

DEBRECENI EGYETEM
KERPELY KÁLMÁN DOKTORI ISKOLA

Doktori Iskola vezető:

Prof. Dr. Holb Imre

egyetemi tanár, az MTA doktora

Témavezető:

Dr. Rátonyi Tamás

egyetemi docens

KUKORICA EGYES BELTARTALMI PARAMÉTEREINEK
ÉRTÉKELÉSE HAGYOMÁNYOS ÉS GÉPI TANULÁSON ALAPULÓ
MÓDSZEREKKEL

Készítette:

Fejér Péter István

doktorjelölt

DEBRECEN

2025

Tartalomjegyzék

1. BEVEZETÉS	4
2. SZAKIRODALMI ÁTTEKINTÉS	10
2.1. A kukorica eredete, jellemzői és jelentősége	10
2.2. A kukorica keményítőtartalma	14
2.3. A különböző műtrágyakezelések hatása a kukorica keményítőtartalmára	16
2.4. A különböző talajművelési rendszerek hatása a kukorica keményítőtartalmára	19
2.5. Az éghajlati változók hatása és az évjáráthatás szerepe a kukorica keményítőtartalmára vonatkozóan	21
2.6. Gépi tanulás és mesterséges neurális hálózatok (ANN) alkalmazása a különböző mezőgazdasági paraméterek becsléséhez	23
2.6.1. Mesterséges neurális hálózatok (ANN)	23
2.6.2. Gépi tanulási módszerek alkalmazása a mezőgazdaságban és a környezetvédelemben	28
2.6.3. Az MLP modell	31
2.6.4. Az RBF modell	32
3. ANYAG ÉS MÓDSZER	34
3.1. Vizsgálati terület és kísérleti elrendezés	34
3.2. Meteorológiai adatok	36
3.3. A kukoricaminták elemzése	38
3.4. Statisztikai elemzés	39
3.4.1. Leíró statisztikai elemzés, korrelációelemzés és többváltozós statisztikai vizsgálatok	39
3.4.2. Varianciaanalízis (ANOVA) és legkisebb szignifikáns különbség (LSD) vizsgálatok	39
3.5. A keményítőhozam előrejelzése ANN-algoritmusok alapján	40
3.5.1. Elemzési célok és módszerek	40
3.5.2. Forgatókönyvek és modellezés	40
3.5.3. A gépi tanulás révén végzett elemzéshez felhasznált scenáriók összetételének bemutatása	41
3.5.4. A gépi tanulási modellek teljesítményének statisztikai értékelése	46
4. EREDMÉNYEK	48
4.1. A felhasznált adatbázis tulajdonságainak áttekintése	48
4.1.1. A bevont változók leíró statisztikai elemzése a 2017-es évre vonatkozóan	48

4.1.2. A bevont változók leíró statisztikai elemzése a 2018-as évre vonatkozóan	51
4.1.3. A bevont változók leíró statisztikai elemzése a 2019-es évre vonatkozóan	54
4.2. Különböző agrotechnikai tényezők, illetve az évjárat hatása a keményítőtartalomra és a keményítőhozamra	57
4.2.1. A különböző tápanyagkezelések hatása a keményítőtartalomra	57
4.2.2. Az évjárat hatása a keményítőtartalomra	58
4.2.3. A különböző talajművelési módok és az évjárat együttes hatása a keményítőtartalomra	59
4.2.4. A tápanyagkezelések és az évjárat együttes hatása a keményítőtartalomra	61
4.2.5. A talajművelés és a tápanyagkezelések hatása a keményítőhozamra	62
4.2.6. A talajművelési módok és az évjárat együttes hatása a keményítőhozamra	63
4.2.7. A tápanyagkezelések és az évjárat együttes hatása a keményítőhozamra	65
4.3. Főkomponens-elemzés (PCA) különböző bemeneti adatok alapján	66
4.4. A kukorica keményítőtartalmát befolyásoló változók összehasonlító elemzése a hároméves kísérleti időszakban (2017-2019)	69
4.5. A keményítőtartalom előrejelzésének mesterséges neurális hálózatokkal (ANN) történő értékelése	71
4.5.1. Az ANN-MLP modell eredményeinek bemutatása	72
4.5.2. Az ANN-RBF modell eredményeinek bemutatása	84
4.5.3. Az MLP és RBF ANN algoritmusok teljesítménye a keményítőtartalom előrejelzésében	97
5. KÖVETKEZTETÉSEK, JAVASLATOK	104
6. ÚJ TUDOMÁNYOS EREDMÉNYEK	107
7. GYAKORLATBAN ALKALMAZHATÓ EREDMÉNYEK	109
8. ÖSSZEFOGLALÁS (magyar nyelven)	110
9. ÖSSZEFOGLALÁS (angol nyelven)	112
10. RÖVIDÍTÉSEK JEGYZÉKE	114
11. FELHASZNÁLT IRODALOM	115
12. PUBLIKÁCIÓK AZ ÉRTEKEZÉS TÉMAKÖRÉBEN	132
13. KÖSZÖNETNYILVÁNÍTÁS	136
14. NYILATKOZATOK	137

1. BEVEZETÉS

Az elmúlt évtizedekben az élelmezésbiztonság az emberiség egyik legsürgetőbb problémájaként jelent meg, amelynek megoldását a mezőgazdasági termelés mennyiségének és minőségének növelése jelenti. A globális élelmezés nehézségeinek egyik fő oka, hogy a világ népessége jelentős mértékben növekszik, és a jelenlegi előrejelzések szerint ez a tendencia tovább folytatódik. Becslések alapján a globális népesség 2050-re eléri a 9 milliárd főt (Roberts, 2011; Mohammed et al., 2021a), illetve 2100-ra várhatóan 9,6 és 12,3 milliárd fő között alakul majd (Gerland et al., 2014). A népesség folyamatos növekedése, valamint a mezőgazdasági termékek és a természeti erőforrások iránti fokozódó kereslet egyre nagyobb terhet ró a környezetre és folyamatos nyomást gyakorol az agrárszektorra. Ennek megfelelően a mezőgazdaság fejlesztése kulcsfontosságú az élelmezési kihívások kezelésében (Ramasamy és Moorthy, 2006). A mezőgazdasági termelést érintő számos akadály közé tartozik az éghajlatváltozás (Juhász et al., 2020), az üvegházhatású gázok kibocsátása (Harsányi et al., 2021a; Mohammed et al., 2021b), az aszály (Mohammed et al., 2022a, 2022b, Harsányi et al., 2021b), a talajdegradáció (Takács et al., 2021; Khallouf et al., 2021; Hateffard et al., 2021), valamint a talaj szikeseződése és szennyeződése (Mohammed et al., 2021a). Az éghajlatváltozás negatív hatásai kedvezőtlen időjárási viszonyokat idézhetnek elő, amelyek akadályozzák a mezőgazdasági termelést és veszélyeztetik az élelmiszerellátást (Elbeltagi et al., 2020).

A mezőgazdaság kulcsszerepet játszik az emberi társadalom fenntarthatóságában és fejlődésében. Az agrárágazat nem csupán a növénytermesztést foglalja magában, hanem jelentős mértékben hozzájárul a globális élelmiszerellátáshoz is (Lynch et al., 2021). A szántóföldi növénytermesztés a mezőgazdasági termelés egyik legfontosabb ágazata, amely alapvető szerepet tölt be a világ élelmiszer-előállításában (Ragán et al., 2024), a növekvő népesség élelmezési igényeinek kielégítésében (Gerland et al., 2014). A világ népességének növekedésével párhuzamosan az élelmiszerek iránti kereslet is folyamatosan emelkedik, ami még fontosabbá teszi a mezőgazdasági termelékenység fenntartását és növelését (Raza et al., 2021). Ezért kiemelten fontos a fenntartható mezőgazdasági gyakorlatok alkalmazása, amelyek hozzájárulnak a termés hozamok növeléséhez és a környezet védelméhez (Mohammed et al., 2022a). Ennek részeként elengedhetetlen az új technológiák, a precíziós mezőgazdaság alkalmazása, valamint a fenntartható gazdálkodási módszerek bevezetése.

