

SZAKDOLGOZAT

Danyi Bence Csaba

2024



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

MESTERSÉGES INTELLIGENCIA ALKALMAZÁSA
PRECÍZIÓS TERMESZTÉS TÁMOGATÁSÁRA

Belső konzulens:

Belső konzulens intézete/tanszéke:

Külső konzulens:

Készítette:

Dr. habil. Baranyai László

egyetemi tanár

**Élelmiszertudományi és
Technológiai Intézet**

**Élelmiszeripari
Méréstechnika
és Automatizálás**

Danyi Bence Csaba

Budapest

2024

Tartalomjegyzék:

1.	Bevezetés és célkitűzés	2
2.	Szakirodalmi áttekintés	3
2.1.	Klímaváltozás és hőhullámok	3
2.2.	Gyümölcsök napégése	4
2.3.	Gépi tanulás.....	5
2.4.	Neurális hálózatok.....	7
2.5.	Mesterséges intelligencia.....	8
3.	Alkalmazott módszerek	10
4.	Eredmények és értékelésük	18
5.	Következtetések és javaslatok	23
6.	Összefoglalás	25
7.	Köszönetnyilvánítás	26
8.	Felhasznált irodalmak jegyzéke	26
9.	Ábrajegyzék	28

1. Bevezetés és célkitűzés

Az elmúlt években a számítástechnika robbanásszerű fejlődésének köszönhetően egyre nagyobb figyelem fordult a precíziós mezőgazdasági technológiák irányába, amelyek alkalmazása lehetővé teszi a termesztések optimalizálását, így számottevő mértékben növelve a hatékonyságot. Az egyik terület ebben a témában a különböző gépi modellek alkalmazása, melyek segítségünkre lehetnek a különféle környezeti és időjárási nehézségek előrejelzésében, így lehetővé teszik azt, hogy képesek legyünk időben reagálni.

A mezőgazdasági termelések során a különféle stresszfaktorok, mint például a drasztikus hőmérsékletingadozások, a csapadékszegény időszakok, vagy akár a túlzott napsugárzás komoly kockázatokat hordoznak, ugyanis ezek a tényezők jelentős károkat képesek okozni mind a termények minőségében, mind pedig a kihozatalban. Ezeket szemelőtt tartva egyre nagyobb igény mutatkozik olyan technológiai megoldásokra, amelyek lehetővé teszik a lehető leghatékonyabb védekezést.

Szakedolgozatom ezen belül egy konkrét esetre lett kihegyezve, amely egy olaszországi szőlőültetvényen elvégzett kísérlet volt. A célom az volt, hogy a mesterséges intelligenciát, pontosabban a TensorFlow modellt és a rendelkezésemre álló meteorológiai adatokat felhasználva kidolgozzak egy olyan rendszert, amely időjárási adatok alapján képes előre jelezni azt, hogy mikor és milyen paraméterek teljesülése esetén kell napégésre számítani, lehetővé téve ezzel a termelési hatékonyság növelését.

Élelmiszerterménként hallgatóként fontosnak érzem, hogy lehetőséget teremtsünk a fenntartható termelés kialakítására és hogy minimalizálni tudjuk az ültetvényeken fellépő termésveszteségeket, ugyanis az idő előrehaladtával egyre komolyabban kell majd azon dolgoznunk, hogy egy adott termőterület lehetőségeit maximálisan kihasználjuk. Emellett hiszem azt, hogy a minőségi élelmiszer előállítása legnagyobb részben a minőségi alapanyagok felhasználásán múlik, és ahogy korábban említettem a napégés komoly minőségbeli romlást eredményez a növényeken.

2. Szakirodalmi áttekintés

2.1. Klímaváltozás és hőhullámok

Az éghajlati rendszer öt alapvető elemének (légkör, óceán, krioszféra, bioszféra, talajfelszín) összefonódása, és ezek kölcsönhatásai határozzák meg a Föld klímáját. Az éghajlati folyamatok egyik leglényegesebb tényezője a légköri hőmérséklet változása. Ezt a folyamatot alapvetően a Napból beérkező, és a Földről távozó sugárzások egyensúlyhiánya okozza. A felmelegedésért a Földre irányuló napsugárzás a felelős. A beeső sugarakból származó energiát a földfelszín abszorbeálja, ennek következményeképpen felmelegszik. A hűtő hatást pedig a Föld felszínéről származó infravörös sugárzás okozza, amely a világűrbe irányul. A planetáris energia-egyensúly hosszútávú fenntartásához a beérkező és távozó sugárzásoknak egyensúlyban kellene lenniük. Ameddig a felmelegedés leginkább az alacsonyabb földrajzi szélességeken figyelhető meg, addig a lehűlés inkább a sarkvidékeken és egyéb olyan helyeken jellemző, ahol kevésbé intenzív a napsugárzás. A krioszféra, azaz a Föld felszínén lévő jég- és hókonformációk összessége kifejezetten gyorsan reagál a hőmérséklet megváltozására. A többnyire téli időszakokban jellemző kontinentális hótakaró, ha nem is tárol jelentős hőmennyiséget, kiemelt szerepet játszik a klímaváltozásban. A hóval fedett felszín ugyanis a ráeső sugarak jelentős részét visszaveri, ezzel csökkentve a felszín hőmérsékletét (MacCracken & Luther, 1985). Az éghajlati rendszerben a légkörben jelenlévő üvegházhatású gázok, mint például a szén-dioxid hasonlóképpen működnek, mint a kertészetekben alkalmazott üvegházak lapjai. Ezek a gázok átengedik a Napból érkező elektromágneses sugarakat, de a felszín felől érkező hőmérsékleti sugárzás útját gátolják. Ennek következtében felborul a korábban említett planetáris energia-egyensúly és a felszínhez közeli hőmérséklet jóval melegebb lesz, mint ezek nélkül a gázok nélkül lenne (Bottyán, 2009). Az éghajlati változások megértéséhez és azok lehetséges előrejelzéséhez elengedhetetlen ezen komplex folyamatok vizsgálata és ismerete (Bartholy & Pongrácz, 2013). Az elmúlt évtizedek tapasztalatai alapján egyértelmű, hogy az éghajlatváltozás egyre inkább fejti ki hatását az időjárási szélsőségek terén is. Ezek közül is leginkább a hőhullámok számának és időtartamának szignifikáns növekedése a legjellemzőbb. Manapság a klímaváltozást előszeretettel emlegetik az igen nagy léptékben történő, ugyanakkor a környezetre káros hatást gyakorló emberi tevékenység szimbólumaként. Fontos megjegyezni, hogy bár bolygónk klímája folyamatosan változik, de a szélsőséges időjárási elemek sokkal

több negatív hatással bírnak az ökoszisztémára, az emberi szervezetre és a mezőgazdaságra, mint a meteorológiai értékek lassú, de folyamatos változásai. A nappali hőmérsékleti maximum és a hőségnapok gyakoriságának növekedése, valamint az aszályos időszakok hosszának kitolódása mind olyan történések, amelyeket a közvélemény a hőhullám fogalmával azonosít, annak ellenére, hogy a hőhullám definíciójára nem létezik egységes nemzetközi meghatározás. Azt, hogy egy adott térségben mikor van hőhullám meteorológiai szolgálatok közreműködésével határozzák meg az adott területre jellemző normál éghajlati paraméterek alapján. Erre azért van szükség, mivel nem lehet egyértelmű határértékeket megszabni a hőhullámok küszöbértékeként, mivel minden területnek megvan a saját klímája, amik eltérő tartományok között mozognak. Magyarországon az Országos Meteorológiai Szolgálat (OMSZ) által kidolgozott háromfokú rendszerét használjuk, ami az egészségügyi kockázat figyelembevételével készült el. (Imre és mtsai., 2014)

2.2. Gyümölcsök napégése

A növények számára a túlzottan magas hőmérséklet számos kedvezőtlen hatással bír, amelyek összetett módon befolyásolják a fejlődésüket és egészségüket. Ezek a hatások szerteágazó módon érintik a növények struktúrája és növekedése mellett a hormon- és másodlagos anyagcserezintézisüket is. A növények hőmérséklettel kapcsolatos toleranciája természetesen faj- és fajtafüggő, az azonban általánosságban kijelenthető, hogy a gyümölcstermő növények számára a hőmérsékleti optimum a vegetációs időszak közepén általában 15°C és 30°C közé esik. A 35 °C-nál tartósan magasabb hőmérséklet esetén a légzésintenzitás jelentős mértékben emelkedik, ami az asszimiláció, azaz a felvett tápanyagok beépülésének csökkenéséhez vezet, és hőstresszt idéz elő. A tartósan fennálló hőstressz akár a növény pusztulását is okozhatja, mivel az egyed nem képes megfelelő mennyiségű tápanyagot hasznosítani. Ezen túlmenően a magas hőmérséklet zavarokat okozhat a vízforgalomban, amiből kifolyólag előfordulhatnak anyagcserezavarok is. A fenntartható és nem utolsó sorban hatékony növénytermesztés érdekében elengedhetetlen a hőmérsékleti változásokra való gyors reagálás, ideértve akár egyes hőtoleráns fajták mesterséges létrehozását, vagy olyan fajok megteremtését melyek lombkoronája megfelelő árnyékot ad gyümölcssei számára. A magas hőmérséklet mellett a növények számára szintén jelentős veszélyt jelenthet az erős napsugárzás, ami úgynevezett napégést idéz elő. A napégés egyfajta fiziológiai károsodás, ami általában a növények felszínén látható. Például a levelek kifehéredése, perzselődése, valamint a gyümölcsök héjbarnulása a

