítségével pedig nagyon pontos eredményeket lehet kapni. Azonban a megfelelő matematikai modell kiválasztása nem egyszerű feladat és szakértelmet igényel, különösképpen mert a hagyományos, egyenes vonalú modellek nem mindig elegendően pontosak. (Acquarelli et al., 2017; Cui és Fearn, 2018)

### 3.4. Fehérjék hamisításának detektálása NIR módszerrel

Az élelmiszer hamisítás az élelmiszer gyártás minden ágazatát begyűrűzi. A hamisítást végzők a gazdasági hasznon kívül, megtévesztik a fogyasztókat vagy akár egészségüket is károsíthatják. A feltüntetett tápértékek szándékos megváltoztatásától, egészen az adalékanyagok hozzáadásáig, különböző módszereket használhatnak a csalók. Ilyen tevékenység például a cukorsziruppal felhígított méz, az eredetmegjelölési védettséget élvező sajtok hamisítása, vagy a táplálék kiegészítők fel hígítása idegenanyagokkal. (Bansal et al., 2017).

Sportolók gyakran fogyasztanak fehérjeporokat táplálék-kiegészítőként, melyek lehetnek állati vagy növényi eredetűek. Sajnos, ezek is hajlamosak hamisításra. A fehérjék minőségének és mennyiségének ellenőrzése kritikus fontosságú, de a fehérjék kemometriai mérése nem egyszerű feladat. A fehérje hamisítás olyan gyakorlat, amikor a termékekben vagy

élelmiszerekben található fehérjék minősége vagy mennyisége nem felel meg a deklarálnak. A fehérje hamisítás különböző formákban jelentkezhet (Moore et al., 2010). A fehérje porok kiegészítői gyakran olcsóbb alapanyagokból és alacsonyabb minőségű alternatívákból származnak, amelyek potenciálisan veszélyeztethetik a fogyasztók egészségét és jólétét. Különösen gyakoriak a nitrogén-alapú anyagok, beleértve olyan aminosavakat, mint a glicin és a taurin, de előfordulnak összetettebb és veszélyesebb vegyületek is, mint az urea és a melamin, melyek csak állati takarmányokban elfogadhatóak (Zinia, 2021).

Számos analitikai módszer létezik élelmiszerek fehérje mérésére, Kjeldahl-módszer, NIR spektroszkópia, Bradford módszer. Az indirekt fehérjemeghatározási módszerek többsége a nitrogén mennyiségének meghatározásán alapul, és ez lehetővé teszi a fehérjék elemi összetételének közelítőleg azonos meghatározását, függetlenül a fehérje minőségétől és eredetétől. (Csapó, 2020.). A fehérjék nitrogéntartalmának meghatározására használt módszerek alapjául szolgáló konverziós faktoroknak vannak korlátai. Ezek a módszerek azt a feltételezést alkalmazzák, hogy a legtöbb fehérje nitrogéntartalma körülbelül 16% körül mozog, így a  $100/16=6,25$  konverziós faktorról lehet kiszámolni a fehérjetartalmat. (Csapó, 2020., Zinia 2020., Zinia és Budapest, 2021) Azonban ezek a módszerek nem tudják megkülönböztetni a nitrogént az alacsony molekulatömegű nitrogéntartalmú új típusú adalékanyagoktól. A konverziós faktoroknak további korlátja, hogy a gazdag nitrogén-alapú aminosavak, mint például a glicin (18,6% N), hisztidin (27,1% N), taurin (11,19% N) és melamin (66,6% N), valamint a karbamid (46,62% N) képesek csökkenteni a szabványos konverziós faktort. Másrészt, a szegény nitrogén-alapú aminosavak, mint például a fenilalanin (8,5% N) és a tirozin (7,7% N), növelhetik ezt a faktort. (Zinia, 2021). Ezért a fehérjék pontos méréséhez és az esetleges hamisítások felderítéséhez olyan módszerekre van szükség, amelyek képesek megbirkózni ezekkel a korlátokkal, és pontosabb eredményeket szolgáltatnak, ilyen módszer a NIR.

## 4. Anyagok és módszerek

### 4.1. Szoftver környezet

A MATLAB egy sok oldalú és széles körben használt számítási szoftver, amely kifejezetten matematikai és mérnöki alkalmazásokhoz készült. A MATLAB lehetővé teszi matematikai számítások, adatelemzések, szimulációk és grafikai megjelenítések végzését egy egyszerű és intuitív programozási nyelven keresztül. Ez a platform széles körben alkalmazható tudományos kutatásokban, mérnöki tervezésben, adatfeldolgozásban és még sok más területen (Vedaldi és Lenc, 2015). Dolgozatom során a MATLAB R2022b verzióját használtam.

Elterjedt alkalmazás a Python neurális hálók alkotására, amely ingyenes hozzáférhetősége miatt széles körben elterjedt és szabad hozzáférése miatt dinamikusan fejlődő programozási nyelv. A Microsoft Cognitive Toolkit egy elavultnak számító alkalmazás mesterséges neurális hálózatok létrehozására, habár felhasználó barát környezete miatt sokan használják.

#### 4.1.1. Neural Network designer

A neurális háló felépítéséhez a MATLAB Neural Network Designer applikációját használtam. Használata gyorsan átlátható, felhasználó barát. Használata előnyös, mivel ikonokon keresztül, logikai sorrendbe állíthatjuk össze hálózatunkat, amelynek különböző egységeinek paramétereit könnyen testre szabhatjuk. A felépült hálózat működőképessége ellenőrizhető és könnyen exportálható programnyelvé.

### 4.2. Felhasznált adatok

#### 4.2.1. Iparból származó adatok

Ebben az adathalmazban a minták, fehérjetartalmát NIR módszerrel vizsgálták. Az adat táblából megismerhetjük az egyes mérésekhez tartozó minták fehérje tartalmát ismerjük, hogy mely spektrumokat használták az elemzésük során tesztelésre, kalibrációra és melyiket zárták ki az adatok feldolgozása során. Kizárt adatokat én sem használtam fel a klasszifikáció során.

A méréseket 959 darab hullámhosszon végezték. A méréseket mintánkként három négy alkalommal végezték ismeretlen szisztéma szerint, 2426x959 méretű .xlsx adattáblát létrehozva. A kizárt adatok leválogatása után 2294x959 méretű adattáblához jutottam. Ahhoz, hogy klasszifikációt végezhessenek az adatokon, 1-től 6-ig soroltam be, fehérje tartalmuk szerint. A kategóriák L1; L2; L3; L4; L5; L6 nevet viselték.

#### 4.2.2. Fehérje hamisítás adatsor

Zinia és munkatársai a kutatásban (2021) hamisított élelmiszerek közeli infravörös spektroszkópiával történő azonosításával foglalkozik. Méréseket végzett idegen anyaggal szennyezett fehérje mintákon. A marhafejréje, borsófehérje és savófehérje mintákat karbamid (urea (U)), glicin (G), taurin (T) és melamin (M) anyagokkal szennyezett, ezzel előállítva a piacon potenciálisan megjelenhető hamisított fehérje alapú táplálékkiegészítőket.

A minták elkészítése során a tiszta fehérje mintákat és a szennyező anyagokat külön-külön vizsgálta, emelet a szennyező anyagok különböző kombinációját állította elő. Ezek a következők: U, G, T, M; GT, UG, GM, UT, TM, UM; UGT, GTM, UGM, UTM, UGTM. A szennyező anyagok koncentrációja 0,5%; 1%; 1,5%; 2%; 2,5%; 3% tömeg arányban keverte a fehérje mintákhoz. Ezt a kutatók úgy végezték el, hogy a keverékekben a szennyező anyagok nitrogéntartalmához képest, mennyiségük arányos legyen. Így 273 mintát vizsgáltak NIR módszerrel, 950 – 1650 nm között, a méréseket mintánkként háromszor végezte el. Ezzel egy 351x2457 méretű adattáblát létrehozva, .xlsx formátumban. A vizsgálat során a koncentrációtól függetlenül az eltérő hamisító anyagok osztályait kerültek kategorizálásra. Ennek céljából céljából, a mintákat szétválogattam úgy, hogy egyetlen szennyező anyag fajtát tartalmazzon az adott fehérje minta, így kutatásom során az karbamid (urea), glicin, taurin és melamin különböző százaléku szennyezését vizsgáltam, így 481x225 méretű adattáblákat dolgoztam fel.