Ebben a kontextusban a kukorica stratégiai jelentőségű növénynek számít az emberi táplálkozásban (Tanumihardjo et al., 2019). A kukorica az egyik legszélesebb körben termesztett és fogyasztott gabonaféle a világon, különösen a fejlődő országokban, ahol alapvető élelmiszerforrásként szolgál. Magas termőképessége és kedvező hektáronkénti hozamai miatt a kukorica jelentős szerepet játszik a növekvő népesség ételmezésében. A kukoricát nemcsak élelmiszerként használják fel (például liszt, kukoricaliszt, pattogatott kukorica formájában), hanem fontos alapanyag az ipar számára is, például bioüzemanyagok és állati takarmányok gyártásában. Rouf Shah et al., (2016) megerősíti, hogy a kukorica szemtermése jelentős mennyiségű szénhidrátot tartalmaz, elsősorban keményítőt, amely az egyik legfontosabb energiaforrás az emberi táplálkozásban.

A kukorica terméshozamát és keményítőtartalmát számos mezőgazdasági tényező befolyásolja, többek között a termesztés típusa, az öntözés és a trágyázás. A művelési típus a talajművelés során alkalmazott módszereket és gyakorlatokat jelenti, amely magában foglalja mind a hagyományos, mind az innovatív módszereket. A modern termesztési technológiák, például a kiváló minőségű hibridek alkalmazása, a gépesítés és a kártevők elleni védekezés jelentősen növelhetik a kukorica terméshozamát és minőségét (Nagy, 2010).

A műtrágyázás és az öntözés hatása egyértelműen meghatározó tényezőként jelenik meg. Széles et al. (2023b) kísérletei során bebizonyosodott, hogy bár a fejtrágyázás a V6 és V12 fenofázisokban aszályos körülmények között nem növelte szignifikánsan a terméshozamot, a 120 kg N ha⁻¹ alaptrágyázás optimálisnak bizonyult, mivel stabilizálta a növények klorofilltartalmát és a levélfelületi indexet, ezáltal mérsékelte a hozamcsökkenést. Széles et al. (2024) öntözött és öntözetlen parcellák összehasonlításával mutatta ki, hogy az öntözés átlagosan 37,2%-kal növelte a terméshozamot, míg a 120 kg N ha⁻¹ dózis alkalmazása az öntözött kezelésekben elérte a 11,863 t ha⁻¹ hozamot. Az eredmények rávilágítanak arra, hogy az öntözés és a megfelelő N-trágyaszintek szinergikus hatást gyakorolnak: öntözés nélkül a többlettrágyázás hatása korlátozott, míg vízpótlással kombinálva a hozamnövelő potenciál teljes mértékben érvényesül.

A kukorica hozamát jelentősen befolyásolja a nitrogén (N), foszfor (P) és kálium (K) műtrágyák alkalmazása, különösen a nitrogén szerepe meghatározó. Illés et al. (2020) kimutatták, hogy a magasabb nitrogénszintek pozitív összefüggést mutatnak a

szemterméssel, és bizonyos hibridek kedvezően reagálnak a nitrogénkezelésekre magyarországi körülmények között. Ezt erősítik meg Bojtor et al. (2021) eredményei is, amelyek rámutattak, hogy a különböző hibridek eltérően reagálnak a változó N-szintekre, ugyanakkor az optimális hozamok jellemzően magasabb, célzott N-dózisok mellett érhetőek el. Ugyancsak hangsúlyozták, hogy a nitrogén kijuttatásának időzítése és módja jelentősen fokozhatja a felvétel hatékonyságát, amely kulcsfontosságú a produktivitás maximalizálásában. Szabó et al. (2022a) vizsgálatai szerint a 100 kg/ha nitrogén kijuttatása szignifikánsan növeli az átlaghozamot, továbbá a korai vetési időpont és a megfelelő N-ellátás kombinációja kedvezőbb tápanyag-felvételt és hozampotenciált biztosít. A különböző műtrágyaszintek és hibridek kölcsönhatása összetett kapcsolatot tár fel, amelyben bizonyos genotípusok kiemelkedően jól reagálnak meghatározott NPK-kombinációkra. Mousavi et al. (2019) kimutatták, hogy a hibridek eltérő mértékben reagálnak a különböző tápanyagellátási kezelésekre.

Az új technológiák, például a nagy mennyiségű adatok (big data) elemzése, a mesterséges neurális hálózatok (artificial neural networks - ANN) és a gépi tanulás forradalmasítják a mezőgazdasági szektort, és jelentős mértékben javíthatják a kukoricatermelés hatékonyságát. Ezek az adatalapú módszerek pontos és fenntartható megoldásokat kínálnak a mezőgazdaságban felmerülő kihívásokra (Raj et al., 2021). A digitális adatgyűjtési és -elemzési módszerek fejlődése lehetővé tette, hogy a mezőgazdasági rendszerek komplexitását korszerű, adatvezérelt megközelítéssel értelmezzük. A big data elemzés – a nagy tér- és időbeli felbontású adatok, valamint gépi tanulási algoritmusok alkalmazásán keresztül – jelentős lehetőségeket kínál a precíziós mezőgazdaságban. E módszerek támogatják a prediktív modellek fejlesztését, a hozamoptimalizálást és a fenntartható döntéstámogatást, amelyek az agronómiai rendszerek hatékonyabb megértéséhez vezethetnek (Kamilaris et al., 2017). Különösen fontos szerepet kapnak ebben a távérzékelésből származó nagy adatállományok, amelyek strukturált feldolgozása és integrálása alapfeltétele a korszerű precíziós növénytermesztésnek (Huang et al., 2018).

Az ANN-ok a gépi tanulási algoritmusok egyik típusát képviselik, amelyek az emberi agy működését és szerkezetét utánozzák az adatok feldolgozása és értelmezése során. Ez lehetővé

teszi, hogy a neurális hálózatok a múltbeli adatok alapján előrejelzéseket készítsenek és összetett mintázatokat azonosítsanak.

Az utóbbi években a mesterséges neurális hálózatok (ANN) alkalmazása egyre szélesebb körben jelenik meg a mezőgazdasági kutatásokban, különösen a kukoricatermesztés hozamának és minőségi paramétereinek előrejelzésében. A modellek képesek a különböző környezeti, talajtani és éghajlati tényezők közötti bonyolult összefüggések feltárására, amelyeket a hagyományos statisztikai módszerek gyakran nem tudnak megfelelően kezelni. Nyéki et al. (2021) például kimutatta, hogy a tér- és időbeli adatok integrálásával a gépi tanulási modellek pontosabb helyspecifikus előrejelzéseket adhatnak, ezáltal támogatva a precíziós gazdálkodás döntéseit. Hasonlóképpen, más kutatások is igazolták, hogy a gépi tanulási algoritmusok – így az ANN mellett a random forest vagy más ensemble modellek – hatékonyan alkalmazhatók a klimatikus tényezők előrejelzésére és a termést veszélyeztető aszálymonitorozásban (Mohammed et al., 2024a). A vízgazdálkodás területén pedig az ANN-alapú modellek sikerrel alkalmazhatók az öntözéshez felhasznált víz minőségének előrejelzésére is, például a nátrium-adszorpciós arány (SAR) meghatározásával, amely közvetlenül hat a talaj vízvezető képességére és így a növények termőképességére (Mohammed et al., 2024b). Ezek a vizsgálatok együttesen rávilágítanak arra, hogy az ANN-ok és más gépi tanulási módszerek alkalmazása jelentős potenciált hordoz a kukoricatermesztés hatékonyságának és fenntarthatóságának növelésében.

A kukoricatermesztés esetében az ANN-ok képesek több különböző paramétert elemezni és ezek alapján előre jelezni a terméshozamot (Adisa et al., 2019) és a keményítőtartalmat (Rodrigues et al, 2024).