napsütötte oldalon, vagy súlyos esetben akár héj- és húsbarnulás együttes előfordulása mind a napégés jellemző tünetei lehetnek. A nekrózis általában átható, sötétebb égési sérülésként jelentkezik. Ahhoz, hogy a gyümölcs felületén napégés következzen be elegendő 52 ± 1 °C felületi hőmérséklet mindössze 10 percig (Darbyshire és mtsai., 2015). Ezzel a legnagyobb probléma, hogy nem csupán a növények esztétikai minőségét rontja, de jelentősen csökkenti piaci értéküket, és korlátozza a friss értékesítésen kívüli egyéb felhasználási lehetőségeket is. Emellett a tárolhatóság hosszát is lerövidíti, mivel a felületi károsodás fokozott lehetőséget nyújt arra, hogy a terményt kórokozó gombák fertőzzék meg. A napégésre való hajlam a hőmérséklettoleranciához hasonlóan faj- és fajtafüggő, viszont az általánosságban kijelenthető, hogy a világosabb héjú gyümölcsök esetében gyakrabban fordul elő, emellett a tapasztalatok azt mutatják, hogy a kifejtett, vagy kifejtetthez közeli állapotban lévő gyümölcsök esetében szintén nagyobb számban figyelhető meg, valamint sűrűn ültetett kisebb lobkoronájú fákat tartalmazó gyümölcsösökben többször fordul elő napégés mint olyan kertekben ahol ritkábban vannak ültetve a fák és nagyobb lomboronával rendelkeznek (Morales-Quintana és mtsai., 2020). Különösen akkor gyakori a napégés kialakulása, ha a szüret nem az optimális időben történik meg, hanem a gyümölcs valamivel tovább marad a növényen. A globális éghajlatváltozások miatt napjainkban már a mérsékelt égövön fekvő területeken túl a trópusi és szubtrópusi éghajlattal rendelkező termőterületeken is egyre növekszik a magas UV sugárzás okozta napégés kockázata, és igen valószínű, hogy ez a hatás a jövőben sem fog mérséklődni. Az agrárkutatásoknak és a növénytermesztési gyakorlatnak egyre nagyobb mértékben kell alkalmazkodniuk a klímaváltozás következtében kialakuló új viszonyokhoz (Hampel és mtsai., 2023; Racskó és mtsai., 2006, Racskó és mtsai., 2005).

2.3. Gépi tanulás

A mesterséges intelligencia, (azaz MI) egy olyan forradalmi terület, mely az emberi intelligencia reprodukálására és minél pontosabb szimulálására törekszik gépi rendszerek segítségével. Ez az ágazat a gépi tanulás terén elért áttöréseken, az adatok és információk feldolgozásának technológiai előrelépésein, valamint a számítási kapacitás robbanásszerű fejlődésén alapul. A definíciók értelmezésekor fontos kiemelni a mesterséges intelligencia azon képességét, ami lehetővé teszi számára, hogy adatok és körülmények alapján tanuljon és adaptálódjon. A gépi tanulás története egészen az 1950-es évekig vezethető vissza, amikor megjelentek az első olyan rendszerek, amelyek adatok alapján képesek voltak tanulni. Eleinte

a fejlődés természetesen nem volt olyan gyors, mint napjainkban és leginkább csak kutatási területként szolgált. A XX. század végére azonban a technológiai fejlődés, különösen a hardverek terén történő hatalmas előrelépések és a felhő alapú számítási modellek alkalmazása lehetővé tette a terület ugrásszerű fejlődését. A hatalmas adattömegek megjelenése kritikus szerepet játszott abban, hogy egyre fejlettebb és hatékonyabb gépi tanulási modellek jöhessenek létre. Ez a terület azért kapott kiemelt figyelmet, mivel felismertük azt, hogy a gépeink csak akkor válhatnak intelligensebbé, ha elegendő adattal és megfelelő módszerrel vannak betanítva. Emellett a számítási kapacitás bővülése is elengedhetetlen részét képezte annak, hogy a gépek gyorsan és hatékonyan legyenek képesek adatokat feldolgozni (Bihari, 2019). A gépi tanulás számos fajtája ismert, az ellenőrzött tanulástól kezdve a megerősítéses tanulásig. Az ellenőrzött tanulás során a gépek olyan adathalmazokból tanulnak, amelyek alapból tartalmazzák a kívánt megoldást például az osztályozás és a regresszió estében. Ezzel ellentétben a nem-ellenőrzött tanulásnál a tanító adathalmaz nem rendelkezik előre megadott megoldásokkal, hanem a rendszernek saját magától kell felismernie és kinyernie a mintákból az információt. Az ellenőrzött és nem-ellenőrzött tanulás mellett létezik félig-ellenőrzött tanulás is, kiváló példa lehet erre a Google Photos, ahol a folyamat felügyelet nélküli részében az algoritmus felismeri a feltöltött fényképeken lévő azonos személyeket, majd, ha megadjuk a képekhez a személyek nevét akkor el is nevezi őket, természetesen a folyamat sokszor nem tökéletes, ezért gyakran manuális utókorrekcióra van szükség. A legtöbb félig-felügyelt tanulási algoritmus felügyelt és felügyelet nélküli tanítás kombinációja. A gépi tanulásnak többféle felhasználási területe létezik, például a klaszterezés vagy csoportosítás, amikor a rendszer csoportokra osztja a kapott adatokat a bennük fellelhető minták alapján. A dimenziócsökkentés célja pedig, hogy a modell az adatokat anélkül egyszerűsítse, hogy információt veszítenénk el. Emellett az algoritmusok szabálytalansági vizsgálatokra is képesek. Ebben az esetben normál, szabályos mintákat használunk tanításra, és ezután a rendszer képes megállapítani, hogy az új minták valamilyen szinten eltérnek-e a „megszokottól”. A megerősítéses tanulás egy kifejezetten izgalmas megoldás, mely során a tanuló rendszer megvizsgálja a körülményeket, választ egy műveletet és a végeredmény függvényében jutalmat vagy büntetést kap. Saját magától kell kidolgoznia egy olyan stratégiát, melyben a lehető legtöbbször kap jutalmat. A stratégia természetesen folyamatosan frissül és addig ismétlődik, ameddig ki nem alakul az optimális folyamatsor, ez fogja a későbbiekben meghatározni, hogy egy adott szituáció esetében a modell melyik műveletet fogja választani. Természetesen ahogyan minden egyéb dolognak a gépi tanulás használatának is vannak nehézségei. Például, ha az adatok minősége nem megfelelő, vagy az adathalmaz nem reprezentatív, esetleg kevés adatot tartalmaz. A létrehozott modell

bonyolultságától függően bekövetkezhet alultanulás, de ugyanúgy akár túltanulás is. Mivel a betanított modellek hatékonyságát szeretnénk ellenőrizni, ezért kezdeti lépésben a rendelkezésre álló adathalmazt felosztjuk tanító- és teszhalmazra. Ezek aránya általában 80:20 arányban oszlik meg. A teszhalmazt arra használjuk, hogy felmérhessük az új minták esetében fellépő általánosítási hiba mértékét még mielőtt a modellt valós helyzetben alkalmazzuk. Az általánosítási hiba megmutatja, hogy hogyan teljesít az adott modell a teszhalmaz után eddig még számára ismeretlen adatokon. Ha a modell a tanító halmazon jól teljesít, de új adatok esetén nem, akkor nagy valószínűséggel túltanult a tanító halmazon. Ebben az esetben megoldást jelenthet a tanító halmazon lévő zaj csökkentése, több adat beszerzése, vagy akár a modell egyszerűsítése. Ha azonban a modellek végső beállítására csak a teszhalmazt használjuk, akkor fennáll a veszélye annak, hogy a teszhalmazon túltanul a modell és a mért általánosítási hiba túl optimista eredményt mutat. Ennek elkerülésére érdemes létrehozni egy validációs halmazt, ami tulajdonképpen egy második teszhalmaz. Ez a módszer modellek összehasonlítására is alkalmas, anélkül, hogy értékes tanító adatokat „pazarolnánk”. Keresztvalidáció alkalmazásával jóval pontosabb érték nyerhető az adott modellek minőségéről, ami kifejezetten fontos lehet abban a helyzetben amikor modellezési döntést kell hoznunk (Mambetaliev & De Bot, 2020).