#### 4.3. Előkezelések

A nyers adatokat a neurális hálóba való táplálás előtt feldolgozzuk, annak érdekében, hogy a mély mesterséges neurális háló képes legyen értelmezni azokat. Igen fontos, hogy előkezelés során az adathalmaz komplexitását csökkentsük. Az előfeldolgozás eltávolítja a nem

kívánt csúcsokat és a spektrális jelek zavaró hatásait. A tipikus előfeldolgozási eljárás magában foglalja a zaj eltávolítását, az alapvonal korrekcióját, a szórás korrekcióját (Yang et al. 2019; Debus et al. 2021). Dolgozatomban 4 fajta előkezelést használtam, Zinia kutatása alapján (Zinia, 2021), kiválasztásukat egyéb irodalmi kutatások alapján végeztem, a leg elterjedtebb kezeléseket használtam.

#### 4.3.1. Savitzky-Golay

Az SG egy népszerű eljárás a spektrumok simítására. Hatékonyan javítja a jelek zajhoz viszonyított arányát, azonban helytelen használata torzíthatja az eredeti jelet és csökkentheti a felbontást. Az első és második deriválttal a spektrumok közötti eltolási különbséget csökkenti és emellett csökkenti a meredekséget. Az előkezelés során a Savitzky-Golay Filter használatával az első deriváltat vettem alapul a 2. polinommal és 11-es szűrő mérettel. (Yang et al. 2019; Zinia 2021).

#### 4.3.2. Multiplicative Scatter Correction

Spektrum elemzések során az MSC korrekciós módszerrel a fizikai fényvisszaverődés vagy szóródás hatása miatt kialakult zaj eltávolítható a spektrumból. Ez a módszer minden egyes spektrumot úgy transzformál, hogy az minél jobban illeszkedjen az adathalmaz átlag spektrumához. Ezt úgy éri el, hogy a vizsgált spektrum tartalmát, ami esetemben az egész spektrum hossza, regresszióval hasonlítja össze a referencia spektrummal, ezután a vizsgált spektrum korrigálásra kerül a lineáris illeszkedés meredekségével és tengelyével (Yang et al., 2019a; Zinia, 2021).

#### 4.3.3. Standard Normal Variate

A Szabványos Normális variáns, SNV segítségével kiküszöbölhetőek a spektrumok alapvonal és úthosszából származó változások, amelyek különbségeket okozhatnak az egyébként azonos spektrumok között. A módszer központosítja és skálázza az egyes spektrumokat úgy, hogy mindegyik átlaga 0, és szórása 1 legyen (Zinia, 2021).

#### 4.3.4. Principal Component Analysis

A Főkomponens-analízis, angol monogramján PCA, az adatokban lévő mintázat vizualitására szolgál (Zinia, 2021). Azért kedvező, mert lehetővé teszi a minták azonosítását az adatokban, és olyan módon fejezi ki az adatokat, hogy azok különbségeit és hasonlóságait hangsúlyozza (Armstrong, 2018). Csökkenti az adatok mennyiségét, kutatásomban az első 20 főkomponens, amelyek alacsonyabb dimenziójú új változóként kerülnek feldolgozásra a neurális hálóban.

#### 4.4. Adatok particionálása

A neurális hálózatok feldolgozása három alapvető szakaszból áll: tanítás, validálás és tesztelés. A rendelkezésre álló kísérleti adatok általában három részre oszthatódnak, elterjedt arány, hogy 70%-ukat a tanításra, 15%-ukat a validálásra, és a fennmaradó részt a tesztelésre használják. A minták kiválasztására különböző módszerek léteznek, elterjedt a crossvalidálás és a véletlenszerű kiválasztás (Guiné, 2019). Az első két adathalmazt elsősorban a modell tanítására és a modell hiperparamétereinek optimalizálására használják, míg a tesztelési adatok az új, eddig nem látott minták előrejelzésének képességét hivatottak mérni. Fontos, hogy minden adatcsoport jól reprezentálja az összes adatot, és ne legyen átfedés közöttük, hogy a modell teljesítménye ne csak az adott adathalmazra specifikálódjon (Debus et al., 2021; Guiné, 2019). A Deep Learning projekteknél gyakran alkalmazzák az adatok véletlenszerű megkeverését a halmazok felosztása előtt, kivéve, ha az adatok idősorosak. Ha az adathalmaz nem elég nagy ahhoz, hogy külön tesztadathalmazt alakítsanak ki, akkor alternatív megoldásként keresztvalidációs módszereket lehet alkalmazni (Debus et al., 2021).

#### 4.5. Alkalmazott Neurális Hálók

Kutatásomban alkalmazott neurális hálókat, hasonló témakörben készített tanulmányokból implementáltam. Közös bennük, hogy mindegyik kutatás közeli infravörös spektroszkópia mérésekből származó spektrumokat dolgozz fel, neurális hálók alkalmazásával, az általam használt előkezelések pedig mindegyik kutatásban megjelent. Törekedtem a neurális hálózatok gyűjtésénél és megalkotásánál, hogy azok a lehetőségek szerint változatos

felépülésűek, legyenek, azzal a céllal, hogy megismerjem, milyen változásokat okoz a neurális háló és előkezelések megváltoztatása a klasszifikációs során.

#### 4.5.1. Darált marhahús hamisításának kimutatása

Ebben a cikk-ben a kutatók, darálthús hamisítások klasszifikációjára használták, a neurális háló és kemometriai mérés kapcsolatát. (Weng et al., 2020)

A kutatás során mintánként két tétel marhalapockát, marhaszívet, marhazsír és sertéslapockát vizsgáltak. A különböző húsokat darálták, és összekeverték őket potenciális hamisító anyagokkal. Sertéshúst, marhaszívet, marhazsír 4%; 12%; 20%; 30% tömegarányban keverték a darálékokhoz. A darált marhalapocka hamisítást, 0-tól 5-ig terjedően sorolták be a következők szerint: marhalapocka sertéslapockával, marhaszív vagy marhazsír, marhalapocka sertéslapockával és marhaszívvvel, marhalapocka sertéslapockával és marhazsírral, valamint marhalapocka marhazsírral, marhaszívvvel és sertéslapockával. Minden hamisításfajtából, tíz mintát készítettek, összesen 240 minta. A marhalapocka mintákat sertéslapockával vagy marhaszívvvel hamisították, 0-48% között, 4%-os lépésközzel. Lépésközönként 6 mintát készítettek, összesen 78 minta. Weng és társai 350-2500 nm között végezték a közeli infravörös méréseket, mintánként 10 visszaverődési spektrumot mértek 1 nm spektrális felbontással.

Adataikat a tanításhoz és teszteléshez 85%-15% -ra bontották. A mérésekből származó spektrumokon Savitzky-Golay (SG) módszert alkalmaztak a zajok csillapítására, ehhez, az első derivált második polinomját vették, 15 pontok keresztül. Ezen kívül főkomponens analízist, és egyéb előkezeléseket is használtak.

A DCNN neurális hálót alkalmaztak. A bementi réteget 4 konvolúciós réteg követ, az első három 3-as kernel mérettel és 25 neuron számmal rendelkezett, a negyedik pedig hasonló kernel számmal, azonban 64 -es neuronnal. Az első három konvolúciós réteget, 3 darab max-pooling réteg követte, 5-ös értékkel, ez az érték igen elterjedt spektrális adatok kezelése esetén. ReLU aktiváló rétegek és BatchNormalization rétegek követték a konvolúciós rétegeket. A neurális hálóba 3 teljesen kapcsolt réteget is beillesztettek, ezeket egy flatten, laposító réteg előzte meg. Az első kettő teljesen kapcsolt réteget szintén ReLU és batchNormalization réteg követi. Az első 2 fully connected réteg 100 és 50 egységgel rendelkezik. A klasszifikációs réteget soft max réteg előzte meg.

A felépült neurális hálózat 23 epoch után stabilizálódott. A darált marhahús-hamisítás megkülönböztetése során, a kalibrációt és validációt 99% pontosságot tudtak elérni és a vizsgálat predikciója is elérte a 99%-ot. Továbbiakban, Weng neurális hálójaként hivatkozom rá.



12. ábra Weng hálózat felépülése, saját.