A kukoricatermesztéssel kapcsolatos ANN-modellek számos tényezőt képesek figyelembe venni:

- az állományra vonatkozó mért adatok (beltartalmi adatok, hozam, hl-tömeg)
- évjárathatás (hőmérséklet, csapadékmennyiség).
- agronómiai tényezők (tőszám, öntözés talajművelési típus, tápanyagellátás).

Az ANN-modellek képesek olyan összefüggéseket és mintázatokat is feltárni, amelyek nem feltétlenül tűnnének fel hagyományos elemzési módszerekkel. Ez lehetővé teszi, hogy a

modell pontos és megbízható előrejelzéseket készítsen a kukorica terméshozamáról és minőségéről (Harsányi et al., 2023).

Ezek az előrejelzések felhasználhatók a mezőgazdasági gyakorlatok optimalizálására egy adott régió vagy gazdaság körülményeinek figyelembevételével. Az ANN-modellek lehetőséget kínálnak arra, hogy a gazdálkodók adatvezérelt döntéseket hozzanak a vetési időpontokról, a művelési módszerekről, valamint az öntözési és trágyázási stratégiákról, ezáltal növelve a kukoricatermesztés hatékonyságát és fenntarthatóságát.

Mindazonáltal az ANN-előrejelzések pontossága és megbízhatósága nagymértékben függ a modell betanításához felhasznált adatok minőségétől, összetételétől és méretétől. Ezért a kukoricatermesztésben az ANN-modellek előnyeinek maximalizálásához elengedhetetlen a részletes, pontos és helyspecifikus adatgyűjtés (Harsányi et al., 2022). A megbízható adatok birtokában az ANN-modellek hatékony eszközként szolgálhatnak a kukoricatermesztés eredményességének és fenntarthatóságának javításában.

Magyarországon az ANN-ok (mesterséges neurális hálózatok) alkalmazása a mezőgazdaságban még viszonylag új kutatási területnek számít, és egyelőre csak korlátozott mértékben használják a kukorica termesztésének vizsgálatában. Számos hazai tanulmány rámutat arra, hogy Magyarországon a kukorica terméshozamát és minőségét leginkább olyan mezőgazdasági tényezők befolyásolják, mint a termesztési mód, az öntözés és a műtrágyázás (Harsányi et al., 2023). Ezért kiemelten fontos megvizsgálni, hogy milyen lehetőségek és kihívások kapcsolódnak az ANN-ok használatához a kukorica terméshozamának és keményítőtartalmának előrejelzésében, különös tekintettel a fent említett agronómiai tényezőkre. Az ANN-ok képesek lehetnek arra, hogy ezeknek a komplex összefüggéseknek az elemzésével pontosabb előrejelzéseket adjanak, és ezzel támogassák a kukoricatermesztés hatékonyságának és fenntarthatóságának javítását. A fenti szempontokat figyelembe véve, kutatásom során az alábbi célokat tűztem ki:

- a) Különböző műtrágyakezelések ($N\ 0\ kg\ ha^{-1}$, $P_2O_5\ 0\ kg\ ha^{-1}$, $K_2O\ 0\ kg\ ha^{-1}$, (kontroll); $N\ 80\ kg\ ha^{-1}$, $P_2O_5\ 60\ kg\ ha^{-1}$, $K_2O\ 90\ kg\ ha^{-1}$, és $N\ 160\ kg\ ha^{-1}$, $P_2O_5\ 60\ kg\ ha^{-1}$, $K_2O\ 90\ kg\ ha^{-1}$) hatásának elemzése a kukorica keményítőtartalmára.

- b) Három talajművelési rendszer (őszi szántás (27 cm), sávos talajművelés (23 cm), lazítás (45 cm) hatásának elemzése a kukorica keményítőtartalmára.
- c) Az évjárat (2017-2019) meteorológiai eltéréseinek elemzése a kukorica keményítőtartalmára vonatkozóan.
- d) A fenti tényezők kumulatív hatásának elemzése a kukorica keményítőtartalmára vonatkozóan.
- e) A mesterséges neurális hálózatok (ANN) (többrétegű perceptron (multilayer perceptron - MLP) és a radiális bázisfüggvény (radial base function - RBF) alkalmasságának elemzése a kukorica keményítőtartalmának előrejelzésére vonatkozóan.
- f) Az eltérő bemeneti változók bevonásával létrehozott forgatókönyvek hatékonyságának értékelése a kimeneti eredmények előrejelzésére vonatkozóan.
- g) Annak a feltételezésnek a bizonyítása vagy cáfolata, hogy az ANN-MLP gépi tanulási modell jobb predikciós hatékonysággal bír a mezőgazdaságra jellemző adatok esetében, mint az ANN-RBF modell
- h) Annak a feltételezésnek a bizonyítása vagy cáfolata, hogy a gépi tanulási modellek hatékonyabban működnek a bemeneti változók számának növelése esetén

2. SZAKIRODALMI ÁTTEKINTÉS

2.1. A kukorica eredete, jellemzői és jelentősége

A kukorica (*Zea mays L.*) eredete Közép-Amerikába, azon belül is Mexikó déli részére vezethető vissza, ahol mintegy 9 000 évvel ezelőtt kezdték el házasítani ősi vad változatából, a teosinte nevű növényből. A genetikai és régészeti bizonyítékok alapján a teosinte-től való domesztikáció során a kukorica jelentős morfológiai változásokon ment keresztül, amelyek a ma ismert nagyobb szemméretet és kompaktabb csövet eredményezték. E hosszú evolúciós folyamat eredményeként alakult ki a mai értelemben vett kukorica, amely nem csupán alapvető élelmiszerforrássá vált, hanem jelentős társadalmi és ökológiai változásokat is előidézett. A kukorica elérhetősége és tápértéke lehetővé tette az első, mezőgazdaságon alapuló települések kialakulását, hozzájárulva a helyhez kötött életmód és a komplex civilizációk megszületéséhez. (Smith, 2001). A mezőgazdasági fejlődés és a növénytermesztési technikák finomodásával a kukorica gyorsan elterjedt Amerika más régióiban, majd később az európai felfedezéseket követően globálisan is alapvető élelmiszernövényé vált (Matsuoka et al., 2002).

A gabonafélék az emberiség számára minden más élelmiszertípusnál több táplálékot és a teljes kalóriaszükséglet közel felét biztosítják. A búza, a kukorica és a rizs fontos emberi táplálékforrás, amelyek az összes gabonafogyasztás 91%-át teszik ki (FAOSTAT, 2024). E gabonafélék fogyasztása régióként igen eltérő, Dél- és Kelet-Afrikában, Közép-Amerikában és Mexikóban a kukoricát részesítik előnyben. A kukorica feldolgozása és fogyasztása országonként változik; például Dél-Afrikában a "pap" nevű kukoricakása különböző formáit fogyasztják (Rebe et al., 2024).

A kukorica jelentős szerepet játszik a globális élelmezésben. A kukoricaszem körülbelül 72% keményítőt, 10% fehérjét és 4% olajat tartalmaz, így 100 grammonként hozzávetőlegesen 365 kilokalória energiát biztosít, ami hasonló a búza és a rizs energiatartalmához (Yu et al., 2022). Bár a kukorica értékes forrása több B-vitaminnak, rostnak és néhány esszenciális ásványi anyagnak, hiányzik belőle a B12- és C-vitamin, valamint általában alacsony a kalcium-, folsav- és vastartalma (Nuss és Tanumihardjo 2010). A keményítőtartalom szerkezete is kulcsfontosságú, mivel a szemekben található keményítő túlnyomó részét az

amilopektin adja, amely jelentős hatással van a kukorica feldolgozhatóságára és végtermékének minőségére (Fox és O'Hare, 2017).