2.4. Neurális hálózatok

A neurális hálózatok széles körben elterjedtek, és kiválóan alkalmazhatóak különböző tudományos és műszaki területeken egyaránt. Felhasználhatók karakterfelismerésre, képfeldolgozásra, jelfeldolgozásra, adatbányászati célokra, bioinformatikai problémák megoldására, valamint mérés technikai és szabályozástechnikai célokra. Egy jól alkalmazott modellel könnyedén meg lehet oldani olyan összetett feladatokat, amelyek felbonthatók osztályozásra és regresszióra. A mesterséges neurális hálózatok tervezésénél valójában kiemelt szerepet játszott a biológiai neurális hálózatok ismerete és tanulmányozása, mivel ezek a természetes hálózatok rendkívül hatékonyak különböző feladatokban, például jelek és képek felismerésében. A biológiai rendszerek tanulmányozása során szerzett ismereteket felhasználva létrehoztak mesterséges neurális hálózatokat. A biológiai hálózatokhoz hasonlóan ezek a rendszerek is kis egységekből, azaz neuronokból épülnek fel és ezek között az egységek között rengeteg kapcsolat áll fenn. Emellett a biológiai rendszerek azon képességét vették alapul, hogy képesek tanulni. A neurális hálózatok alapvetően olyan számítási mechanizmusok, amelyek az

idegrendszer analógiáját követve, de nem teljesen másolva azt születtek meg. Ugyanis a fő cél az volt, hogy képesek legyünk egy olyan működő modell létrehozására, amely elektronikai megoldásokat és tudományos eljárásokat alkalmaz. A kialakított modell matematikai alapjait elméleti módszerekkel dolgozták ki, ezt követően alkalmazott matematikai módszerek felhasználásával számításokra alkalmassá tették, végül számítógépeken implementálták. Azonban gyakran van szükség heurisztikus megfontolásokra és természetesen számítógépes kísérletezésre is, nem csak matematikai módszerekre. A neurális hálózatokra tehát egymással összekapcsolt neuronokból álló rendszerekként tekinthetünk. A neuronok, vagy más néven idegsejtek, információ feldolgozására képes egységek, melyek a neurális hálózatok alapvető építőkövei. A neurális hálózatok kezdeti típusa az egyetlen neuronból álló perceptron volt, de a valóságban ma már többnyire többrétegű perceptront alkalmazunk. A többrétegű perceptron amelyben a neuronokat rétegekbe szervezzük különösen elterjedt. A hálózat rétegei közül megkülönböztetünk bemeneti, rejtett és kimeneti rétegeket. A rejtett rétegekből tetszőleges mennyiséget tartalmazhat, de bemeneti és kimeneti rétegekből csak egyet-egyed. Minden neuron saját aktivációs függvényrel és súlyokkal rendelkezik. A többrétegű perceptron betanításának négy lépése van. Kezdetben meghatározzuk a kiindulási súlyokat, majd a bemeneti jelet átáramoltatjuk a hálózaton, anélkül, hogy a súlyokat megváltoztatnánk. A kapott kimeneti jelet összehasonlítjuk a tényleges kimeneti jellel, majd a hibát visszaáramoltatjuk a hálózaton keresztül, viszont ebben az esetben a súlyokat a hiba minimalizálásának érdekében módosítjuk (Noriega, 2005). Összességében a neurális hálózatok rendkívül sokoldalú rendszerek, melyek kiválóan alkalmazhatók különféle feladatok megoldására. Tervezésükhöz és alkalmazásukhoz egyaránt szükség van matematikai ismeretekre, számítógépes kísérletezésre és a biológiai rendszerek tanulmányozásával megismert alapelvekre is (Fazekas, 2013; Popescu és mtsai., 2009).

2.5. Mesterséges intelligencia

Bár a mesterséges intelligenciát nehéz egy általános definícióval összefoglalni, a világ egyetért abban, hogy milyen elvárásoknak kell megfelelnie egy ilyen alkotásnak. A mesterséges intelligenciát elképzelve gyakran olyan megoldásokra gondolunk, amelyek gépi módszerek alkalmazásával ugyan, de a megtévesztésig hasonlítanak az emberi, vagy akár az állati viselkedésre, ami bizonyos szemszögből nézve egy helytálló megközelítés, ugyanis az élő szervezetek fennmaradása és folyamatos fejlődése szoros kapcsolatban áll az alkalmazkodó

képességgel (Boden, 1996). Az élőlények szüntelenül érzékelik a körülöttük lévő világot, a gyűjtött információt kiértékelik, majd ennek megfelelően reagálnak. Az adaptív élőlények az alkalmazkodás során egy sor genetikai változás révén új populációkat hoznak létre, melyek egyre komplexebb válaszokat képesek adni a környezetükre az evolúció során. Kétségtelenül az emberi intelligencia a legösszetettebb variáció mind közül. Különlegessége többek közt abban rejlik, hogy a saját működésének mintájára mesterséges működéseket teremt, amely különböző környezeti ingerek hatására reagálva segít elérni a kitűzött célokat. Az emberi intelligencia kisegítésére létrehozott gépi intelligencia felhasználási körét nagyban megnövelik az időközben egyre fejlődő számítógépek. Amikor 1997-ben az IMB Deep Blue sakkprogramja legyőzte Garri Kaszparov világbajnokot igazi mérföldkő volt, mára azonban a mesterséges intelligencia fejlesztése nem csupán manuális programozáson alapul. A kutatások középpontjában olyan rendszer létrehozása áll, amely képes önállóan cselekedni és fejlődni. Az előre meghatározott szempontok szerinti programozást fokozatosan felváltotta a korábban már tárgyalt gépi mélytanulás és a megerősítéses tanulás (Csepeli, 2020). Egészen más eredményt hoztunk egyetlen problémából kiindulva próbáljuk megtalálni a legjobb megoldást. Ahelyett, hogy egy rögzített módszert alkalmazna, az AI (artificial intelligence) megpróbál folyamatosan új lehetséges utakat kidolgozni a lehető legtöbb különböző feladatra (Ertel, 2018). Az egyre nagyobb mennyiségű rendelkezésre álló adatnak és a korábban tárgyalt gépi tanulásnak köszönhetően a mesterséges intelligencia egyre komplexebb döntések meghozatalára képes (Berente és mtsai., 2021). Természetesen a mesterséges intelligenciát nem csak szofveres megoldások korlátai közé szorítva alkalmazhatjuk, hanem egyre inkább terjednek el a hardveres implementációk is. A hatékony robotizáció szoros kapcsolatban áll a mesterséges intelligencia mellett a szenzortechnológiák fejlődésével és a Information and Communication Technology (ICT), azaz az információ- és kommunikációstechnológia alkalmazásával is (Bártfai és mtsai., 2018). A kognitív számítástechnikát alkalmazó technológiák bevezetése többek között lehetőséget teremtett a mezőgazdasági robotika fejlődésére. Példának okáért, ami eddig emberi érzékszervek helyszíni bevonását igényelte, mint a növényi betegségek azonosítása, vagy a termények érettségi szintjének megállapítása, az ma már könnyedén helyettesíthető gépi látórendszerekkel felszerelt robotok alkalmazásával. A növénytermesztésben használt robotok mellett az elmúlt két évtizedben a legnagyobb fejlődést a fejőrobotok mutatták. Ezek a robotok nem ritkán sokkal nagyobb hatékonysággal képesek dolgozni mint az emberek (Kiss, 2023). Mint minden új technológiának, a mesterséges intelligenciának is vannak veszélyei és árnyoldalai. Egyes formáinál, kiváltképp azokat tekintve, amelyek gépi tanulást alkalmaznak fennáll az a veszély, hogy egy ember sem érti, hogy milyen következtetések útján hoz döntést

és mit miért csinál, ebből kifolyólag számunkra kiszámíthatatlanná válhat. Mivel gyorsan és hatékonyan képes a rendelkezésére álló adatokat elemezni, ezért javaslataival megkönnyítheti bizonyos döntések meghozatalát, de az előbbieken vázolt veszély ismeretében érdemes felvetni a kérdést, hogy mikor és milyen mértékben érdemes megbízni egy ilyen eszközben (Hampel és mtsai., 2023).

3. Alkalmazott módszerek

A Davis Instruments meteorológiai állomások igen nagy népszerűségnek örvendenek mivel könnyen telepíthetőek, ugyanakkor pontos és megbízható időjárási adatok gyűjtését teszik lehetővé. A helyszíni meteorológiai adatokat számomra is egy Davis Instruments márkájú meteorológiai állomás gyűjtötte 51 napon keresztül. Főbb jellemzőjük ezeknek a berendezéseknek, hogy alapvetően komplex érzékelőkkel vannak felszerelve, amely lehetővé teszi, hogy egyszerre mérjenek szélsébséget, szélirányt, hőmérsékletet, páratartalmat és csapadékszintet is. Jelen esetben azonban további integrált érzékelők alkalmazására is szükség volt, mivel a kísérlet talán legfontosabb elemei a napsugárzással kapcsolatos adatok voltak.

A meteorológiai állomás által gyűjtött adatok excel tábla formájában álltak rendelkezésemre, melyek alapvetően három fontos oszlopot tartalmaztak, úgy mint: hőmérséklet, páratartalom és napsugárzás. Mivel a meteorológiai berendezés 15 percenként gyűjtött adatokat, így a megközelítőleg két hónapos megfigyelés során 4900 adatot gyűjtött be. A kapott kiindulási adatokat számomra kedvezőbb formába alakítottam úgy, hogy további oszlopokra osztottam fel a mért adatokat, illetve az egész napos mérések eredményeiből egy-egy napra jellemző adatokat készítettem (**1. táblázat**).

Az általam létrehozott táblázat a hőmérsékleti adatokat felosztva már tartalmazott átlagos hőmérséklet, maximális hőmérséklet, hőmérséklet különbség és hőmérsékletek összege oszlopokat is. A hőmérsékletek különbsége oszlopba az egymást követő két nap maximális értékeinek különbsége, míg a hőmérsékletek összege oszlopba pedig a megelőző két nap átlaghőmérsékletének összege került. A napsugárzás oszlop adatait szintén a hőmérsékleti adatoknál alkalmazott elv alapján dolgoztam fel. A páratartalmat az előző két adatsortól eltérően csak átlagos páratartalom és maximális páratartalom oszlopokra osztottam fel. Fontos észrevenni, hogy az így létrehozott adattábla adatai időrendben követték egymást, ami

kedvezőtlen jelen esetben, mivel egy ilyen táblázatot alapul véve nem egyértelműen meghatározható, hogy milyen értékeket meghaladva jelentkezik károsodás a terményekben.