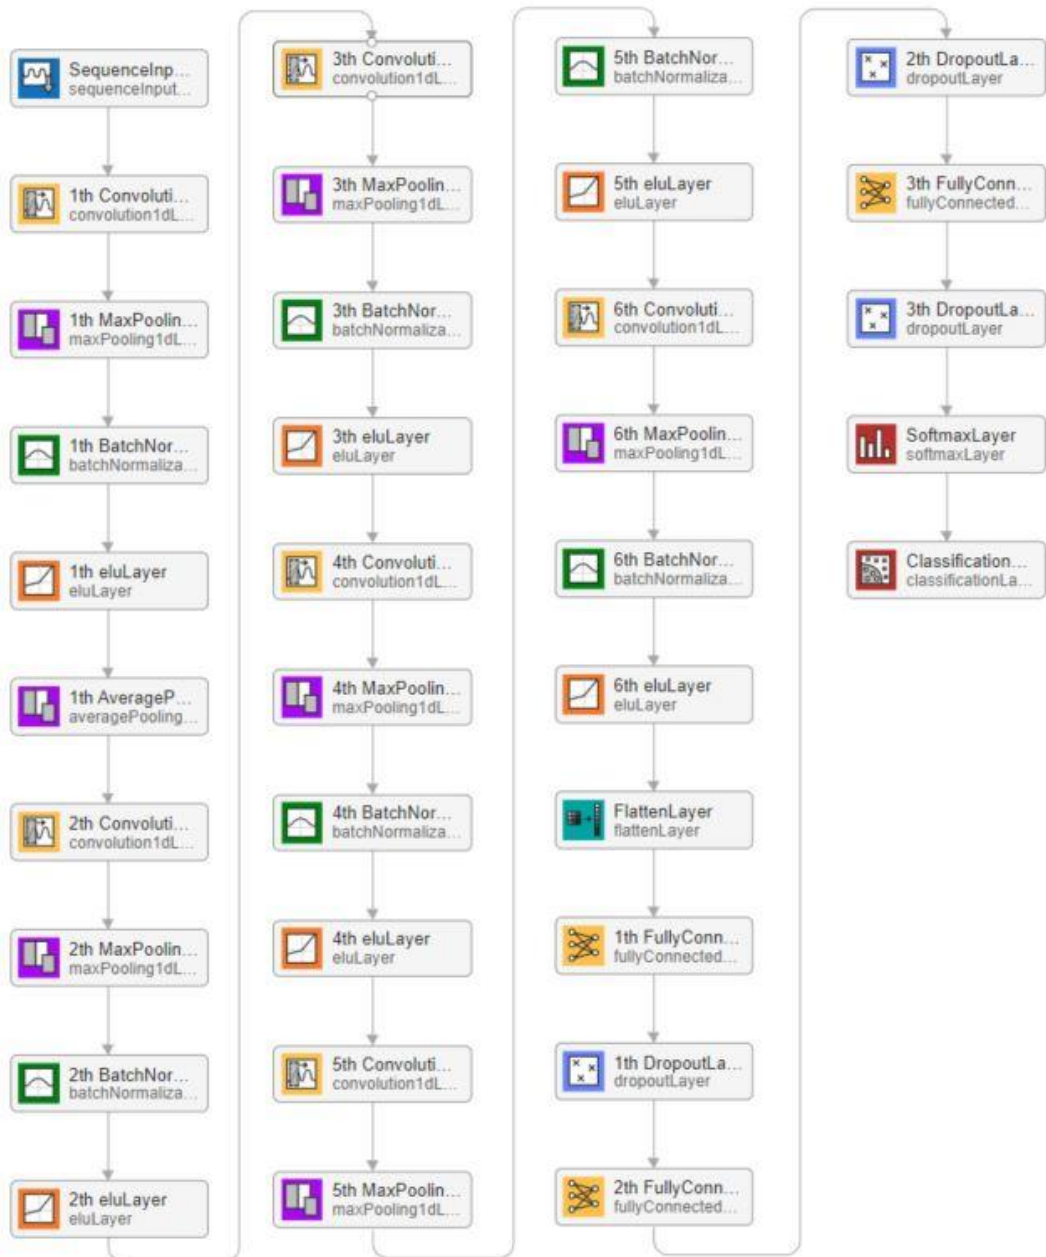


#### 4.5.2. Mély konvolúciós hálózat fejlesztés szenzoros adatok elemzésére

A kutatás során dohánylevél mintákat vizsgáltak közeli-infravörös spektrális szenzor adatok felhasználásával, amelyek spektrumait neurális hálóval elemezték. Céljuk, hogy nagy hatékonysággal képesek legyenek dohánytermesztési területek megkülönböztetésére (Wang et al., 2020).

A dokumentumból sokat nem tudunk meg a magáról a minták előkészítéséről és az előkezelésekről. 600 dohányból készült mintát alkalmaztak a vizsgálathoz.

Az eredeti NIR információk egydimenziósak, melyekhez dimenzióként 1609 attribútum kapcsolódik. Ennek megfelelően minden konvolúciós szinten az ilyen magokat egydimenziós tömbként definiálják. Az első három szint használatával gyorsan szeretnék kivenni a helyi attribútumokat, ezért 9-es méretű filtert 1 neuronnal használnak. A következő három szinten viszont a részletesebb adatok érdekében 1x3-as, 1 neuron és 3 kernel, vektort alkalmaznak. A különböző és finomabb tulajdonságok eléréséhez a konvolúciós magok csatornáinak száma fokozatosan nő, kezdve az első réteg 32 csatornájával, egészen a hatodik réteg 256 csatornájáig. Minden szintnél a rétegekhez maxPooling 1x2 méretű filtert alkalmaznak. Az első két FullyConnected rétegnél 512 neuront használnak, míg az utolsónál, ahol nyolc kategória található, nyolc neuron szerepel. Az osztályozási eredményeket a végső szinten a softmax módszerrel vonják ki. Továbbiakban Wang neurális hálójaként hivatkozom rá.



13. ábra Wang hálózat felépülése, saját.

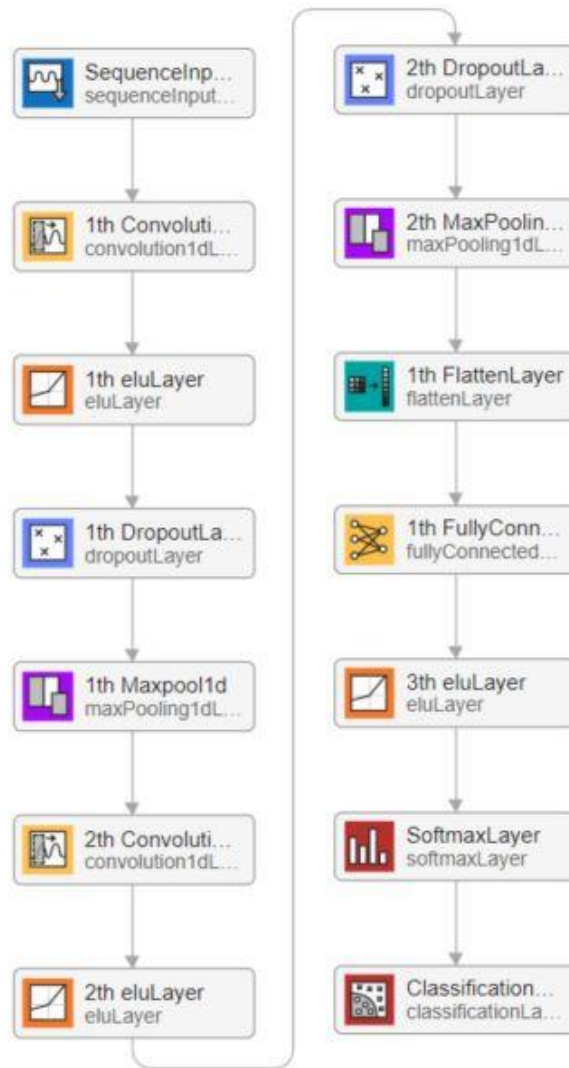
A konvolúciós hálózat legmagasabb pontossága 93,03% volt, 6 konvolúciós réteggel és 3 FullyConnected réteggel. A kutatók megállapították, hogy a predikciós teljesítmény csökken, amikor a teljes kapcsolati rétegek száma nő. Ennek oka lehet, hogy a bemeneti adat egydimenziós, korlátozott jellemzőkkel rendelkezik. Hat konvolúciós réteg és három FullyConnected réteg elegendő az összes jellemző kinyeréséhez a bemeneti adatból, és minden további réteg túltanuláshoz, overfitting-hez vezet.