A kukorica fontosságát a globális élelmezésbiztonság szempontjából számos tanulmány hangsúlyozza. Hosszú távú kísérletek igazolták, hogy a kelet-európai régióban a terméssbiztonság és a stabilitás szempontjából meghatározó szerepet tölt be, hiszen az agrártermelés egyik alapvető gabonaféléje (Nagy et al., 2022). Világszinten a kukorica az egyik legnagyobb területen termesztett növény, amely nemcsak az élelmiszer- és takarmányláncban, hanem az ipari feldolgozásban is kulcsfontosságú alapanyag (Bojtor et al., 2022). Jelentőségét tovább növeli, hogy termesztése érzékenyen reagál az éghajlati szélsőségekre, különösen Közép-Európában, ami felértékeli az adaptációs technológiák és a klímareziliens termesztési megoldások szerepét (Széles et al., 2023a). A kukorica beltartalmi értékei, elsősorban a keményítő- és fehérjetartalom, szintén kiemelik sokoldalú hasznosíthatóságát: a növény nemcsak állati takarmányként és ipari alapanyagként jelentős, hanem az emberi táplálkozásban is egyre fontosabb szerepet tölt be (Nyandi et al., 2025).

A kukorica mára a világ egyik legfontosabb gabonaféléjévé vált, kiterjedt agrárgazdasági szerepe pedig világszinten is meghatározó. Az AKI legutóbbi átfogó agrárpiaei jelentése a gabona és ipari növényekre vonatkozóan összefoglalja, hogy a Nemzetközi Gabonatanács (International Grains Council, IGC) 2024 márciusában közzétett előrejelzése szerint a globális kukoricatermés a 2025/2026-os gazdasági évben elérheti az 1269 millió tonnát, amely az előző évhez képest 4%-os növekedést jelent. A világpiaci felhasználás ennek megfelelően szintén bővül, a becsült 1263 millió tonnás volumen körülbelül 25 millió tonnával haladja meg az előző gazdasági év értékét. Az előrejelzések alapján a szezon végére 280 millió tonna kukorica maradhat raktárkészleten, ami 2%-os készletnövekedést jelent az előző évhez képest (AKI, 2025).

Az AKI jelentése arra is kitér, hogy az Európai Unió vonatkozásában a Tallage piacelemző cég előrejelzése szerint a 2025/2026-os évben a kukorica vetésterülete 8,15 millió hektárra csökkenhet, amely a 2024-es szinthez viszonyítva 6%-os visszaesést jelent. A nagyobb termelő tagországok közül Franciaországban és Romániában várhatóan egyaránt 12%-kal csökken a vetésterület – előbbiben 1,4 millió hektárra, utóbbiban 2 millió hektárra. Lengyelországban ezzel szemben a becslések 1,24 millió hektár körüli vetésterülettel

számolnak. Magyarország esetében a Tallage szakértői 810 ezer hektár kukoricával bevetett területet valószínűsítene a 2025/2026-os szezonban (AKI, 2025).

A FAO 2024-es World Food and Agriculture című statisztikai évkönyve alapján a globális kukoricatermelés az elmúlt évtizedekben jelentős növekedést mutatott, és 2022-ben elérte az 1,2 milliárd tonnát, ami a világ elsődleges növénytermesztésének 12 százalékát tette ki. Ezzel a kukorica a második legnagyobb mennyiségben termesztett szántóföldi növényé vált, közvetlenül a cukornád után. A világ kukoricatermelésének mintegy 60 százalékát a három legnagyobb termelő ország – az Egyesült Államok (30%), Kína és Brazília – adja, míg a globális termelés felét az amerikai kontinens biztosítja.

Az Európai Unión belül a kukoricatermesztés fontos, de kisebb részt képvisel a globális volumenhez képest: 2022-ben az EU összesen 282,7 millió tonna kukoricát termelt, amelyből Magyarország 4,35 millió tonnával részesedett. Ezzel hazánk a középmezőnyhöz tartozik, termőterülete és kibocsátása alapján megelőzi például Csehországot és Horvátországot, de elmarad Franciaország, Románia vagy Lengyelország mögött.

Magyarország mezőgazdasági struktúrájában a kukorica ugyancsak kiemelt helyet foglal el, bár a termőterület enyhe visszaesést mutatott az elmúlt években. A 2024. június 1-jei statisztikai állapot szerint a hazai vetésterület 907 ezer hektár volt, amely a 2022-es aszályos év után még mindig alacsonyabb érték, de az alkalmazkodó agrotechnológiai gyakorlatok révén stabilizálódni látszik (KSH, 2024).

A kukoricatermelés növekedéséhez számos tényező járult hozzá: a technológiai innovációk, például a magas hozamú fajták és a fejlettebb termesztéstechnológiák alkalmazása, a műtrágyahasználat növekedése, valamint az öntözés és a növényvédő szerek használatának bővülése. Ezek a fejlesztések lehetővé tették a terméshozamok javulását, és hozzájárultak a globális kukoricatermelés fenntartható bővüléséhez (FAO, 2024).

A kukoricatermesztést az éghajlati viszonyok, például az aszályok és árvizek is befolyásolják, amelyek hatással lehetnek a termés hozamára és minőségére. Például 2012-2013-ban a globális kukoricatermelés 6 százalékkal csökkent az Egyesült Államokban és Kelet-Európában tapasztalt súlyos aszályok miatt (Erenstein et al., 2022).

A Shiferaw és munkatársai (2011) által készített tanulmány szerint a kukorica kiemelkedő szerepet játszik a globális élelmezésbiztonságban, különösen a fejlődő országokban. A kukorica, a búzával és a rizsszel együtt, több mint 4,5 milliárd ember számára biztosítja az élelmiszerkalóriák legalább 30%-át 94 fejlődő országban. Különösen jelentős a kukorica szerepe Afrika egyes részein és Közép-Amerikában, ahol önmagában több mint 20%-át adja a bevitt élelmiszerkalóriának. A kukorica nemcsak alapvető élelmiszer, hanem takarmányként és ipari alapanyagként is fontos, például bioüzemanyagok előállításában. Az éghajlatváltozás és a termelési kihívások azonban veszélyeztetik a kukoricaellátást, ami különösen a szegényebb fogyasztókat érinti hátrányosan. A tanulmány hangsúlyozza a magas hozamú, stressztűrő kukoricafajták nemesítésének és a fejlett agronómiai gyakorlatok alkalmazásának fontosságát a jövőbeni élelmezésbiztonság biztosítása érdekében. A fejlett gazdaságokban a kukorica elsősorban állati takarmányként szolgál, ugyanakkor ipari és energetikai célokra is széles körben hasznosítják. A gazdasági fejlődés, beleértve a jövedelmek növekedését és az urbanizációt, fokozza az állati eredetű élelmiszerek iránti keresletet, ami viszont növeli a kukorica takarmányként való felhasználását – Ázsia ebben a folyamatban különösen jelentős példát mutat (Erenstein, 2010). A kukorica globális szinten sokkal többet jelent, mint egyszerű gabonaféle: dinamikus szerepet tölt be az agrár-élelmiszeripari rendszerekben, és központi eleme a fejlődő országok élelmezésbiztonságának. Értékláncai nemcsak az élelmiszer rendelkezésre állását és hozzáférhetőségét befolyásolják, hanem kulcsszerepet játszanak a stabil ellátás és fenntartható felhasználás biztosításában is – különösen Afrikában és Ázsiában, ahol a termelési kockázatokhoz alkalmazkodni képes, stressztűrő fajták fejlesztése kiemelt fontosságú (Grote et al., 2021). Ezzel párhuzamosan a kukorica táplálkozás-élettani jelentősége sem elhanyagolható: bár gyakran energiahordozóként tartják számon, valójában fontos forrása lehet fehérjéknek, mikrotápanyagoknak és bioaktív vegyületeknek, így jelentős szerepet játszhat az alultápláltság és a mikrotápanyag-hiány csökkentésében (Poole et al., 2021). Az elmúlt évtizedben megnövekedett az érdeklődés az agrár-élelmiszeripari rendszerek, különösen a stratégiai jelentőségű növények – mint a kukorica – összetett társadalmi, gazdasági és táplálkozási szerepe iránt. A kukorica nem csupán alapvető élelmiszer- és takarmányforrás világszerte, hanem kulcsszereplője azoknak az élelmezési rendszereknek, amelyek közvetlenül befolyásolják a fenntartható fejlődést, a

táplálkozásbiztonságot és a vidéki megélhetést (Brouwer et al., 2020). Az ilyen rendszerek átalakítása és fejlesztése egyre sürgetőbbé válik a klímaváltozás, a növekvő népesség és a globális egyenlőtlenségek fényében.