1. táblázat: Feldolgozott adatok (Forrás: Saját készítés, kapott adatok alapján)

TempAVG	TempMAX	TempDIFF	TempSUM	RadAVG	RadMAX	RadDIFF	RadSUM	HumidAV	HumidMA	DAMAGE
25,977	32,4	0	51,954	228,86	966,5	0	457,71	62,248	92,2	0
26,761	33,5	1,1	52,739	246,74	895,2	17,882	475,59	57,733	92,4	0
27,871	32,8	-0,7	54,632	216,98	970	-29,755	463,72	58,267	81,7	0
24,164	27,6	-5,2	52,034	47,723	288,4	-169,26	264,71	55,866	86,1	1
18,399	22,2	-5,4	42,563	98,291	654,3	50,568	146,01	85,877	96	1
23,13	30,5	8,3	41,529	304,91	905,8	206,62	403,2	55,927	86,3	1
21,768	27,9	-2,6	44,898	304,59	903,1	-0,3146	609,5	54,191	93	1
21,836	30,2	2,3	43,604	292,09	941	-12,501	596,68	50,28	82,8	1
23,17	31,2	1	45,006	268,36	890,8	-23,734	560,45	56,027	79,3	1
23,204	30,9	-0,3	46,373	246,76	941	-21,599	515,11	67,965	93,4	0
25,158	31,8	0,9	48,362	282,39	855,7	35,634	529,15	62,117	92	1
25,35	33,5	1,7	50,508	283,52	860,9	1,125	565,91	61,064	90,7	1
26,76	33,7	0,2	52,11	274,64	837,2	-8,8781	558,15	62,922	90,2	1
26,294	34	0,3	53,054	269,55	849,5	-5,0855	544,19	62,088	91,3	1
26,482	34,1	0,1	52,776	253,12	838,9	-16,432	522,67	60,553	89	1
27,4	34,3	0,2	53,882	268,89	868,8	15,775	522,01	60,897	88,3	1
26,713	33,1	-1,2	54,113	193,86	819,6	-75,031	462,76	64,873	86,5	0
27,577	34,7	1,6	54,29	260,71	838,1	66,85	454,58	63,207	88,5	1
28,072	35,3	0,6	55,649	267,88	831,9	7,1667	528,59	61,829	90,5	1
27,765	34,7	-0,6	55,836	261,76	846,9	-6,1208	529,64	61,349	87,6	1
28,391	35,6	0,9	56,155	265,86	833,7	4,1031	527,62	58,033	82,2	1
28,85	36,5	0,9	57,241	262,81	823,1	-3,049	528,67	56,426	82,5	1
29,48	38,1	1,6	58,33	263,29	822,2	0,4802	526,11	53,581	88,7	1
29,811	38,6	0,5	59,292	255,57	803,8	-7,7188	518,87	51,543	81,3	0
30,467	38,3	-0,3	60,278	251,61	804,7	-3,9646	507,18	50,615	83,9	0
29,646	37,7	-0,6	60,113	251,7	805,5	0,0938	503,31	43,776	74,2	1
26,652	33,4	-4,3	56,298	139,02	569,9	-112,69	390,72	58,407	73,9	1
23,976	29,2	-4,2	50,628	158,08	966,5	19,064	297,1	66,102	85,3	0
18,052	21	-8,2	42,028	92,399	553,1	-65,682	250,48	85,361	91,5	0
20,774	24,7	3,7	38,826	251,21	865,3	158,82	343,61	67,097	90,4	0
20,688	28,1	3,4	41,461	205,93	957,7	-45,281	457,15	69,372	88,5	0
23,253	29,5	1,4	43,941	248,32	806,4	42,385	454,25	60,673	82,9	1
23,91	31,2	1,7	47,164	244,25	802	-4,0719	492,57	66,26	89,8	1
24,943	31,6	0,4	48,853	226,35	814,3	-17,901	470,59	64,092	90,7	1
24,016	29,1	-2,5	48,958	246,14	847,7	19,795	472,49	61,566	86,8	0
22,44	27,2	-1,9	46,455	208,29	1041,2	-37,855	454,43	54,446	76,5	1
22,032	29,6	2,4	44,472	236,77	793,2	28,481	445,05	57,796	77,6	1
22,622	30,4	0,8	44,654	232,59	923,4	-4,1729	469,36	59,472	79,7	1
23,159	30,7	0,3	45,781	229,78	773,9	-2,8146	462,37	57,344	76,5	0
23,308	31,2	0,5	46,468	235,2	787,9	5,425	464,98	57,146	79,9	0
23,271	31,4	0,2	46,579	229,73	766,8	-5,4698	464,94	56,808	79,2	0
24,057	32,2	0,8	47,328	228,07	780	-1,6615	457,81	56,624	86,9	1
24,734	33,4	1,2	48,792	216,58	755,4	-11,49	444,66	55,679	82,2	1
24,531	30,1	-3,3	49,266	144,17	998,1	-72,416	360,75	57,209	78,9	1
24,122	29,9	-0,2	48,653	201,23	774,8	57,058	345,39	64,021	85,1	0
21,892	25,9	-4	46,014	163,58	902,3	-37,643	364,81	80,861	93,8	0
21,358	26,8	0,9	43,25	162,66	1002,5	-0,9208	326,25	83,971	97	0
23,439	28,5	1,7	44,797	168,33	737,8	5,6646	330,99	78,883	94,3	1
23,33	28,3	-0,2	46,768	62,57	271,7	-105,76	230,9	77,147	94,5	1
25,009	30,1	1,8	48,339	205,42	724,6	142,85	267,99	61,929	86,4	1
21,763	26,5	-3,6	46,773	86,728	409,8	-118,69	292,15	71,025	84,5	0

Ahhoz, hogy valamilyen számítástechnikai modellt alkalmazva meg tudjunk állapítani egy határértéket, növekvő sorrendbe kellett rendezni az adatokat, hogy kétséget kizáróan leszűrhessek, hogy milyen értéket meghaladva történik napégés a modell szerint. Bár ez a megoldás elméleti szinten működött, nem veszi figyelembe az adatok egymáshoz való viszonyulását, ezért létrehoztam több új adattáblát, amelyek az adatok korrelációs mátrixának felhasználásával készültek (**2. táblázat**).

2. táblázat: Korrelációs táblázat (Forrás: Saját készítés, kapott adatok alapján)

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10
1	0	0.92048279	0.3284213656	0.899463184	0.6010652269	0.435101367	0.0651865945	0.6446227261	-0.617848249	-0.6542899943
2	1.86E-22	0	0.4764308351	0.8289786653	0.6675128345	0.5333421135	0.05561838108	0.7386100347	-0.6733854744	-0.5449530997
3	0.01635281101	0.0003106514726	0	-0.01821756579	0.5307765655	0.2277179743	0.2754291217	0.2475730742	-0.4579188828	-0.2156640044
4	5.68E-20	1.79E-14	0.8969825475	0	0.4124372024	0.4012388914	-0.04742589958	0.613601591	-0.4488958963	-0.5219360864
5	1.95E-06	4.79E-08	4.34E-05	0.002148765292	0	0.8231293738	0.4214635996	0.8245960597	-0.77155226	-0.422423312
6	0.001130286881	3.92E-05	0.101024764	0.002904871526	3.92E-14	0	0.5342946591	0.7226040235	-0.5718168429	-0.2072934802
7	0.6428317337	0.6924302178	0.0459193317	0.7359490591	0.001672486364	3.78E-05	0	-0.0001414935041	-0.1802587112	-0.0460742797
8	1.90E-07	2.74E-10	0.07388579953	1.03E-06	3.23E-14	1.00E-09	0.9991977073	0	-0.7579228166	-0.403109767
9	8.27E-07	3.30E-08	0.0005652605982	0.0007477394875	1.37E-11	7.73E-06	0.196488395	5.00E-11	0	0.7532432424
10	1.08E-07	2.45E-05	0.1209177077	6.12E-05	0.001627855371	0.1363913513	0.7432128467	0.00276413812	7.65E-11	0

Ahogy a táblázatból is látszik, nem minden esetben pozitív a korreláció az adatok között, ami kiválóan szemlélteti azt, hogy miért volt kulcsfontosságú, hogy az adatok feldolgozása alatt figyelembe vegyem a korrelációs táblázatot. Mivel így már ne csak egyszerű növekvő táblázatok készültek, minden oszlop kiindulási adata az adott tényező minimum vagy maximum értéke volt és ezt követően a korrelációs adatoknak megfelelően növeltem a maximumig vagy csökkentettem a minimumig úgy, hogy megtartsam az 51 napos felosztást.

Az elkészített táblázatok elemzésére egy TensorFlow modellt használtam, amely egy olyan nyílt forráskódú, ugyanakkor nagy teljesítménnyel bíró számítástechnikai könyvtár, amelyet kifejezetten gépi tanulást, de leginkább mélytanulást igénylő feladatok végrehajtásához fejlesztett ki a Google. A TensorFlow hatékony megoldás adatfeldolgozási feladatokra mind kisebb, mind nagyobb projektek esetén. Kiválóan alkalmas neurális hálózatok kiépítésére és kezelésére, de emellett természetesen számos egyéb felhasználása lehet. Többek között alkalmas klasszifikációs, azaz osztályozási feladatokra, regressziós feladatokra előrejelzési célból, de emellett akár képfeldolgozásra is használható.

Kezdetben egy egyszerűbb kódot és kész modellt alkalmaztam az adatok kiértékelésére, de végül egy bonyolultabb, de pontosabb eredményekhez vezető kódot használtam. Többek között azért döntöttem a váltás mellett, mert a kezdeti kód egy már létező, betanított TensorFlow modellt használt, amely tulajdonképpen egy kész megoldás volt, amit egyszerűen csak futtatni kellett az adatokon. Viszont, ha a modell nem volt elég pontos akkor nagyon kevés lehetőséget kínált a finomhangolásra. Ezzel szemben az újabb és összetettebb kód már tartalmazza a neurális háló létrehozását és betanítását, ezzel sokkal nagyobb szabadságot biztosítva. A másik előnye a korábbi kóddal szemben, hogy tartalmaz validációt, ami segít meghatározni, hogy a modell mennyire teljesít jól számára ismeretlen adatokon.