### 4.5.3. Deep learning az analitikai kémia területén

Debus és kutatótársainak célja ezzel a kutatással az, hogy bemutassák, milyen releváns a Deep Learning használata a kemometriában. Cikkükben bemutatják, hogyan működik a CNN és milyen paraméterekkel rendelkezhet. Debus és kutató társai által készített neurális háló felépüléséhez nem ragaszkodtam szigorúan. Ebben az esetben próbáltam olyan változtatásokat tenni, amelytől javult a mesterséges neurális háló teljesítménye. Ezen keresztül sikerült egy meglévő neurális háló vázára felhúznom saját neurális hálómam.

A kutatásban szereplő neurális háló a bemeneti réteg után egy 32 kernellel és 28-as szűrő méretű konvolúciós réteg következik, ezután 2x2 méretű maxpooling réteg csökkenti az adatok dimenzióját. A következő konvolúciós rétegben 64 kernel és 11 méretű szűrő működik, amit egy pooling layer követ. Egy flattening vagy is lapító réteg után szokásos módon egy teljesen kapcsolt réteg következik.

Debus, a kutatásában 90,5%-os pontosságot tudott elérni klasszifikáció során, NIR spektrométeres méréseken. Továbbiakban Debus neurális hálójaként hivatkozom rá.



14. ábra Debus hálózat felépítése, saját.

## 5. Eredmények és értékelés

A következőkben bemutatom a kutatásom során használt mesterséges neurális hálózatok működését és azok eredményeit. A diplomamunkámban a neurális hálózatok összehasonlításakor több kulcsfontosságú mutatót is vizsgálok, így az általános pontosságot, a vesztesség mértékét, a program lefutási idejét, és az osztályozási értékek stabilitását. Ezek a mutatók segítenek abban, hogy átfogó képet kapjak a különböző modellek teljesítményéről és megbízhatóságáról. Sorra veszem az előkezelések hatásait, Weng, Debus és Wang kutatásában található neurális hálózatok klasszifikációjának pontosságát és hibáit, végül pedig Zinia kutatásának eredményeit hasonlítom össze az általam kapott legjobb eredményekkel.

Zinia kutatásához hasonlóan, (Zinia, 2021), a tiszta Marha (Beef), Borsó (Pea), Savó (Whey) fehérje mintákat külön-külön dolgoztam fel a neurális hálókkal a mérések során a hozzájuk kevert Karbamid (Urea (U)), Glicin (G), Taurin (T) és Melamin (M) szennyező anyagokkal. A neurális hálók klasszifikációs képességének további vizsgálatához pedig, iparból származó fehérje mérések értékeit osztályoztam egy L1-től L6-ig tartó skálán.

Az előkezelések kiválasztása során Zinia kutatására építkeztem (Zinia, 2021), amelyben a különböző előkezeléseket és azok kombinációit használta. Savitzky-Golay simítás (SG) előkezelést Standard Normál Variáns (SNV) technikával alkalmaztam, ezek hatását többszörös szóródási korrekció Multiplicative Scatter Correction (MSC) előkezeléssel hasonlítom össze. A DCNN hálók tesztelése során, ezeket a felállásokat találtam, megfelelően összehasonlíthatóknak.

Weng és Debus neurális hálójával, 90% fölötti pontossággal tudtam elvégezni a szennyező anyagok predikcióját, Dara adathalmazon ~80% -os pontossággal tudtam klasszifikálni a mintákat. Alapvető megfigyelés, hogy a Zinia adathalmazának klasszifikációja során már 100 epoch-nál stabilizálódott a klasszifikáció, míg Dara adatok esetében ez 550 epoch után történt a stabilizáció, ennek természetesen oka lehet az adathalmazok méretének különbsége.

## 5.1. Előkezelések hatása

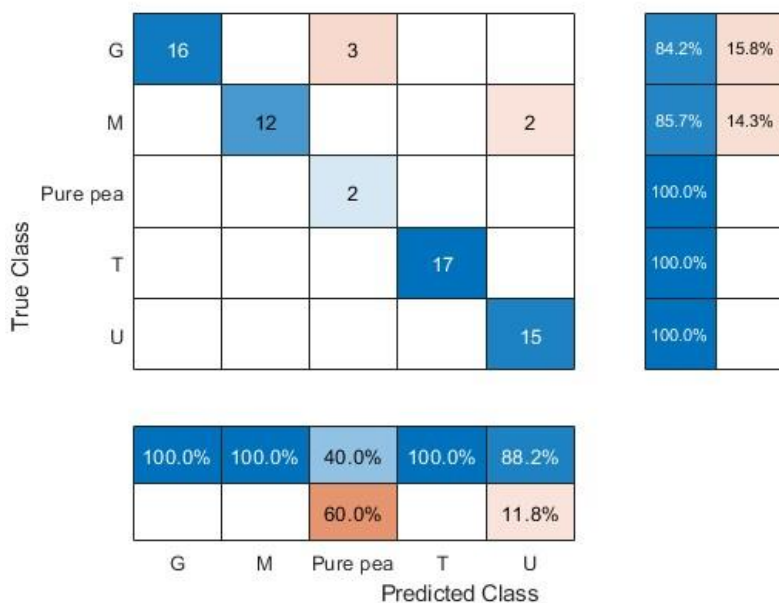
Savitzky-Golay előkezelés során az Zinia által használt 21 ponttal nem értem el elegendő pontosságot, azonban tapasztalati úton a 11 pont használatával akár 10%-kal jobb klasszifikációs pontosságot tudtam elérni adathalmazaimon, ehhez hasonló úton jutottam el a PCA-ban alkalmazott első 20 főkomponens alkalmazásához. Multiplicative Scatter Correction a spektrum teljes hosszán való használata eredményesnek mutatkozott.

A SG és SNV előkezelések és MSC előkezelés hatása jelentős különbséget nem jelentett a predikció pontosságára, azonban a lefutási görbéjük stabilabb, simítottabb volt és korábban saturálódott mint SG és SNV esetén. SG és SNV előkezelések hátránya, hogy a veszteség mértéke magasabb volt, ez összefüggésben lehet a predikció pontosságának különbségével. Annak ellenére, hogy ideálisnak találtam a SG és SNV előkezelések együttes használatát, valószínűleg túlzottan egyszerűsítették a spektrumokat.

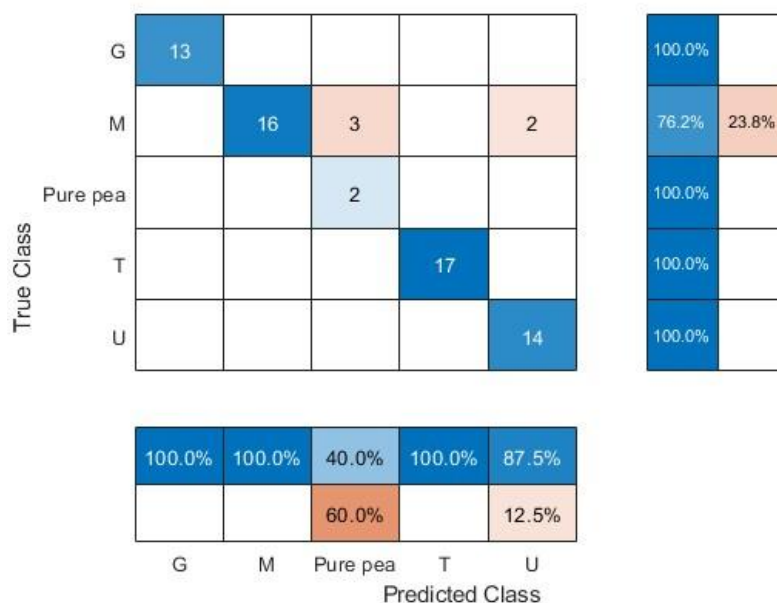
## 5.2. Darált marhahús hamisításának kimutatása

Shizuank kutatásában elért 95%-os klasszifikáció pontossága, az én kutatásom esetén Zinia adathalmazán, SG, SNV és PCA előkezelés alkalmazásával a Beef 95,5%; Pea 92,54% és Whey 91,04 % pontossággal történt míg MSC és PCA előkezelések alkalmazásával a Beef 95,52%; Pea 92,54% és Whey; 95,52%. Dara adathalmaz SG, SNV és PCA klasszifikációja csak 86,77% pontossággal történt, míg MSC és PCA klasszifikáció esetén 82,5%.