Fanzo és munkatársai (2021) hangsúlyozzák, hogy az élelmezési rendszerek átalakítását célzó beavatkozások csak akkor lehetnek eredményesek, ha a kulcsfontosságú növények – mint a kukorica – értékláncait is szisztematikus monitoring és adatvezérelt döntéshozatal kíséri. Mivel a kukorica több milliárd ember étrendjének része, és egyszerre funkcionál élelmezési, gazdasági és bioenergetikai erőforrásként, az ellátási láncai stabilitása és rugalmassága közvetlen hatással van az élelmezési rendszerek teljesítményére. A kukorica tehát nem pusztán növényfaj, hanem a globális fenntarthatósági célok szempontjából stratégiai jelentőségű rendszeralkotó elem (Fanzo et al., 2021).

Az agrár-élelmiszeripari rendszerek fenntarthatóvá alakítása iránti igény részben abból a felismerésből fakad, hogy a jelenlegi gyakorlatok nem képesek hosszú távon biztosítani a növekvő világnépesség egészséges és elérhető táplálékellátását, miközben egyre nagyobb nyomást helyeznek a bolygó ökológiai határértékeire (Willett et al., 2019). Az éghajlatváltozás hatása tovább súlyosbítja ezt a helyzetet, különösen a sérülékenyebb közösségekben, ahol a termelés visszaesése közvetlenül fenyegeti a táplálkozásbiztonságot (Jones és Yosef, 2015). Ebben a kontextusban a kukorica – mint globálisan egyik legelterjedtebben termesztett gabonaféle – kulcsszereplővé válik az élelmezési rendszerek átalakulásában. Erenstein és munkatársai (2021) becslése szerint a világ kukoricával foglalkozó gazdaságainak száma 2020 és 2030 között várhatóan 216 millióról 227 millióra nő, miközben a kukorica globális termőterülete 205 millió hektárról 241 millió hektárra bővíülhet, így megelőzve a búzát is a legszélesebb körben termesztett növényként. Ez a tendencia jól tükrözi azt, hogy a kukorica nem csupán alapvető élelmiszer- és takarmánynövény, hanem a globális agrárátalakulás és a fenntarthatósági célkitűzések szempontjából is stratégiai jelentőségű növényé válik (Erenstein et al., 2021).

2.2. A kukorica keményítőtartalma

A kukoricaszem keményítőtartalmának döntő többsége az endospermiumban található, amely raktározószövetként funkcionál az érett kukoricaszemben. A keményítő a kukorica egyik legfontosabb komponense, amelyet ipari méreteken elsősorban nedves őrléses

technológiával nyernek ki (Singh et al., 2014). A kukoricakeményítő szemcséi jellemzően kettős eloszlást mutatnak: a kisebb méretű frakció 1–7 μm , míg a nagyobb szemcsék 15–20 μm közé esnek.

A keményítő alapvető energiaforrásként szolgál mind az emberi táplálkozásban, mind az állattenyésztés során alkalmazott takarmányozásban. A kukoricaszem keményítőtartalma jelentős variabilitást mutat a genotípus és a termesztési feltételek függvényében, azonban a szárazanyag-tartalomra vetítve jellemzően 68–74% között alakul. A FAO (2022) adatai szerint a kukoricaszem kémiai összetételének domináns frakcióját, megközelítőleg 72–73%-át a keményítő alkotja. A fennmaradó szénhidrát-tartalom egyszerű cukrok – glükóz, szacharóz és fruktóz – formájában van jelen, melyek aránya rendszerint 1–3% között mozog.

A kukoricakeményítő két típusú glükózpólimerből épül fel: az amilóz lineáris láncú, míg az amilopektin elágazó szerkezetű molekula. A hagyományos kukoricafajták keményítője jellemzően 25–30% amilózt és 70–75% amilopektint tartalmaz, míg a viaszos (waxy) hibridek esetében az amilopektin részaránya eléri a 95–100%-ot (Kiss, 2013). A keményítő összetétele nemcsak táplálkozási, hanem ipari szempontból is meghatározó jelentőséggel bír. Számos olyan tulajdonsággal rendelkezik, amelyek kiemelten alkalmassá teszik különféle élelmiszeripari, fermentációs és takarmányozási alkalmazásokra.

A keményítő mennyiségi meghatározására különféle analitikai módszerek állnak rendelkezésre. A legelterjedtebb eljárás az enzimatis bontáson alapul, ahol a keményítőt α -amiláz és amiloglükozidáz segítségével glükózzá hidrolizálják, majd a glükóz mennyiségét glükózoxidáz/peroxidáz (GOPOD) reagenssel határozzák meg (McCleary et al., 2019). További lehetőségek közé tartozik a polarimetriás mérés, amely a síkban polarizált fény elfordulását méri, valamint a spektrofotometriás eljárás, amely színreakciókon – például jóddal vagy antron alkalmazásán – alapul.

A modern mezőgazdasági kutatásokban és ipari gyakorlatban egyre szélesebb körben alkalmazzák a gyors és nem roncsoló közeli infravörös spektroszkópiái (NIR) technikákat is. A kutatáshoz felhasznált adatok esetében a kukoricaszemek keményítőtartalmának mérése a FOSS Infratec 1241 típusú NIR analizátorral történt, amely megbízhatóan és nagy pontossággal képes kvantifikálni a keményítőt – különösebb mintaelőkészítés nélkül. Ez az

eszköz jól alkalmazható nagy mintaszámok esetén is, és különösen előnyös a precíziós mezőgazdasági rendszerekben (Kiss, 2013).

2.3. A különböző műtrágyakezelések hatása a kukorica keményítőtartalmára

A különböző összetételű és mennyiségű műtrágyadózisok hatása a kukorica (*Zea mays L.*) keményítőtartalmára jelentős kutatási érdeklődés tárgyát képezi. Számos vizsgálat igazolta, hogy a különböző tápanyagok – különösen a nitrogén (N), foszfor (P) és kálium (K) – alkalmazása kulcsszerepet játszik a kukoricaszem keményítőtartalmának alakulásában (Viswakumar et al., 2008).

A káliumtartalmú műtrágyák kijuttatása kimutathatóan növeli a keményítőtartalmat. Zhang és munkatársai (2022) vizsgálatai szerint a K-trágyával végzett kezelések szignifikáns keményítőtartalom-növekedést eredményeztek viaszoszemű kukoricában, miközben csökkent a fehérjetartalom, amit a szacharózbontás fokozódásával és a keményítőszintézis gyorsulásával magyaráztak. Hasonló megállapításra jutott Laghari et al. (2024), akik az NPK-műtrágyák alkalmazása kapcsán egyértelmű összefüggést mutattak ki a kijuttatott dózisok és a kukorica minőségi jellemzői – így a keményítőtartalom – között.

A nitrogéntrágyázás különösen hatékonynak bizonyult a keményítőtartalom növelésében. Xu et al. (2019) megállapították, hogy megemelt CO₂-szint mellett végzett nitrogénpótlás fokozta a keményítő-felhalmozódást. Wang és Lu (2023) azt is kiemelték, hogy a különböző nitrogéndózisok jelentősen befolyásolják a keményítő fizikai-kémiai tulajdonságait: magasabb N-szintek mellett nőtt a fehérjetartalom, de ezzel együtt a keményítőtartalom is emelkedett – igaz, ez utóbbi némi kompromisszumot jelenthet az olajtartalom rovására.

A termelési technológiák fejlődése révén a lassú lebomlású műtrágyák alkalmazása is ígéretes eredményeket hozott. Zhu et al. (2023) eredményei szerint e típusú trágyák jelentősen javították a keményítőtartalmat és annak minőségét, különösen akkor, ha azokat a növény fejlődésének kulcsszakaszaiban alkalmazták. Ezt támasztotta alá Yuan et al. (2021) is, akik megállapították, hogy a különböző fenológiai fázisokban kijuttatott tápanyagok pozitívan hatottak a keményítőszemcsék méretére, ezzel is javítva a végtermék minőségét.