1. ábra: Kódrészlet 1 (Forrás: Saját készítés)

```
import numpy as np
import pandas as pd
import tensorflow as tf
```

Kezdeti lépésként a kód behívja a felhasznált könyvtárakat (**1. ábra**). A „numpy” egy olyan matematikai könyvtár, ami képes hatékonyan dolgozni többdimenziós tömbökkel. A numpy tömbök olyan többdimenziós homogén adatszerkezetek, melyek optimalizáltságuk miatt memóriahatékonyabbak az egyszerű python listáknál, emellett a python listáktól eltérően az összes elemük ugyanolyan formátumban van jelen (többnyire számok, de lehetnek akár logikai értékek is). A „pandas” egy adatkezelési csomag, amely kifejezetten táblázatokba rendezett adatok kezelésére alkalmas. A „tensorflow” pedig az előbbieken ismertetett gépi tanulási könyvtár, amit az adatok tényleges kiértékelésére használtam.

2. ábra: Kódrészlet 2 (Forrás: Saját készítés)

```
ds = pd.read_csv('Radavg_no_2023.csv', sep=';')
nrow = ds.shape[0]
idx = np.random.choice(nrow, size=int(round(0.2*nrow,0)), replace=False)
train_data = ds.iloc[-idx]
test_data = ds.iloc[idx]
```

A következő művelet, hogy egy pandas függvénnyel beolvassuk az adatokat és utána olyan formátumra alakítjuk őket, hogy kompatibilis legyen a modellel (**2. ábra**). Az „np.random.choice” parancs az adattábla sorai közül kiválaszt véletlenszerűen 20%-ot tesztelési (korábban említett) variációs adathalmaznak, majd a fennmaradó 80%-ot fogja tanulási adathalmaznak használni.

3. ábra: Kódrészlet 3 (Forrás: Saját készítés)

```
features = tf.convert_to_tensor(train_data.iloc[:,0:10])
target = train_data.pop('DAMAGE_future')
vfeatures = tf.convert_to_tensor(test_data.iloc[:,0:10])
vtarget = test_data.pop('DAMAGE_future')
```

Ezt követően kiválasztjuk a beolvasott adatkészlet első tíz oszlopát (**3. ábra**). Ezek lesznek azok az értékek, amelyeket a modell bemenetként fog használni (features és vfeatures). Ezzel egyidejűleg az adatokból tensort készítünk, ugyanis a TensorFlow műveleteihez szükséges, hogy az adatok ebben a formában legyenek. A tensorok sokban hasonlítanak a numpy tömbökhöz, de támogatják a modell speciális műveleteit. A „pop” parancsokkal pedig a megnevezett oszlopból választjuk ki a célváltozót (target és vtarget).

4. ábra: Kódrészlet 4 (Forrás: Saját készítés)

```
normalizer = tf.keras.layers.Normalization(axis=-1)
normalizer.adapt(features)
```

Különösen fontos lépés a normalizáló réteg használata (**4. ábra**), ugyanis ez az, ami biztosítja, hogy a bemeneti adatok standardizált állapotban legyenek (ami tulajdonképpen a közös skála használatát jelenti), mivel a neurális háló sokkal hatékonyabban képes tanulni, hogyha az adatok hasonló skálán vannak. Az „axis=-1” részlet pedig azt jelenti, hogy a bemeneti adatok legutolsó tengelyén fog történni a normalizálás. A normalizálás során a kód tulajdonképpen a bemeneti adatokhoz alkalmazza a standardizálást. A második sorban pedig a modell megtanulja a bemeneti adatok statisztikáit, hogy ezeket a későbbi számítások során alkalmazni tudja.

5. ábra: Kódrészlet 5 (Forrás: Saját készítés)

```
def get_basic_model():
    model = tf.keras.Sequential([
        normalizer,
        tf.keras.layers.Dense(10, activation=tf.nn.relu),
        tf.keras.layers.Dense(10, activation=tf.nn.relu),
        tf.keras.layers.Dense(5, activation=tf.nn.relu),
        tf.keras.layers.Dense(3, activation=tf.nn.relu),
        tf.keras.layers.Dense(1, activation="sigmoid")
    ])
    model.compile(optimizer='adam',
                  loss=tf.keras.losses.BinaryCrossentropy(from_logits=True),
                  metrics=['accuracy'])
    return model
```

Ebben a kódrészletben (5. ábra) épül fel az a neurális háló modell, amit alkalmaztam a kísérletem során, ezen felül itt van lehetőség beállítani az alapvető paramétereket. A „tf.keras.Sequential” parancs hívja be az alkalmazott neurális háló modellt, ami jelen esetben egy egyszerűen rétegzett modell, míg a következő néhány sorban vannak definiálva a felhasznált paraméterek. A modell összesen öt rétegből áll ugyanis, ha ilyen kevés adatra túlságosan nagy neurális hálót építünk ki akkor előfordulhat, hogy a kapott adatokat teljesen betanulja és rosszul, pontatlanul fog reagálni számára ismeretlen adatokon. Ezt a jelenséget nevezzük úgy, hogy a modell túltanul. Az első kettő réteg tíz-tíz neuront használ és az aktivációs függvényük a ReLU (Rectified Linear Unit). A harmadik réteg már csak öt, illetve a negyedik réteg csak három neuronból épül fel és az aktivációs függvényük az előzőkéhez hasonlóan szintén a ReLU. A ReLU egy olyan aktivációs függvény, melyet a neurális hálózatok világában igen széles körben alkalmaznak. A függvény feladata, hogy meghatározza, hogy egy adott neuron milyen kimenetet ad az adott bemenet hatására. Tulajdonképpen úgy működik, hogy ha a bemeneti érték pozitív, akkor a kimenet ugyanaz lesz, de ha a bemeneti érték negatív, akkor a hozzá tartozó kimeneti érték nulla lesz. A ReLU függvény használata azért célszerű, mivel rendkívül egyszerű, gyakorlatilag egy műveletről van benne szó, ami rendkívül gyorsan számítható, így akár az általam felhasznált adatoknál jóval nagyobb adathalmaz esetén is kiválóan alkalmazható. Emellett segít a neurális hálónak bonyolultabb, nem-lineáris mintázatok betanulásában is. Természetesen, mint minden másnak, ennek a függvénynek is vannak hátrányai. Előfordulhat az, hogy ha egy neuron bemenete tartósan negatív, akkor az a neuron nem fog aktiválódni, így a kimeneti értéke folyamatosan nulla lesz. Ezt a jelenséget nevezi a szaknyelv „halott neuron” -nak. A végső réteg mindössze egy neuronból áll és egy bináris kimeneti értékhez vezet.

A következő néhány sor az optimalizálási algoritmust tartalmazza, amely kezdetben az SDG függvényt használta, amely ugyanakkora lépéseket alkalmazva próbálja meghatározni a függvény minimum pontját, de ez túl pontatlan volt és közel 60 %-os veszteséget eredményezett. Ennek folyományaképp lecseréltem a függvényt az Adam nevű társára, amely kezdetben nagy lépéseket alkalmazva, majd ezeket folyamatosan egy algoritmus alapján csökkentve keresi a minimum értéket. Az így kapott adatokat figyelve ellenőrizhetjük a modell pontosságát.

6. ábra: Kódrészlet 6 (Forrás: Saját készítés)

```
model = get_basic_model()
hist = model.fit(
    features, target,
    epochs=800,
    verbose=1,
    validation_data=(vfeatures, vtarget)
)
```

A fenti kódrészlet (6. ábra) tartalmazza a modell betanításának paramétereit. Látszik, hogy itt szabjuk meg, hogy a modell a bemeneti értékeket és az általunk kijelölt célváltozót használja fel, emellett itt szabjuk meg, hogy hány iteráción szeretnénk tanítani a kapott adatokból. Ez az érték az első kísérleteknél 1500 volt, de úgy tapasztaltam, hogy ez pontatlan végeredményt ad. Fontos figyelni, hogy a modell tanulása során a tanulási adatokra értelmezett veszteség folyamatosan csökkenjen, és a lehető legkisebb értékben álljon meg. Emellett én figyeltem a validációs halmazra értelmezett veszteséget is, ugyanis ez információt ad a modell tanulásának folyamatáról. Hogyha a validációs halmazhoz tartozó érték nem csökken tovább, vagy akár nőni kezd, az azt jelzi, hogy a modell már túltanul és ilyenkor le kell állítani a tanulási folyamatot. Éppen ezért a kiindulási magasabb értéket elkezdtem csökkenteni és úgy tapasztaltam, hogy a 800 alkalommal való futtatás volt a leghatékosabb, ugyanis értelemszerűen a minél magasabb érték megtartása a cél, de ennél magasabb érték esetén márt a túltanulási hiba jelentkezett.

7. ábra: Kódrészlet 7 (Forrás: Saját készítés)

```
print('Calibration performance:')
model.evaluate(features, target)
print('Validation performance:')
model.evaluate(vfeatures, vtarget)
```

A számítás végeztével a kód kiírja a kapott eredményeket mind a validációs adatsorra, mind pedig a tanító adatsorra (7. ábra). Erre a lépésre azért van szükség, hogy ellenőrizni tudjuk azt, hogy a modell milyen pontossággal dolgozott a kapott adatokon.