A 15. és 16. ábrán jól bemutatja, hogy annak ellenére, hogy milyen jó pontossággal végezhető a klasszifikáció mély neurális hálók alkalmazásával, egy állandó ismeretlen méretű szórást, magukban hordoznak. Míg ebben az esetben a borsófehérje mind 2 előkezelés hatására, ugyan olyan pontossággal volt képes felismerni a mintákat, ennek ellenére, precizitása a két ismételt osztályozásnak már nem ugyan olyan. Tapasztalatom szerint a mérések pontossága közötti különbség 3-4%.



15. ábra Borsó fehérje Confusion Matrix SG és SNV előkezelés esetén



16. ábra Borsó fehérje Confusion Matrix MSC előkezelés esetén


### 5.3. Deep learning az analitikai kémia területén

Mivel számomra, az 5 kategória jól behatárolható tulajdonságai voltak fontosak ezért, a convolutionLayer kernel méretét 5 -re módosítottam, a filterek méretét a dimenzió csökkentése érdekében 20-ra állítottam. Habár az alap neurális háló aktivációs réteget nem tartalmaz Cui kutatása alapján (Cui és Fearn, 2018), ELU aktivációs réteget alkalmaztam, amit dropout réteg

követett a túlillesztés elkerülésért. A cikkhez hasonlóan maxpooling réteget használtam. Az első 4 réteget hasonló 4 réteg követ. Az első dropout réteg a neuronok 30% a második 50% kapcsolja, ki. Egyéb különbség, hogy a fullyconnected réteget is egy ELU réteg követ.

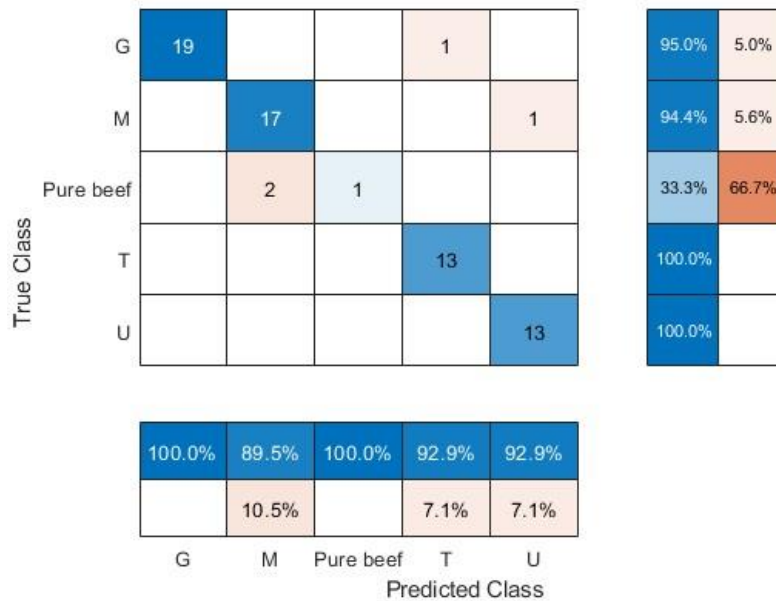
Debus eredeti neurális hálójánál, valamivel nagyobb pontossággal végezte az osztályozást a módosítások után a CNN. Kevesebb epoch után stabilizálódott a tanító fázis lefutása, ezt a javulást a fullyconnected réteg után beillesztett dropout és eluLayer rétegek eredményezték, a pontosság javulása a neuron számának és a filter méretének változtatása eredményezte.

SG, SNV és PCA előkezelések esetén Debus neurális hálóján Beef 95,52%; Pea 97,01% és Whey 94,03%, míg a MSC és PCA előkezeléssel Beef 94,03%; Pea 91,04% és Whey 95,52%. Érdekes módon, míg a Shizuank neurális hálója egy jóval mélyebb Deep Learning technikát mutat be, addig Debus esetében is el tudunk érni, hasonló epoch szám után, nagy pontosságot, azonban 600 epoch tanítási időt Shizuank modelje másfélszer annyi idő alatt végezte el. Debus neurális hálóval a Dara adathalmazosztályozása ebben az esetben is alacsonyabb értékkel rendelkezett, 79,8% és 82,56%.



17. ábra Marhaminta fehérje minta Confusion Matrix, SG és SNV előkezelés esetén

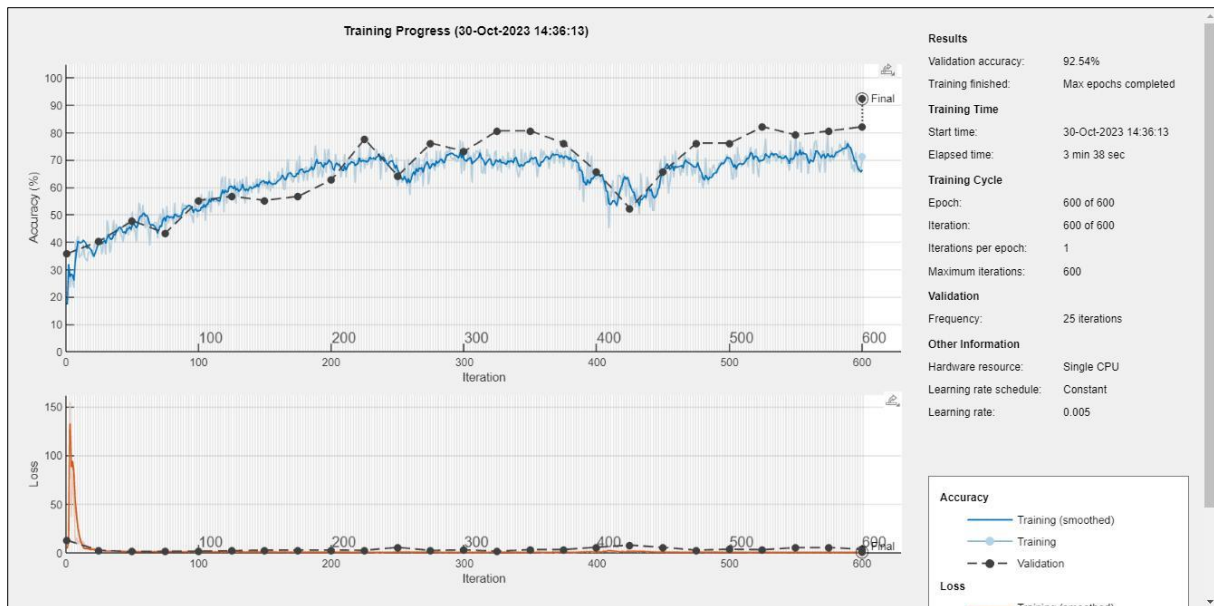




18. ábra Marhaminta fehérje minta Confusion Matrix MSC előkezelés esetén

#### 5.4. Mély konvolúciós hálózat fejlesztés szenzoros adatok elemzésére

Wang és csapata által készített neurális háló esetében nem értem el az előzőkéhez, hasonló eredményességet, mint az SG, SNV és PCA előkezelések mint a MSC, PCA előkezelések, során. Igen változatos lefutású a tanítás ennek eredményeként annak pontossága is. Emellett ebben a kivételes esetben a predikció jobban teljesített a tanító folyamatnál, ahogy ezt láthatjuk a 19. ábrán.