A nitrogéntrágyázás nemcsak a hozamra és fehérjetartalomra van hatással, hanem a kukorica endospermiumának szerkezetét is módosíthatja, ezáltal befolyásolva a keményítő

feldolgozhatóságát. Oikeh et al. (1998) vizsgálatai szerint a 30–60 kg ha⁻¹ N-dózis mellett nőtt a lisztes endospermium aránya.

Fontos azonban megjegyezni, hogy a tápanyagpótlás és a keményítőtartalom közötti kapcsolat nem minden esetben lineáris. Bár a nitrogénpótlás a terméshozamok emelkedése révén növelheti a keményítőhozamot, a túlzott N-műtrágyázás negatív hatással lehet a keményítőtartalomra (Khan, 2016; Correndo et al., 2021). Ez az összefüggés rávilágít arra, hogy a tápanyagpótlást a növényfajta és a környezeti feltételek igényeihez kell igazítani.

A műtrágyakezelések kukorica keményítőtartalmára gyakorolt hatása jelentős mértékben függ a kijuttatott tápanyagszintek, a környezeti feltételek és a genotípusok kölcsönhatásától. Többhibrides kísérletekben AMMI- és GGE-biplot elemzések alapján megállapították, hogy közepes és magas NPK-dózisok esetén számos genotípusban emelkedett a keményítőtartalom, ugyanakkor a változás mértéke genotípusfüggőnek bizonyult (Illés et al., 2020). Hároméves tartamkísérletben a nitrogéndózisok növelése következetesen emelte a fehérjetartalmat, miközben két évben a legmagasabb keményítőtartalom a kontroll (A0) kezelésben volt mérhető; ezzel szemben a csapadékos 2020-as évben a 120 kg N ha⁻¹ dózis biztosította a legnagyobb keményítőtartalmat (77,9 g/100 g), ami a vízellátottság meghatározó szerepére utal (Horváth et al., 2021a). Aszályos években a nitrogén-utánpótlás időzítése és az alaptrágyázás szintje különösen kritikus tényezőnek bizonyult: 2021–2022-ben a fejtrágyázás (V6/V12 fenológiai fázisban) nem eredményezett szignifikáns terméstöbbletet, és a 120 kg ha⁻¹ alaptrágya dózis mutatkozott a legkedvezőbbnek. Eszerint vízhiányos körülmények között a nitrogéntrágyázás hozamfokozó hatása korlátozott, mivel a stressz csökkenti a fotoszintézist és ezzel együtt a szénhidrátok – köztük a keményítő – felhalmozódását is. (Széles et al., 2023b). Nyandi et al. (2025) eredményei szerint az alacsonyabb nitrogéndózisok mellett mérték a legmagasabb keményítőtartalmat: például 2022-ben a kontroll (0 kg N ha⁻¹) kezelésben 73,19 % keményítőtartalmat állapítottak meg, míg a 90 kg N ha⁻¹ szinten ez 69,91 %-ra, a 150 kg N ha⁻¹ szinten pedig 71,40 %-ra csökkent. Eszerint az alacsonyabb nitrogénszintek kedvezőbbek lehetnek a keményítő-felhalmozódás szempontjából, míg a magasabb dózisok inkább a fehérjetartalom növelésének kedveznek.

Illés et al. (2020) és Bojtor et al. (2021) rámutattak, hogy a növekvő N-dózisok általában a fehérjetartalom emelkedését eredményezik, míg a keményítőtartalom mérséklődik,

különösen magasabb dózisok mellett. Horváth et al. (2021b) kutatása során három egymást követő év adatai alapján igazolták, hogy a nitrogéntrágyázás mértéke szignifikáns hatással van a kukoricaszemek fehérje- és keményítőtartalmára. A vizsgálatok szerint a fehérjetartalom a műtrágyadózisok növekedésével emelkedett (6,2–10,2 g/100 g), míg a keményítőtartalom ezzel ellentétes tendenciát mutatott. Két évben (2018 és 2019) a legmagasabb keményítőtartalmat (74,2 és 72,3 g/100 g) a nem trágyázott (A0) kezelés biztosította, míg a magasabb nitrogéndózisokkal kezelt parcellákban szignifikáns csökkenést mértek. Ugyanakkor a 2020-as év kedvező csapadékviszonyai mellett a legmagasabb keményítőtartalmat (77,9 g/100 g) a 120 kg ha⁻¹ kezelés adta. Hasonló következtetésre jutott Kaplan et al. (2019) is, akik a nitrogéntrágyázás hatására a kukoricaszemek keményítőtartalmának csökkenését tapasztalták öntözéses körülmények között.

A nitrogéntrágyázási rendszerek részletes beltartalmi elemzésekor Bojtor et al. (2022) kimutatta, hogy az alacsonyabb N-dózisokhoz magasabb keményítőtartalom, a magasabb N-szintekhez viszont fokozott fehérjeszint társul, vagyis a két minőségi paraméter egymás rovására változik. Hasonló tendenciát jeleztek a távérzékelési módszerekkel végzett elemzések is: Szabó et al. (2022b) szerint a levélterület-index (LAI) és a tápanyagellátottság összefüggései alapján a keményítő-felhalmozódás elsősorban mérsékelt N-szintek mellett kedvező. A legújabb vizsgálatokban Nyandi et al. (2025) tovább pontosították a N-hatás és a keményítőtartalom kapcsolatát: 0 kg N ha⁻¹ mellett 73,19 %, 90 kg N ha⁻¹ mellett 69,91 %, míg 150 kg N ha⁻¹ mellett 71,40 % keményítőtartalmat mértek, ami megerősíti, hogy a mérsékelt vagy alacsonyabb N-dózisok a keményítő szempontjából kedvezőbbek

Ezzel szemben Ibrahim et al. (2007) Egyiptomban végzett, intenzíven öntözött körülmények között olyan eredményeket közöltek, melyek szerint a növekvő N és P trágyaszintek (akár 120 kg N + 35 kg P₂O₅ /fed.) jelentősen növelték a kukoricaszemek keményítőtartalmát, elérve a 73,16%-ot. A vízellátás rendszeressége – tíznapos öntözési intervallum – kulcsszerepet játszott ebben a pozitív hatásban, mivel megfelelő talajnedvesség mellett a növények hatékonyabban hasznosítják a felvett tápanyagokat, és zavartalanabban zajlik a fotoszintézis és a szénhidrát-anyagcsere. Hasonló megfigyelésekre jutottak Yue et al. (2022) is, akik kimutatták, hogy a magas nitrogénellátás a keményítő-anyagcsere enzimeinek

aktiválásán és a hormonális szabályozáson keresztül serkentette a keményítő-felhalmozódást öntözött körülmények között.

A különféle műtrágyaelemek együttes alkalmazása jótékony hatással lehet a keményítőhozamra. Jiang et al. (2024) kutatásai szerint a nitrogén és a kén kombinált kijuttatása nemcsak a keményítőtartalmat, hanem a szemtermés mennyiségét is növelte. Emellett Toishimanov et al. (2023) eredményei is alátámasztják, hogy az organikus trágyák alkalmazása jelentős mértékben javította a keményítőtartalmat és más minőségi mutatókat a hagyományos tápanyag-visszapótlási eljárásokkal szemben.

2.4. A különböző talajművelési rendszerek hatása a kukorica keményítőtartalmára

A különböző talajművelési rendszerek nemcsak a növénynövekedést és a talajszerkezetet, hanem a talajbiológiai folyamatokat is jelentősen befolyásolják (Mohammed et al., 2021c). A talajművelési gyakorlatok hatással vannak a talaj fizikai tulajdonságaira, és befolyásolják a növények növekedését, terméshozamát és minőségét, beleértve a kukorica keményítőtartalmát is.