8. ábra: Kódrészlet 8 (Forrás: Saját készítés)

```
m = hist.history['accuracy'][-1]
if m > 0.9:
    converter = tf.lite.TFLiteConverter.from_keras_model(model)
    tflite_model = converter.convert()
    with open('model.tflite', 'wb') as f:
        f.write(tflite_model)
    pass
```


A kód legvége (8. ábra) pedig megvizsgálja, hogy a modell pontossága meghaladja-e a 90%-ot, és ha igen akkor lementi a modellt, majd átalakítja egy kisebb méretű és alacsonyabb számítási kapacitással bíró formátumba (TensorFlow Lite).

Miután a modell lementésre került, ami azt jelenti, hogy „betanult” az általunk kiválasztott adatokon, lefuttattam az összes táblázaton, melyek a korrelációkat figyelembevéve voltak felépítve, hogy meg tudjam határozni a küszöbértékeket.

4. Eredmények és értékelésük

Az eredményeim kiértékelését az időrendben egymást követő adatokból készült grafikonok vizsgálatával kezdtem. Az adatok sorrendiségét követve, az elemzés során a hőmérsékleti értékek voltak az elsők (9. ábra).

9. ábra: Hőmérséklet adatok a megfigyelt időszak alatt (51 nap) (Forrás: Saját készítés)



Az átlaghőmérsékletet vizsgáló grafikonon (9. ábra) jól láthatóan elkülöníthető egymástól a nyári és az őszi időszak. A kezdeti hőmérsékletesést követően a várakozásaimnak megfelelően a nyári időszakra egyértelműen megfigyelhető a növekvő tendencia, ami a szőlő épségét tekintve hátrányos jellemző. A szeptemberi napokban egy drasztikus hőmérsékletesést követően tartósan alacsonyabban maradt, sőt ezt követően el sem érte a 29,23 °C-os értéket, melyet a neurális háló meghatározott kockázati küszöbértéknek. A kísérlet adataival összevetve megállapítható, hogy 4 alkalommal átlépte a hőmérséklet ezt a küszöbértéket, és ebből 3 alkalommal tapasztaltak is napégést a megfigyelések során.


A kísérlet szempontjából fontos szerepet játszik még a maximális hőmérsékleti érték, ugyanis ez szintén nagy mértékben hozzájárul ahhoz, hogy egy termény megégjen. A maximális hőmérsékletet ábrázoló görbéről (**9. ábra**) azt olvashatjuk ki, hogy szinte teljes egészében a pontos mása a korábban bemutatott átlaghőmérsékletet vizsgáló ábrának, természetesen úgy, hogy a skála magasabb értékeit használja. Ez logikusnak tűnhet, de nem törvényszerű, mivel létezhetnek olyan szélsőséges hőmérsékleti ingadozások, amelyek matematikailag alacsonyabb átlaghőmérsékletet eredményeznek, de az óriási hőingadozás miatt ugyanakkor magas maximális hőmérsékletet mutatnak. Ez többnyire olyan helyeken fordul elő, ahol éjjelente nagyon drasztikusan vissza tud hűlni a levegő. A neurális háló számításai alapján a kritikus érték a maximális hőmérsékletet illetően $36,84\text{ }^{\circ}\text{C}$. Az átlaghőmérséklethez hasonlóan jelen esetben is 4 alkalommal lépte át a kritikus értéket a maximális hőmérséklet, melyek közül mind a 4 eset egy blokkba esett. A 4 esetből a neurális háló előrejelzései és a valós tapasztalatok 3 esetben fedték egymást. Abban az egy esetben amikor tévedett a modell, akkor éppen a küszöbértéket vette fel a hőmérséklet.

Az éghajlat változás tanulmányozása közben számos tényezőt kell figyelembe vennünk, de mind közül talán a leglátványosabb a hőmérséklet időbeli változása, azaz a hőingadozás. A gyakran erőforduló erős hőingadozások számos negatív hatást képesek kiváltani a termesztett és vadon élő növényekből egyaránt. A kísérlet során vizsgált napok alatt a kezdeti pár nap erősebb hőingadozást mutatott, ami a tizedik és a huszonharmadik nap között mérséklődni látszott, de később egy drasztikus hőmérsékletesést követően ismét sokkal jelentősebbé vált mind negatív, mind pozitív irányba (**9. ábra**). A modell a küszöbértéket jelen esetben $-5,89\text{ }^{\circ}\text{C}$ -ra a negatív és $4,01\text{ }^{\circ}\text{C}$ -ra pozitív irányba határozta meg. Különösen érdekes, hogy ebben az esetben alsó és felső értéket is meghatározott. Ez feltételezhetően amiatt alakult így mivel, ha a hőmérséklet a negatív irányba ingadozik, akkor az azt jelenti, hogy kevesebb ideig tartja a kritikushoz közeli hőmérsékletet a levegő, így a növénynek nem áll rendelkezésére megfelelő idő az alkalmazkodáshoz, így könnyebben jelentkezhet napégés mint olyan esetben amikor viszonylag állandó a hőmérséklet. Jelen esetben a negatív értékhatárt összesen egy alkalommal lépte át a hőmérséklet ingadozása, viszont ebben az esetben nem jelentkezett égéskár. A pozitív irányba való eltolódás alkalmával jelentkezett égés viszont azzal magyarázható, hogy a növények is csak bizonyos szintig képesek alkalmazkodni a környezeti változásokhoz, és ezen napok alkalmával feltehetően már meghaladta a hőmérséklet azt a szintet, amit a növény még károsodás nélkül elvisel. Ezeket a kritikusnak megszabott értékeket a hőingadozás összesen 2 alkalommal lépte át, melyből csak egy alkalommal jelentkezett égés. Ebből levonhatjuk azt a

következtetést, hogy bár nagyon fontos tényező az időjárási adatok vizsgálatakor a hőingadozás, jelen esetben nem ebben rejlett a fő kockázat.

Az, hogy esetünkben nem a hőingadozásban keresendő a probléma fő oka nem jelenti azt, hogy növénytermesztés kapcsán nem fontos paraméter, ugyanis a hirtelen hőmérsékletesés is tud károkat okozni például a fagyással, de mivel a kísérlet csak napégést vizsgálja, így csak az égéskárokkal tudta összevetni a neurális háló a mért adatokat és vélhetően ezért határozta meg a küszöbértékeket ilyen szélsőséges szintekre.

10. ábra: Napsugárzási adatok a megfigyelt időszak alatt (51 nap) (Forrás: Saját készítés)



A következő jellemző, amit a kísérlet vizsgált az átlagos napsugárzás volt (10. ábra). Bár a napsugárzás a növények életének egyik legfontosabb tényezője, mégis képes arra, hogy nagy károkat, vagy akár nekrózist is okozzon. A neurális háló modell az átlagos napsugárzásra vonatkozó küszöbértéket $279,188 \text{ W/m}^2$ -nél határozta meg. Fontos észrevennünk, hogy ez szintén a 46. adat az emelkedő táblázatban, akárcsak az átlag hőmérséklet, és maximális hőmérsékletek táblázatai alkalmával. Ezt okozhatja, hogy ahogyan korábban említettem a táblázatok úgy lettek kialakítva, hogy figyelembe veszik az adatok közti korrelációt. Ezt a megszabott küszöböt 5 alkalommal lépte át a mért napsugárzás, melyeket megvizsgálva azt tapasztaltuk, hogy mind az 5 alkalommal meg is égett a szőlő, ami azt jelenti, hogy ebben az

esetben a modell 100%-os pontosságot mutatott. Ugyanakkor fontos kiemelni, hogy a szülő nem csak ebben az 5 esetben égett meg, hanem ezeken kívül jelentkeztek még égéskárok egyéb napok alkalmával is, de ezekért feltehetőleg másik tényező volt felelős.

Az átlagos napsugárzás grafikonját (10. ábra) vizsgálva láthatjuk, hogy bár sokkal drasztikusabb mértékben ingadozva, de az esések és emelkedések közel ugyanakkor jelentkeztek, mint azt az átlaghőmérséklet grafikonján láttuk. Ez nem meglepő, mivel ezek az adatok kapcsolatban vannak egymással. Ugyanakkor érdekes, hogy a hőmérséklet esetében a kezdeti visszaesést követve emelkedő tendenciát láttunk, jelen esetben a szintén megfigyelhető kezdeti zuhanás után egy erősebb emelkedést látunk, viszont ebben az esetben az emelkedő tendenciát csökkenő helyettesíti.


A hőmérséklethez hasonlóan a sugárzás esetében is vizsgáltam a maximális sugárzási adatokat (10. ábra). Korábban azt láttuk, hogy az átlagos hőmérséklet és az átlagos sugárzás grafikonjai között valamilyen kapcsolat fedezhető fel. Egyértelműen kijelenthető, hogy a maximális hőmérséklet és a maximális sugárzás esetében ez már nem mondható el. Ez amiatt lehet, mivel a napsugárzást olyan érték, melyet olyan tényezők is befolyásolhatnak, mint például a felhőzet. Hogyha egy nap több felhő volt az égen akkor az nagy mennyiségben csökkenthette a sugárzás mért értékeit. Adódik a kérdés, hogy ez miért nem látszódik ilyen drasztikusan az átlagos sugárzási adatokon. Feltételezésem szerint azért, mert előfordulhat az, hogy a terület éppen felhős volt azokban az órákban amikor a sugárzás éppen a legerősebb volt, ami alacsonyabb maximális mért értékhez vezetett, de mivel az átlagot az egész napra vonatkoztatva számoljuk mégsem volt alacsony a végérték. Ugyanakkor jelen esetben is a 46. értéket jelezte küszöbértéknek a neurális háló éppen úgy, ahogyan az átlaghőmérsékelt, maximális hőmérséklet és átlagsugárzás esetén. A küszöbérték a maximális sugárzás esetén $964,25 \text{ W/m}^2$ -nél került kijelölésre a modell számításai alapján. Ezt az értéket 6 alkalommal lépték át az adatok, viszont ezesetben csak 2 alkalommal tapasztalhattunk égést. Ez lehet amiatt, mivel a maximális sugárzás csak egy pillanatnyi érték, és emiatt kevésbé lehet pontos következtetést levonni belőle, mint például az átlagos sugárzás adataiból. Ha a napsugárzás ingadozásának adatait vizsgáljuk akkor azt látjuk, hogy igen széles skálát járnak be a számok. Több alkalommal is láthatunk kiugró értékeket mind a negatív, mind pedig a pozitív irányba.