19. ábra Wang neurális háló tanítása

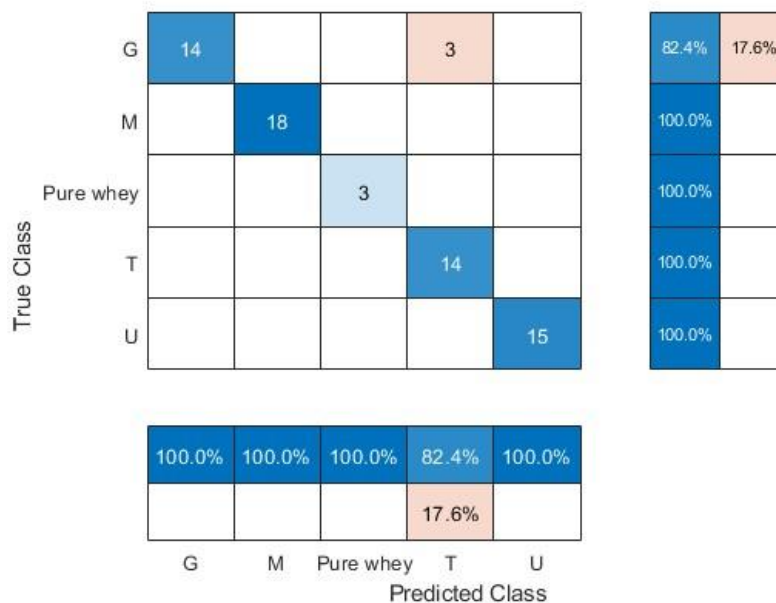
Wang a kutatásukban 93% -os pontosságot ért el, amihez hasonló sikerült elérni, Beef minta esetében 92,54% pontossággal. A Pea és Whey esetében 90,62% ; 85,94% pontosságot értem el. MSC és PCA előkezeléssel Beef 95,52%; Whey 91,04% és Pea 73,13% pontosságot értem el. A Dara adathalmaz tulajdonságait is egészen nagy 73,55% és 82,12 % pontossággal meg tudta határozni a hálózat, igen alacsony veszteség mellett. Azonban az előző adatokhoz hozzátartoznak igen alacsony pontosságú osztályozások is. Akár 37% -ig is sülyedhetett a predikció sikeressége (20. ábra) annak ellenére, hogy ez az alacsony teljesítménye a Loss, veszteség görbén nem mutatkozott. Fontos kiemelni emellett, hogy pontos predikciós százalék mellett is előfordul ennek a neurális hálónak a lefutása során, hogy nem ismeri fel az adott minta tiszta összetevőjét, ahogyan ez látható a 20. ábárn is. Ezek mellett a tanítás lefutása is hosszadalmasabb, mint az előző két CNN esetében.



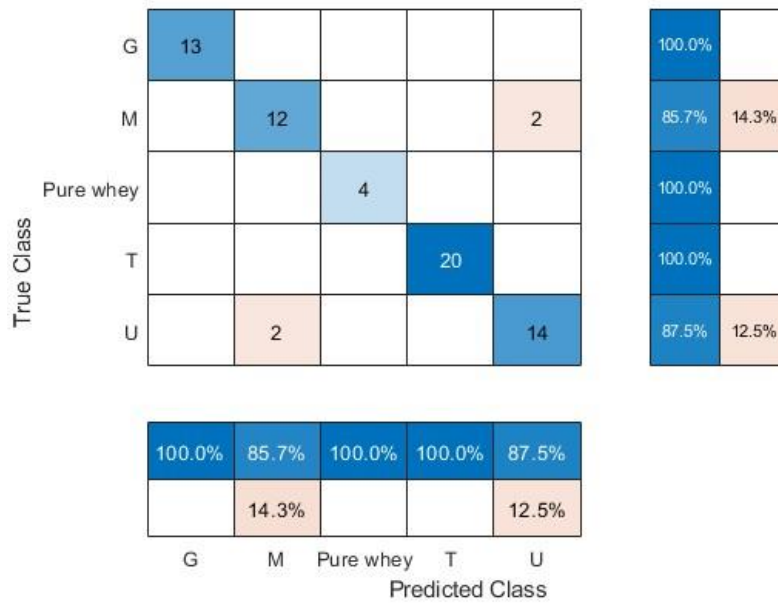
kilengésű és mértékű veszteséggel rendelkeznek, ez a regularizáció változtatásával csökkenthető. Az ingadozás azt jelzi, hogy túl nagymértékű a véletlenszerűség az adatok előkészítése során, ez lassítja a konvergenciát (Yang et al., 2019). A Dara adathalmaz esetén, az látható, hogy az epoch növekedésével, veszteség mértéke is növekszik a predikció esetén, mindkét neurális hálózaton. Ez feltételezhetően túlillesztést okoz, amely az „early-stop”, korai megállás nevű technikával orvosolható Ying szerint. (Ying, 2019)

### 5.5. Eredményeim összehasonlítása Zinia eredményeivel

Zinia a kutatásában Savófehérje klasszifikációja során 90,43%-os pontosságot ért el, a tiszta fehérje mintát 11% -ban tévesztette melaminnak. Debus és Weng neurális hálóival 95,52% -os pontossággal voltam képes klasszifikálni. Ahogyan a confusion mátrixból is látszik (22. ábra, 23. ábra) annak ellenére, hogy a tiszta fehérjét 100%-ban feltudták ismerni a hálók, Debus 17,6%-ban Taurinnak hitte a glicin mintát, Weng pedig 14,3% ban ureanak hitte a melamint és 12,5% -ban urea-t melaminnak.

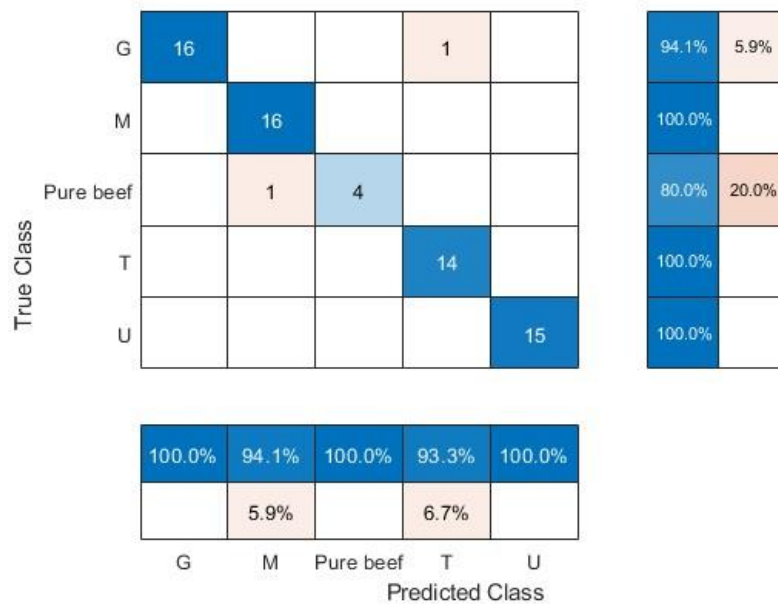


22. ábra Savófehérje klasszifikációja Debus CNN, SG és SNV előkezelés



23. ábra Savófehérje klasszifikációja Weng CNN, SG és SNV előkezelés

Marhafehérje osztályozását legsikeresebben 95,5%-ban Weng hálójával tudtam végezni, ahol 5,9%-ban taurinként osztályozta a glicint, és a tiszta marhafehérje minta 80% -át ismerte csak fel mivel 20%-ot melaminként osztályozott. Zinia klasszifikációja 94,8% volt, és a tiszta fehérjét 100%-ban tudta felismerni.



24. ábra Marhafehérje klasszifikációja Weng CNN, SG és SNV előkezelés

Borsófehérje klasszifikációja során értem el a legmagasabb eredményt, 97,01%. Azonban 14,3% -ban tiszta borsó fehérjének osztályozott Glicint és Taurint 20%-ban tiszta savófehérjeként osztályozott. Zinia, ebben az esetben 93,71% sikerességgel osztályozta a fehérjét, Melamint 11%-ban osztályozott tiszta borsófehérje ként.

True Class	G	18		3			85.7%	14.3%
	M		12				100.0%	
	Pure pea			4	1		80.0%	20.0%
	T				15		100.0%	
	U					14	100.0%	
		100.0%	100.0%	57.1%	93.8%	100.0%		
				42.9%	6.2%			
	G	M	Pure pea	T	U			
	Predicted Class							

25. ábra Borsófehérje klasszifikációja Debus CNN, SG és SNV előkezelés

## 6. Összefoglalás

Az élelmiszeriparban igen sok lehetősége van a mesterséges intelligencia alkalmazására akár termelési szinten és akár analitikai szinten. A Deep Learning alkalmazása a kemometriában elősegíti az eredmények gyorsabb és pontosabb produkálását. Az ilyen fajta technológiák alkalmazása nagylépés az élelmiszeriparnak és jelentős potenciállal rendelkezik. A NIR spektrumok értékelése mesterséges neurális hálókkal egyre elterjedtebben kutatott téma és számos alkalommal bizonyították alkalmasságukat, az ilyen fajta adatok értelmezésében.