Az őszi szántás során a talaj mélyebb forgatása segíti a tömörödött rétegek megszüntetését, javítva a levegőzöttséget és a vízelvezetést. Kutatások szerint a hagyományos talajművelési rendszerek – például az őszi szántás – alatt termesztett növények gyakran nagyobb terméshozamot érnek el a kedvezőbb talajviszonyoknak köszönhetően, ami elősegíti a keményítő felhalmozódását a szemekben (Bramdeo és Rátonyi, 2020; Megyes et al., 2001; Nagy és Széles, 2018). Ezen túlmenően a környezeti tényezők – mint a talajnedvesség és a tápanyag-ellátottság – interakciója szintén hozzájárulhat a keményítősintézishez, és az őszi szántás ezeket pozitívan befolyásolhatja a gyökérnövekedés és a tápanyagfelvétel javításán keresztül (Ferencsik és Rátonyi, 2014; Sedlák, 2012).

Ezzel szemben a lazítás, amely nem forgatja ugyan meg a talajt, de jó körülményeket hoz létre a gyökerek számára, elősegítheti a mélyebb gyökérrendszer kialakulását és javíthatja a talaj vízmegtartó képességét. Ez a kedvezőbb talajszerkezet hozzájárulhat a szénhidrát-felhalmozódáshoz, így potenciálisan növelve a keményítőtartalmat a hagyományos szántással szemben. A kutatások szerint a lazítás során kialakuló talajszerkezet kedvezően hat a tápanyag-mobilizációra, elősegítve ezzel a keményítősint emelkedését (Bramdeo &

Rátonyi, 2020; Ferencsik et al., 2014). Ugyanakkor a lazítás hatása függhet a termesztett kukoricahibridtől és a környezeti feltételektől, mivel a keményítőszintézis szorosan kapcsolódik a genotípus talajhasznosítási képességéhez (Virág et al., 2020).

A sávos művelés során a talaj nagy része érintetlen marad, csupán a vetősávokat munkálják meg. Ez a módszer előnyös lehet a talajnedvesség megőrzése és az erózió csökkentése szempontjából. A kutatások szerint a sávos művelés hozamai gyakran vetekednek a hagyományos művelési rendszerekkel, miközben hozzájárulnak a talajállapot hosszú távú javulásához, valamint mérséklék a kedvezőtlen éghajlati tényezők hatását (Huzsvai et al., 2003; Zsembeli et al., 2018). A kevésbé zavaró jelleg elősegíti a mikrobiális aktivitást és a tápanyagkörforgást, így támogatja a keményítőtartalom növekedését a gyökérfejlődés és a tápanyagfelvétel serkentésén keresztül (Ferencsik és Rátonyi, 2014; Ferencsik et al., 2014).

A különböző talajművelési módszerek hozamra és keményítőtartalomra gyakorolt hatását Wasaya és munkatársai is vizsgálták. Megállapították, hogy a szántás jobb nitrogénfelvételt és szemminőséget – beleértve a keményítőtartalmat – eredményezett, mint más művelési módok. Kutatásuk szerint a hatékony talajforgatás és a talajtömörödés csökkentése pozitívan befolyásolja a szem tápanyagtartalmát (Wasaya et al., 2018).

Drobitko et al. (2024) megállapították, hogy a 30 cm mélységig végzett szántás magasabb keményítőtartalmat eredményezett (70,9%), mint a sekélyebb, például tárcsás művelési módszerek. Eredményeik szerint a talajművelési módok szignifikáns hatást gyakorolnak a szem minőségi mutatóira, köztük a keményítőtartalomra is. Hasonló megállapításra jutott Simić et al. (2020), aki kimutatta, hogy a kukoricaszem minőségét – beleértve a keményítőtartalmat is – jelentősen befolyásolja a talajművelési mód és a nitrogénadagolás mértéke. Vizsgálataik szerint a hagyományos talajművelés magasabb keményítőtartalmat eredményezett a csökkentett vagy mulcsos műveléssel szemben.

Az alkalmazott talajművelési mód jelentős szerepet játszik a kukoricaszem keményítőtartalmának alakulásában. Az őszi szántás általában kedvezőbb talajállapotot teremt, ami elősegíti a magasabb keményítőtartalmat. A lazítás a mélyebb gyökerezés és jobb tápanyaghasznosítás révén bizonyos hibrideknél kedvezőbb, míg a sávos művelés hosszú távon javíthatja a talaj egészségét, és ezzel közvetetten támogatja a keményítőfelhalmozódást. Az eredmények rámutatnak az agronómiai gyakorlatok és a kukorica

minőségi paraméterei – különösen a keményítőtartalom – közötti szoros összefüggésre (Bramdeo és Rátonyi, 2020; Nagy és Széles, 2018; Huzsvai et al., 2003).

2.5. Az éghajlati változók hatása és az évjáráthatás szerepe a kukorica keményítőtartalmára vonatkozóan

Az éghajlati változók, mint a hőmérséklet és a csapadék, jelentősen befolyásolhatják a kukorica növekedését és fejlődését, befolyásolva a terméshozamot és a minőségi jellemzőket, többek között a keményítőtartalmat. Az időjárási tényezők változékonysága azonban merőben eltérő klimatikus összetételt mutathat a különböző évjáratok esetén. A kukoricatermesztés eredményességét jelentősen befolyásolják az évjáratok különbségei, ezért a fenológiai és meteorológiai viszonyok részletes értékelése elengedhetetlen a termesztéstechnológiai beavatkozások eredményeinek pontos értelmezéséhez (Nagy és Nagy, 2020). Gombos et al. (2023) 50 és 30 éves trendvizsgálatukban kimutatták, hogy a Debrecen térségében tapasztalható szignifikáns nyári felmelegedés és a nyári csapadékmennyiség csökkenése együttesen romló vízellátottsághoz és csökkenő hozamokhoz vezet. E szoros összefüggés tükrében szintén jelentőségteljesek Gombos és Nagy (2019), illetve Nagy et al. (2020) időjárási adatelemzései. Gombos és Nagy (2019) tartamkísérletek alapján kimutatták, hogy a hőmérsékleti szélsőségek és a csapadékeloszlás egyenlőtlensége alapvetően meghatározza a kukorica termésbiztonságát. Nagy et al. (2020) részletes elemzése szerint a 2018–2019. évi kedvezőtlen meteorológiai feltételek – különösen az aszályos periódusok – a termésmennyiség jelentős csökkenését eredményezték, ami jól illusztrálja a klimatikus tényezők közvetlen hatását a tartamkísérletekben. Ezek a kutatások együtt alátámasztják, hogy a klímaváltozás hosszú távon a kukoricatermesztés stabilitását és fenntarthatóságát is veszélyeztetheti.

A kukorica keményítőtartalma jelentős mértékben változhat az egyes évjáratok között, elsősorban a vízellátottság eltéréseinek következtében. Bánszki (2012) megfigyelései alapján az eltérő csapadékeloszlású évjáratokban jelentős különbségek mutatkoztak a keményítőhozamban: míg az aszályos 2007-es évben magasabb keményítőtartalom volt mérhető, addig a hektáronkénti keményítőhozam drasztikusan alacsonyabb volt, mint a csapadékban gazdagabb 2008-as és 2009-es években, ahol az alacsonyabb keményítőtartalom ellenére lényegesen magasabb volt a hektáronkénti keményítőhozam. Ez a jelenség összhangban áll más kutatások eredményeivel is, amelyek kiemelik a vízellátottság

szerepét nemcsak a kukoricánövény növekedésére, hanem annak biokémiai összetételére gyakorolt hatása szempontjából is (Rátonyi et al., 2012; Nagy és Széles, 2018). Hasonló összefüggéseket írt le Butts-Wilmsmeyer et al. (2019), akik kimutatták, hogy a kukorica hozamát és a szem minőségét alapvetően meghatározza az időjárás a kulcsfejlődési szakaszokban.