Érdekes, hogy bár talán azt várnánk, hogy a magasabb sugárzás jelenti a nagyobb kockázatot mégsem ezt mutatják a modell számításai, ugyanis a kritikus értéket $-56,5 \text{ W/m}^2$ -nél találta. Összesen 7 alkalommal estek a mért adatok a kritikus érték alá és ebből 5 alkalommal valóban tapasztaltunk is égéskárt. Ennek oka véleményem szerint ott keresendő, hogy ha nagy

mértékben ingadozik a sugárzás, akkor a növénynek nincs elég ideje arra, hogy kialakítsa a megfelelő mértékű toleranciát, így amikor egy erősebb dózist kap a sugárzásból akkor nagyobb valószínűséggel károsodik. Es mivel a sugárzás ingadozása (**10. ábra**) táblázat a két átlagérték közti eltérést tartalmazza, nem zárhatjuk ki azt, hogy a maximális sugárzás bizonyos ideig olyan magas volt, hogy képes legyen kárt okozni a növényben.

Ami a páratartalmat illeti, ebben az esetben nem a minimumtól a maximumig növeltem az adatokat, hanem a maximumtól csökkentettem a minimumig, mivel értelem szerűen nagyobb valószínűséggel fordul elő égéskár alacsonyabb páratartalom esetén.

11. ábra: Páratartalmi adatok a megfigyelt időszak alatt (51nap) (Forrás: Saját készítés)



Az adatokat figyelve észrevehetjük, hogy 3 különösen kiugró érték szerepel a diagrammon (**11. ábra**) a pozitív, viszont csak egy a negatív irányba. Ez a növénytermesztők szempontjából előnyös, mivel így az adatok alapján azt feltételezhetjük, hogy nem okozott számottevő problémát az alacsony páratartalom. A 47,99%-nál meghatározott, küszöbérték szintén ezt támasztja alá, mivel egyetlen alkalommal volt ennél az értéknél alacsonyabb a páratartalom, viszont ebben az esetben meg is égett a növény, ami azt igazolja, hogy a modell jól határozta meg az értéket. Fontos viszont, hogy egyetlen adatból nem érdemes messzemenő következtetést levonni, mivel bár valószínűtlen, de megtörténhet, hogy mindez pusztán csak a véletlen műve.

Az átlagos adatokon túl érdemes vizsgálni a páratartalom esetében is a maximális adatokat (**11. ábra**), ugyanis további értékes információ nyerhető ki belőlük.

Láthatjuk, hogy sokkal kisebb mértékben ingadozik a maximális adat, mint az átlagértékek ellenben a korábban vizsgált két tényező értékeivel. A jelen változóra meghatározott kritikus érték 76,21% volt. Két alkalommal csökkent le annyira a páratartalom, hogy ezen értéket ne érje el a maximális érték, és mindkét alkalommal jelentkezett is égéskár. Ez ismét 100%-os pontosságot jelent, de még mindig fennál előző kijelentésem, hogy bár valóban úgy látszik, hogy a páratartalom értékeivel lehet a legpontosabban előre jelezni az égéskár kockázatát, de két érték esetén sem jelenthetjük ki teljes magabiztossággal, hogy a modell minden esetben tökéletesen fog dolgozni.

5. Következtetések és javaslatok

A kísérlet eredményei alapján láthatjuk, hogy a növények (jelen esetben szőlő) napégése több tényező együttes értékeitől függ. Hiába magas a hőmérséklet, hogyha hozzá egy magas páratartalom és egy felhősebb időszak miatt alacsonyabb sugárzási szint társul, akkor nagy valószínűséggel nem fogunk égéskárt tapasztalni. Ugyanakkor hogyha alacsony a páratartalom és a Nap sugaraitól sem védi semmi a növényt akkor egy alacsonyabb hőmérsékleti érték mellett is jelentkezhet égés, ezért fontos, hogy a lehető legpontosabb előre jelzés érdekében az összes számottevő adatot folyamatosan megfigyeljük.

Az átlaghőmérséklet és a maximális hőmérséklet egyértelműen egy magas kockázatot hordoz magában, hogyha napégésről van szó, különösen egy olyan időszakban amikor ezek az értékek emelkedő tendenciát mutatnak és gyakran lépik át a küszöbértéket. Természetesen szerepet játszik a hőingadozás is, de a kísérlet eredményei alapján nem ez bizonyult a fő kockázati tényezőnek, illetve nem tudott olyan pontosan számolni vele a neurális háló, hogy ezen érték alapján lehessen előre tervezni bármilyen intézkedést.

Az átlagos és maximális sugárzás is szintén nagyon fontos szerepet játszottak a napégés előfordulásában. Az átlagos sugárzással kapcsolatos előrejelzések 100%-ában tapasztalhattunk égéskárt, ami azt mutatja, hogy meglehetősen pontos előrejelzéseket lehet tenni ezen adat figyelésével és tendenciájának nyomon követésével. A maximális sugárzással kapcsolatban ez már nem mondható el, ugyanis ebben az esetben csak 2 alkalommal tapasztaltak égést a 6 küszöbértéket meghaladó esetből, így a tapasztalatok alapján ez az érték nem alkalmas pontos

előrejelzésre, mivel a maximális sugárzás pillanatnyi értékei kevésbé megbízhatóak, mint az átlagos sugárzás adatai, mivel azok egész napra vonatkoztatott adatok.

A páratartalommal kapcsolatos eredményeket vizsgálva észrevehetjük, hogy rendkívül pontos eredményeket kaptunk. Mind az átlagos páratartalomra, mind a maximális páratartalomra meghatározott küszöbértékek átlépésekor a várakozásoknak megfelelően jelentkezett is napégés. Bár tényleg azt látjuk, hogy magas pontossággal dolgozott a modell ezen adatok vizsgálatakor, így ezen kísérleti eredmények alapján az a logikus következtetés, hogy a megfigyelések alatt a páratartalomra kell a legnagyobb hangsúlyt fektetni, ugyanakkor fontos kiemelni, hogy ez nagyon kevés adat. Ahhoz, hogy valóban pontos eredményhez jussunk és a gyakorlatban is használható legyen a modell ezen adatok sokszorosára lenne szükség a betanításához.

Vannak bizonyos visszatérő természeti elemek, amikkel jó közelítéssel lehet számolni és fel lehet rájuk készülni, például, hogy a nyári időszak beköszöntével emelkedő tendenciát fog mutatni a hőmérséklet (amit ezen kísérlet adatai is alátámasztanak) és ehhez többnyire erősebb napsugárzás fog tartozni, viszont a növénytermesztők értelemszerűen nem tudják előre az összes időjárási elemet megjósolni így ez a neurális háló hasznos lehet számukra. Ezt a rendszert használva lehetőség nyílik arra, hogy tendenciákat figyelve akár napokkal előre fel lehessen készülni a kockázatra. Ha időben értesülünk arról, hogy fokozódik a napégés valószínűsége akkor különféle intézkedésekkel, mint például árnyékolással, vagy nagyobb területek esetén a különféle speciális védőpermetek használatával minimalizálható a ténylegesen kialakuló kár mértéke.

Ahhoz, hogy ezt a modellt ténylegesen sikeresen lehessen integrálni egy mezőgazdaságba további tanító adatokra lenne szükség, ugyanis ahogy korábban is említettem ez a mennyiségű adat kevésnek bizonyult ahhoz, hogy valóban megbízhatóan tudjon előrejelzést adni. Ahhoz, hogy értelme is legyen használni egy ilyen rendszert, vele párhuzamosan érdemes megoldásokat kidolgozni az öntözés finomítására és a tápanyagellátást a lehető legjobb szintre hozni, hogy a növények a lehető legjobban fel legyenek vértézve a kihívást jelentő időjárással szemben. Az, hogy jelen kísérlet a napégést vizsgálta nem jelenti azt, hogy kizárólag erre használható a modell. Természetesen eredményesen alkalmazható lenne egyéb várt, vagy nem várt tényezők előrejelzésében, de ehhez értelemszerűen megfelelő információkat tartalmazó adattáblákra van szükség.