A mesterséges neurális hálók létrehozásával és pontos beállításával, összehasonlítotam, eredményeimet a forrásukként szolgáló kutatásokkal. Eredményeim jól megközelítették, az eredeti eredményeket, az előkezelések és az adathalmaz különbségének ellenére. Wang kutatásának eredményességét nem tudtam elérni, az alkalmazott neurális hálóval.

Debus és Weng kutatásában szereplő pontosságnál jobb klasszifikációs pontosságot értem el adataimon Zinia adatain. Az Ipari adatok klasszifikációja alacsonyabb szinten sikerült, 80% feletti eredményt alig sikerült elérnem. Jól látszódik a neurális hálók lefutásából, hogy azok mélysége és rétegei, milyen mértékben befolyásolják azt. Eredményeimből azt is megítélhetjük, a klasszifikációk pontossága bizonyos százalékon belül változnak, viszont egy jól beállított neurális hálózat pontos és megbízható eredményeket adhat.

A szennyezett fehérjeminták detektálása, hasonló vagy nagyobb pontossággal történtek, mint Zinia kutatásában szereplő adatok. Weng neurális hálójával szinte azonos pontossággal tudtam osztályozni a marhafehérje mintákat, mint Zinia, azonban a savófehérjék esetén már 5% pontosabban történt ez. A borsófehérjék esetén alacsonyabb értéket értem el Weng neurális hálójával, viszont Debus kutatása alapján készült neurális hálóm jobb eredményt ért el. Ezzel a neurális hálóval Wengéhez megegyező pontosságot értem el a marhafehérje osztályozásánál és kiemelkedő 97,01% pontosságot értem el a borsófehérje esetében.

Debus kutatása alapján sikerült egy olyan neurális hálót terveznem, amely nagy pontossággal működik, eredményei elfogadható mértékben változnak, 2-3%. Megfigyeltem azt is ezen keresztül, hogy a konvolúciós rétegek pontos beállítása, milyen nagyban befolyásolja a neurális hálózat, adott adathalmaz tulajdonságaira való érzékenységének változását.

További vizsgálatokat érdemelne, másfajta előkezelések alkalmazása és a dolgozatomban használt előkezelések finom hangolása. A neurális hálózat tanításához és teszteléséhez az

adatok újfajta feldolgozása, kisebb és nagyobb méretű adathalmazokon. Ezenkívül regresszió alkalmazása is egy előreutató lépés lenne az adatok további vizsgálatára.

A mesterséges intelligencia egyre nagyobb térnyerése az élelmiszeriparban segíteni fogja a kutatókat és a termelőket. Ezáltal az Ipar 4.0 folyamatok tovább gyűrűznek a következő lépcsőfokra.



## Irodalomjegyzék

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 7-22.
- Armstrong, A. J. (2018). Multivariate Data Analysis and Data Fusion Techniques for Modeling Spectroscopic Data During CO<sub>2</sub> Capture with Amines, 23-24.
- Ayed, R. Ben, & Hanana, M. (2021). Artificial Intelligence to Improve the Food and Agriculture Sector. In *Journal of Food Quality Vol. 2022*, Hindawi Limited, 3-5.
- Bansal, S., Singh, A., Mangal, M., Mangal, A. K., & Kumar, S. (2017). Food adulteration: Sources, health risks, and detection methods. *Critical Reviews in Food Science and Nutrition*, 57(6), 1174-1189.
- Benson, I. M., Helser, T. E., Marchetti, G., & Barnett, B. K. (2023). The future of fish age estimation: deep machine learning coupled with Fourier transform near-infrared spectroscopy of otoliths. *Canadian Journal of Fisheries and Aquatic Sciences*, 1482-1494.
- Bettina, B., & Szabó Zs., R. (2022). 68 Vezetéstudomány / Budapest management review cikkek, tanulmányok, 1482-1492.
- Bihari, P. (2019). Halmozódó ellentmondások. *Külgazdaság*, 63(7-8), 4-8.
- Chowdhary, K. R. (2020). Fundamentals of artificial intelligence. In *Fundamentals of Artificial Intelligence*. Springer India, 1-716
- Collins, C., Dennehy, D., Conboy, K., & Mikalef, P. (2021). Artificial intelligence in information systems research: A systematic literature review and research agenda. *International Journal of Information Management*, 60, 2-11.
- Cozzolino, D. (2021). The ability of near infrared (NIR) spectroscopy to predict functional properties in foods: Challenges and opportunities. In *Molecules Vol. 26, Issue 22*, 2-8.
- Csapó, J., Albert, C., & Kiss, D. (2020). Csapó János Albert Csilla Kiss Dóra Analitikai kémia élelmiszer-mérnököknek, 53-56.

- Cui, C., & Fearn, T. (2018). Modern practical convolutional neural networks for multivariate regression: Applications to NIR calibration. *Chemometrics and Intelligent Laboratory Systems*, 182, 9–20.
- da Silva, I. N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B., & dos Reis Alves, S. F. (2017). Artificial Neural Network Architectures and Training Processes. In *Artificial Neural Networks* 21–28. Springer International Publishing.
- Debus, B., Parastar, H., Harrington, P., & Kirsanov, D. (2021). Deep learning in analytical chemistry. In *TrAC - Trends in Analytical Chemistry Vol. 145*, 1–7.
- Demuth, H., & Beale, M. (1992). *Neural Network Toolbox For Use with MATLAB User's Guide*, 2-35.
- Deng, J., & Lin, Y. (2022). Frontiers in Computing and Intelligent Systems The Benefits and Challenges of ChatGPT: An Overview. *Frontiers in Computing an Intelligent Systems*, 1–3.
- Európai Parlament. (2023). A mesterséges intelligencia használata és veszélyei | Hírek | Európai Parlament, 1-4.
- Fine, D., Havas, A., Hieronimus, S., Jánoskúti, L., Kadocsa, A., & Puskás, P. (2018). *Átalakuló munkahelyek: az automatizálás hatása Magyarországon*. Budapest: McKinsey & Company, 1-30.
- Guiné, R. P. F. (2019). The Use of Artificial Neural Networks (ANN) in Food Process Engineering. *ETP International Journal of Food Engineering*, 15-24.
- Hrycej, T., Bermeitinger, B., Cetto, M., & Handschuh, S. (2023). *Mathematical Foundations of Data Science*. Springer International Publishing, 55-201.
- Jia, W., Li, Y., Qu, R., Baranowski, T., Burke, L. E., Zhang, H., Bai, Y., Mancino, J. M., Xu, G., Mao, Z. H., & Sun, M. (2019). Automatic food detection in egocentric images using artificial intelligence technology. *Public Health Nutrition*, 22(7), 1168–1179.
- Jiang, D., Hu, G., Qi, G., & Mazur, N. (2021). A Fully Convolutional Neural Network-based Regression Approach for Effective Chemical Composition Analysis Using Near-infrared Spectroscopy in Cloud. *Journal of Artificial Intelligence and Technology*, 1(1), 74–82.
- Lo, C. K. (2023). What Is the Impact of ChatGPT on Education? A Rapid Review of the Literature. In *Education Sciences (Vol. 13, Issue 4)*, 3–10. MDPI.

- Mahesh, B. (2018). Machine Learning Algorithms-A Review. *International Journal of Science and Research*, 3-5.
- Mavani, N. R., Ali, J. M., Othman, S., Hussain, M. A., Hashim, H., & Rahman, N. A. (2022). Application of Artificial Intelligence in Food Industry—a Guideline. In *Food Engineering Reviews* (Vol. 14, Issue 1, pp. 134–175). Springer.
- Misra, N. N., Dixit, Y., Al-Mallahi, A., Bhullar, M. S., Upadhyay, R., & Martynenko, A. (2022). IoT, Big Data, and Artificial Intelligence in Agriculture and Food Industry. *IEEE Internet of Things Journal*, 9(9), 6305–6324.
- Moore, J. C., DeVries, J. W., Lipp, M., Griffiths, J. C., & Abernethy, D. R. (2010). Total protein methods and their potential utility to reduce the risk of food protein adulteration. In *Comprehensive Reviews in Food Science and Food Safety* (Vol. 9, Issue 4, pp. 330–357).
- Német, B. (2010). Elm-6-Infravörös-spektroszkópia, [H.n.], [K.n.] 11-15.
- Paschek, D., Mocan, A., Dufour, C. M., & Draghici, A. (2017). Organizational knowledge management with Big Data. the foundation of using artificial intelligence. *Balkan Region Conference on Engineering and Business Education*, 3(1), 301–308.
- Selenko, E., Bankins, S., Shoss, M., Warburton, J., & Restubog, S. L. D. (2022). Artificial Intelligence and the Future of Work: A Functional-Identity Perspective. *Current Directions in Psychological Science*, 31(3), 272–279
- Taneja, A., Nair, G., Joshi, M., Sharma, S., Sharma, S., Jambrak, A. R., Roselló-Soto, E., Barba, F. J., Castagnini, J. M., Leksawasdi, N., & Phimolsiripol, Y. (2023). Artificial Intelligence: Implications for the Agri-Food Sector. In *Agronomy* (Vol. 13, Issue 5). MDPI.
- Theodoridis, S. (2015). Neural Networks and Deep Learning. In *Machine Learning* (pp. 875–936). Elsevier.
- Vas, A. (2019). Tejsavófehérje koncentrátumok hamisításának kimutathatósága közeli infravörös spektroszkópiával, 55-62.
- Vasisht, D., Chandra, R., Kapoor, A., Sinha, S. N., Sudarshan, M., Stratman, S., Kapetanovic, Z., Won, J., & Jin, X. (2017). FarmBeats: An IoT Platform for Data-Driven Agriculture 517-521.
- Vedaldi, A., & Lenc, K. (2015). MatConvNet: Convolutional neural networks for MATLAB. *MM 2015 - Proceedings of the 2015 ACM Multimedia Conference*, 689–692.

- Wang, D., Tian, F., Yang, S. X., Zhu, Z., Jiang, D., & Cai, B. (2020a). Improved deep CNN with parameter initialization for data analysis of near-infrared spectroscopy sensors. *Sensors (Switzerland)*, 20(3), 2–16.
- Weng, S., Guo, B., Tang, P., Yin, X., Pan, F., Zhao, J., Huang, L., & Zhang, D. (2020). Rapid detection of adulteration of minced beef using Vis/NIR reflectance spectroscopy with multivariate methods. *Spectrochimica Acta - Part A: Molecular and Biomolecular Spectroscopy*, 230, 1–8.
- Yang, J., Xu, J., Zhang, X., Wu, C., Lin, T., & Ying, Y. (2019a). Deep learning for vibrational spectral analysis: Recent progress and a practical guide. *Analytica Chimica Acta*, 1081, 6–17.
- Ying, X. (2019). An Overview of Overfitting and its Solutions. *Journal of Physics: Conference Series*, 1168(2), 3–6.
- Zarifhonarvar, A. (2023). Economics of ChatGPT: A Labor Market View on the Occupational Impact of Artificial Intelligence.
- Zhang, W., Kasun, L. C., Wang, Q. J., Zheng, Y., & Lin, Z. (2022). A Review of Machine Learning for Near-Infrared Spectroscopy. In *Sensors (Vol. 22, Issue 24)*. MDPI.
- Zhou, L., Zhang, C., Liu, F., Qiu, Z., & He, Y. (2019). Application of Deep Learning in Food: A Review. In *Comprehensive Reviews in Food Science and Food Safety (Vol. 18, Issue 6, pp. 1793–1811)*. Blackwell Publishing Inc.
- Zhou, Q., Zhang, H., & Wang, S. (2022). Artificial intelligence, big data, and blockchain in food safety. In *International Journal of Food Engineering (Vol. 18, Issue 1, pp. 1–14)*. De Gruyter Open Ltd.
- Zinia, J.-L. Z. (2021). Application of electronic tongue and near infrared spectroscopy to detect adulteration of some foods with high economic value, 12-68

## Internetes források

- Dr. Szabó, O. (2021). Mesterséges Intelligencia a jogi szolgáltatásokban – elkészült a gyakorlati útmutató az okos jogi technológiák alkalmazásához. FintechZone. (2023.09.13.) Internet: <https://fintechzone.hu/mesterseges-intelligencia-a-jogi-szolgaltatasokban-elkeszult-a-gyakorlati-utmutato-az-okos-jogi-technologiak-alkalmazasahoz/>
- FÉSZ. (2019). Ipar 4.0 az élelmiszeriparban. (2023.09.19.) Internet: <http://elelmiszeripar.hu/2019/04/17/ipar4-az-elelmiszeriparban/>
- Gülen, K. (2023). Weak AI: Narrow but useful lane of artificial intelligence. Data Conomy. (2023.09.19.) Internet: <https://dataconomy.com/2023/03/02/what-is-weak-artificial-intelligence/>
- Markets and Markets. (2023). Google's Project Mineral in 2023: Revolutionizing Agriculture with AI. (2023.09.19.) Internet: <https://www.marketsandmarkets.com/industry-news/Google-Project-Mineral-In-2023-Revolutionizing-Agriculture-With-AI>
- Menedzsment és Controlling Portál. (2018). Milyen új állásokat teremt a mesterséges intelligencia? Menedzsment És Controlling Portál. (2023.09.13.) Internet: <https://www.controllingportal.hu/milyen-uj-allasokat-teremt-a-mesterseges-intelligencia/>
- Rádi. (2023). Nagy Márton: Az AI hatalmas lökést adhat a magyar gazdaságnak, de látni a veszélyeket is. Index. (2023.09.12.) Internet: <https://index.hu/gazdasag/2023/09/11/nagy-marton-ai-summit-mesterseges-intelligencia-magyarorszag-gazdasag-gazdasagfejlesztési-miniszterium-gfm/>
- van der Meulen, R., és Pettey, C. (2017). Gartner Says By 2020, Artificial Intelligence Will Create More Jobs Than It Eliminates. (2023.09.13.) Internet: <https://www.gartner.com/en/newsroom/press-releases/2017-12-13-gartner-says-by-2020-artificial-intelligence-will-create-more-jobs-than-it-eliminates>
- Villasenor, J. (2023). How AI will revolutionize the practice of law. (2023.09.13.) Internet: <https://www.brookings.edu/articles/how-ai-will-revolutionize-the-practice-of-law/>

## Köszönetnyilvánítás

Ezúton fejezem ki hálámat és köszönetemet témavezetőimnek, Dr. Gillay Zoltánnak és Dr. Kovács Zoltánnak, akik az elmúlt időszakban nyújtott szakmai irányításukkal és támogatásukkal nélkülözhetetlen segítséget nyújtottak a dolgozatom elkészítéséhez. Kiemelten köszönöm Dr. Gillay Zoltánnak a rengeteg türelmet és támogatást, amit adott. Az ő hozzájárulásuk nélkül a szakdolgozat nem jöhetett volna létre.

Továbbá köszönöm családomnak és barátaimnak, akik mellettem álltak és támogattak engem minden lépésnél, biztatásukkal és megértésükkel hozzájárulva személyes és szakmai fejlődésemhez.

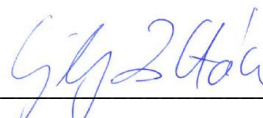
## NYILATKOZAT

Halek Mátyás (hallgató Neptun azonosítója: DF3ZX2) konzulenseként nyilatkozom arról, hogy a diplomadolgozatot áttekintettem, a hallgatót az irodalmi források korrekt kezelésének követelményeiről, jogi és etikai szabályairól tájékoztattam.

A diplomadolgozatot a záróvizsgán történő védelemre javaslom / **nem javaslom**.

A dolgozat állam- vagy szolgálati titkot tartalmaz: igen nem

Kelt: 2023. év november hó 8. nap



---

belső konzulensek

# NYILATKOZAT

## a diplomadolgozat nyilvános hozzáféréséről és eredetiségéről

A hallgató neve: Halek Mátyás  
A Hallgató Neptun kódja: DF3ZX2  
A dolgozat címe: Mesterséges intelligencia alkalmazása az élelmiszeriparban  
A megjelenés éve: 2023  
A konzulens intézetének neve: Élelmiszertudományi és -technológiai Intézet  
A konzulens tanszékének a neve: Élelmiszeripari Mérés-technika és Automatizálás Tanszék

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

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

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

Tudomásul veszem, hogy az általam készített dolgozatra, mint szellemi alkotás felhasználására, hasznosítására a Magyar Agrár- és Élettudományi Egyetem mindenkori szellemitulajdonkezelési 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: 2023. 11. 08.



---

Hallgató aláírása