6. Összefoglalás

A klímaváltozás okozta egyre szélsőséesebb időjárási viszonyok miatt fokozatosan nagyobb hangsúlyt kell fektetnünk a precíziós növénytermesztésre, és minél több helyen kell alkalmaznunk a modern technológia által kínált lehetőségeket annak érdekében, hogy a nehezedő körülmények ellenére meg tudjunk felelni a minőségi és mennyiségi igényeknek egyaránt. Sőt, arra kell törekednünk, hogy a lehető legnagyobb kihozatazt érjük el úgy, hogy ehhez a lehető legmagasabb minőség párosul. Ezt az elmúlt 10 év kutatási eredményei nagy mértékben segítik. A számítástechnika fejlődésével létrejövő rendszerek és megoldások kiválóan alkalmazhatóak mezőgazdasági körülmények között is, mint például ezen dolgozat témáját képző neurális háló modellek felhasználása. A kísérlet eredményei igazolták, hogy valós környezetben is eredményesen alkalmazható egy gondosan betanított modell. Természetesen nem csak napégéssel kapcsolatos előrejelzésekre alkalmas egy neurális háló. Hogyha megfelelő mennyiségű adat áll rendelkezésünkre akkor könnyedén készíthetünk akár öntözés optimalizáló rendszert, vagy akár olyan modellt, ami javaslatot tesz arra, hogy mikor lenne ideális megkezdeni a vetést. Az viszont minden esetre általánosan kijelenthető, hogy a kulcs a neurális háló tanításában az, hogy megfelelően megválasztott, megfelelő méretű és valóban reprezentatív adatsort használjunk. A jelen kísérlet hiányossága az adatok mennyisége volt, de a kezdetben használt modell finomítása után még így is sikerült egyértelmű küszöbértékeket meghatározni. Bár az értékek egyesével kerültek meghatározásra, természetesen úgy érhető el a legpontosabb előrejelzés, hogy a modell által is felhasznált adatok változását együttesen figyeljük, de a tapasztalatok azt mutatták, hogy az összes adat közül a páratartalomra érdemes a legnagyobb hangsúlyt fektetni.

Jelen kísérletnek már létezik gyakorlati alkalmazása, a SHEET applikáció formájában. Az alkalmazás célja, hogy a neurális háló döntéshozatali modellje alapján segítségére legyen a növénytermesztőknek abban, hogy hatékonyan védekezhessenek az égéskárok ellen. Jelenlegi verzióját a bolognai (szakdolgozatom tárgyát képező ültetvény) és postdami kísérleti ültetvényeken fejlesztették ki, specifikusan a helyi körülményekre hangoltan. Ez nem jelenti azt, hogy más helyeken ne lehetne alkalmazni, csak használat előtt az adott régióból származó adatokon fel kell tanítani a modellt. Az applikáció továbbfejlesztése jelenleg közösségi alapú. A felhasználók feltölthetik saját adataikat, ezzel hozzájárulva a rendelkezésre álló adathalmaz bővítéséhez.

7. Köszönetnyilvánítás

Ezúton szeretnék köszönetet mondani mindazoknak, akik támogattak és segítettek szakdolgozatom elkészítése során. Külön köszönet illeti Dr. habil. Baranyai László konzulensemét, aki nem csak a kutatás szakmai irányításában, hanem a felhasznált kód elkészítésében és az adatok elemzésében is nagy segítséget nyújtott számomra.

Köszönöm továbbá Nagy Miklós kollégámnak, valamint Szenes Attila és Czeba Bálint barátaimnak, akik nagy türelemmel és szakértelemmel voltak segítségemre a kódom tökéletesítése során, ezzel jelentős mértékben hozzájárulva a munkám elkészítésének sikeréhez.

8. Felhasznált irodalmak jegyzéke

Bártfai Z., István B., Dezső F., Kar S. G., & Blahunka Z. (2018). Robotok a mezőgazdaságban.

Mezőgazdasági Technika, 2–7.

Bartholy J., & Pongrácz R. (2013). *Klímaváltozás*. Eötvös Loránd Tudományegyetem.

Berente, N., Gu, B., Recker, J., & Santhanam, R. (2021). MANAGING ARTIFICIAL INTELLIGENCE. *MIS Quarterly*, 45(3), 1433–1450.

Bihari P. (2019). Halmazódó ellentmondások. *Külgazdaság*, 63(7–8), 4–8.
<https://doi.org/10.47630/KULG.2019.63.7-8.4>

Boden, M. A. (1996). *Artificial Intelligence*. Elsevier.

Bottyán, Z. (2009). LÉGKÖRI ÜVEGHÁZHATÁS A KÖZETBOLYGÓKON. *Hadmérnök*, 15–23.

Csepeli G. (2020). *Ember 2.0—A mesterséges intelligencia gazdasági és társadalmi hatásai*. Kossuth Kiadó zrt.

Darbyshire, R., McClymont, L., & Goodwin, I. (2015). Sun damage risk of Royal Gala apple in fruit-growing districts in Australia. *New Zealand Journal of Crop and Horticultural Science*, 43(3), 222–232.

- Ertel, W. (2018). *Introduction to Artificial Intelligence*. Springer.
- Fazekas, I. (2013). *Neurális Hálózatok*. Debreceni Egyetem.
- Hampel G., Kiss K., Mikó E., & Monostori T. (2023). *Mezőgazdasági és vidékfejlesztési kutatások a jövő szolgálatában 4*. MTA SZAB Mezőgazdasági Szakbizottság.
- Imre K., Ferenczi Z., Dézsi V., & Gelencsér A. (2014). A baj nem jár egyedül – hőhullámok és levegőszennyezettség. *Iskolakultúra*, 24(11–12), Article 11–12.
- Kiss C. (2023). Világuralmi verseny az elsőbbségért a mesterséges intelligenciában. *Hadtudományi Szemle*, 16(2), 211–220. <https://doi.org/10.32563/hsz.2023.2.15>
- MacCracken, M., & Luther, F. (1985). *Detecting the climatic effects of increasing carbon dioxide* (DOE/ER-0235, 6264945; o. DOE/ER-0235, 6264945). <https://doi.org/10.2172/6264945>
- Mambetaliev, A., & De Bot, K. (2020). *Tavaszi Szél Tanulmánykötet 2019—III*.
- Morales-Quintana, L., Waite, J. M., Kalcsits, L., Torres, C. A., & Ramos, P. (2020). Sun injury on apple fruit: Physiological, biochemical and molecular advances, and future challenges. *Scientia Horticulturae*, 260, 108866. <https://doi.org/10.1016/j.scienta.2019.108866>
- Noriega, L. (2005). *Multilayer Perceptron Tutorial*. Staffordshire University.
- Popescu, M.-C., Balas, V. E., Perescu-Popescu, L., & Mastorakis, N. (2009). *Multilayer Perceptron and Neural Networks*. 8(7).
- Racskó J., Szabó Z., & Lakatos L. (2006). A napégés hatása az Idared almafajta gyümölcsminőségére. *Agrártudományi Közlemények*, 19.
- Racskó, J., Thurzó, S., & Drén, G. (2005). Effect of M9, MM106 and Seedling Rootstocks on Sunburn-Sensitivity of 33 Apple Cultivars, and Sunburn Effects on Fruit Quality. *Acta Agraria Debreceniensis*, 16, Article 16. <https://doi.org/10.34101/actaagrar/16/3316>

9. Ábrajegyzék

1. ábra: Kódrészlet 1 (Forrás: Saját készítés)	13
2. ábra: Kódrészlet 2 (Forrás: Saját készítés)	13
3. ábra: Kódrészlet 3 (Forrás: Saját készítés)	13
4. ábra: Kódrészlet 4 (Forrás: Saját készítés)	14
5. ábra: Kódrészlet 5 (Forrás: Saját készítés)	14
6. ábra: Kódrészlet 6 (Forrás: Saját készítés)	16
7. ábra: Kódrészlet 7 (Forrás: Saját készítés)	16
8. ábra: Kódrészlet 8 (Forrás: Saját készítés)	17
9. ábra: Hőmérséklet adatok a megfigyelt időszak alatt (51 nap) (Forrás: Saját készítés).....	18
10. ábra: Napsugárzási adatok a megfigyelt időszak alatt (51 nap) (Forrás: Saját készítés)...	20
11. ábra: Páratartalmi adatok a megfigyelt időszak alatt (51nap) (Forrás: Saját készítés).....	22

10. Táblázatjegyzék

1. táblázat: Feldolgozott adatok (Forrás: Saját készítés, kapott adatok alapján)	11
2. táblázat: Korrelációs táblázat (Forrás: Saját készítés, kapott adatok alapján).....	12

NYILATKOZAT

a szakdolgozat nyilvános hozzáféréséről és eredetiségéről

A hallgató neve: Danyi Bence Csaba
A Hallgató Neptun kódja: GLNHAX
A dolgozat címe: Mesterséges intelligencia alkalmazása precíziós
termesztés támogatására
A megjelenés éve: 2024
A konzulens intézetének neve: Élelmiszertudományi és Technológiai Intézet
A konzulens tanszékének a neve: Élelmiszeripari Méréstechnika és Automatizálás

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

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


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

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

Tudomásul veszem, hogy dolgozatom elektronikus változata feltöltésre kerül a Magyar Agrár- és Élettudományi Egyetem MATER Hallgatói Dolgozatok repozitóriumába. Tudomásul veszem, hogy a megvédett és

- nem titkosított dolgozat a védést követően
- titkosításra engedélyezett dolgozat a benyújtásától számított 5 év eltelte után nyilvánosan elérhető és kereshető lesz az Egyetem MATER Hallgatói Dolgozatok repozitóriumában.

Kelt: Budapest, 2024 év október hó 29 nap


Hallgató aláírása


NYILATKOZAT

Danyi Bence Csaba (hallgató Neptun azonosítója: GLNHAX) konzulenseként nyilatkozom arról, hogy a szakdolgozatot áttekintettem, a hallgatót az irodalmi források korrekt kezelésének követelményeiről, jogi és etikai szabályairól tájékoztattam.

A záródolgozatot/szakdolgozatot/diplomadolgozatot/portfóliót a záróvizsgán történő védésre javaslom / nem javaslom¹.

A dolgozat állam- vagy szolgálati titkot tartalmaz: igen nem^{*2}

Kelt: Budapest, 2024 év október hó 29 nap


belső konzulens

¹ A megfelelő aláhúzendó.

² A megfelelő aláhúzendó.