A hőmérséklet befolyásolja a kukorica fotoszintézisének, szemtöltésének és keményítőszintézisének sebességét. Sánchez és munkatársai megállapították, hogy a kukorica növekedése szempontjából optimális hőmérséklettartomány 20° és 35 °C között van. Amennyiben a hőmérséklet túl magas, az a szemtöltődés csökkenéséhez és alacsonyabb keményítőtartalomhoz vezethet. Másrészt az alacsonyabb hőmérséklet lelassíthatja az anyagcsere-folyamatokat, beleértve a keményítőszintézist is, és potenciálisan alacsonyabb keményítőtartalomhoz vezethet (Sánchez et al., 2014).

A kukorica megfelelő fejlődéséhez különösen fontos a megfelelő vízellátás, főként a nővirágzás és a szemkitöltés kritikus fejlődési szakaszaiban. A növény teljes vízszükségletének mintegy 45%-át ezekben az időszakokban – a nővirágzás előtti és a középerés közötti fázisban – veszi fel (Bagula et al., 2022). A virágzási időszak alatt egyetlen növény napi vízigénye elérheti a 8–9 mm-t. Ha két héttel a virágzás előtt szárazság alakul ki, az akár 25%-kal is csökkentheti a szemtermést, míg ha a vízhiány éppen a virágzással esik egybe, a termésveszteség mértéke meghaladhatja az 50–60%-ot (Comas et al., 2019).

A vízstressz ezekben az érzékeny fázisokban hátrányosan befolyásolja a szemkitöltést és a keményítőfelhalmozódást. Ezzel szemben a túlzott nedvesség gyökérvárosodást és tápanyag-kimosódást idézhet elő, rontva a növény általános egészségi állapotát és potenciálisan csökkentve a keményítőtartalmat.

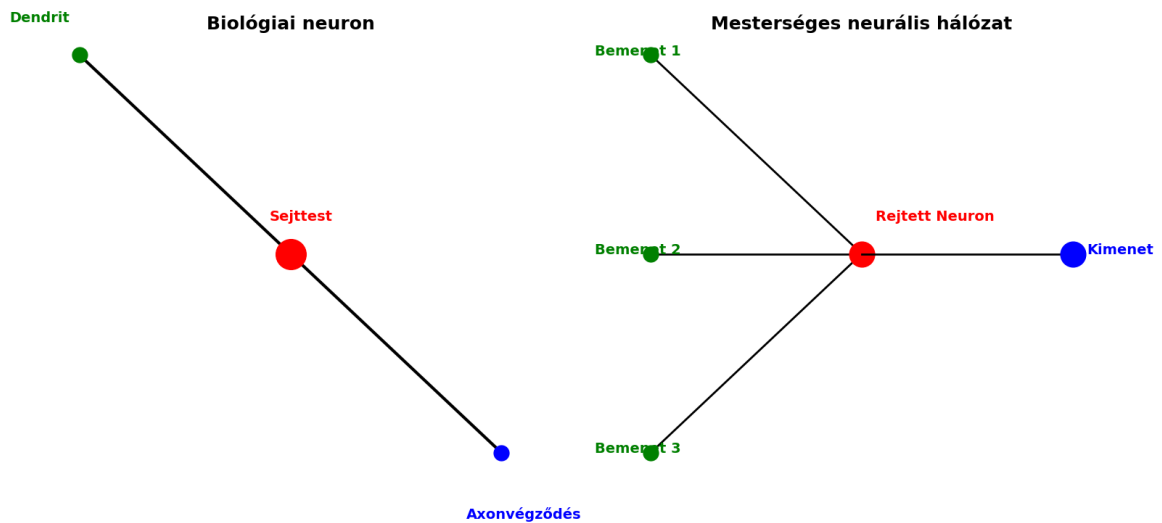
Guo és munkatársai (2023) két kukoricafajta esetében vizsgálták a megtermékenyülés utáni aszálystressz hatásait. Eredményeik szerint a stressz csökkentette a szemtömeget, a nedvességtartalmat, a magmennyiséget és a hozamot, illetve gátolta a keményítő bioszintéziséhez kapcsolódó enzimek működését, ezáltal csökkent a keményítő és az oldható cukrok lerakódása. Eközben fokozta a fehérjeszintézisben szerepet játszó enzimek aktivitását, növelve a szemek fehérjetartalmát. A kutatás megerősíti, hogy a virágzás utáni vízhiány jelentősen módosítja a szemek töltődési folyamatait, valamint a keményítő- és fehérjeanyagcserét, ami a termés mennyiségét és minőségét egyaránt befolyásolja.

2.6. Gépi tanulás és mesterséges neurális hálózatok (ANN) alkalmazása a különböző mezőgazdasági paraméterek becsléséhez

A gépi tanulás és a szimulációs termésmodellezés terén elért legújabb tudományos és technológiai fejlesztések új távlatokat nyitottak a mezőgazdasági előrejelzések pontosságának és megbízhatóságának javításában (Archontoulis et al., 2020). A gépi tanulás, mint a neurális hálózatok, döntési fák vagy random forest algoritmusok alkalmazása különösen hatékony a nagyméretű és komplex mezőgazdasági adathalmazok feldolgozásában, lehetővé téve a mintázatok felismerését és a prediktív modellek finomhangolását (Shahhosseini et al., 2021). A gépi tanulás hatékony eszköz lehet a legfontosabb bemeneti változók kiválasztásában, a modell paramétereinek optimalizálásában, valamint a torzítások és hibák korrigálásában.

2.6.1. Mesterséges neurális hálózatok (ANN)

A mesterséges neurális hálózatok (ANN) a gépi tanulás és a számítástechnika egyik dinamikusan fejlődő és innovatív szakterületét alkotják, céljuk pedig a biológiai neuronok működésének szimulációja. Az ANN-ek kulcsszerepet játszanak a valós életből származó, összetett problémák kezelésében, ezért már évtizedek óta alkalmazzák őket különféle tudományterületeken (Qi, 1996). A neurális hálózatok fejlődésének kezdete a 20. század derekára vezethető vissza, amikor McCulloch és Pitts (1943) elsőként dolgoztak ki olyan elméleti modelleket, amelyek az alapvető logikai és aritmetikai műveletek végrehajtására alkalmas egyszerű neuronhálózatokat írtak le. A mesterséges neuronok alkalmazásának első kézzelfogható eredménye Rosenblatthoz köthető, aki létrehozta a Mark I perceptront, egy karakterfelismerésre szolgáló rendszer prototípusát (Rosenblatt, 1958, 1961). A korai perceptronok azonban túlzottan leegyszerűsítették az idegi folyamatokat, és nem tudtak megbirkózni a nemlineáris osztályozási problémákkal, ami hátráltatta további fejlődésüket. Az áttörés az 1980-as évek közepén következett be, amikor a visszaterjesztéses tanulási algoritmust (backpropagation) újra felfedezték és széles körben alkalmazni kezdték (Rumelhart et al., 1986), új lendületet adva a kutatásoknak és az ipari alkalmazásoknak egyaránt. A mesterséges neurális hálózatok és a természetes neuronok közötti párhuzam főként a működés logikájában ragadható meg. A biológiai neuronok képesek több bemeneti jel fogadására, ezek feldolgozására és továbbítására.




1. ábra: A neuronok és a mesterséges neurális hálózatok szerkezetének összehasonlítása

(Forrás: Saját szerkesztés Basheer és Hajmeer (2000) alapján)

A jeleket dendritek veszik fel, majd az axonokon keresztül, szinapszisok segítségével jutnak el a következő sejtekhez. Ezzel szemben az ANN-ek csomópontjai (mesterséges neuronok) matematikai módon utánozzák ezt a működést: fogadják a bemeneteket, meghatározott szabályok alapján feldolgozzák őket, és továbbítják az eredményeket a hálózat következő rétege felé. Bár ezek a modellek jelentősen egyszerűsítik az idegrendszer valódi működését, mégis kiválóan alkalmazhatók komplex feladatok, például mintafelismerés, osztályozás vagy előrejelzés területén (Basheer és Hajmeer, 2000). A mesterséges és biológiai neuronok szerkezeti és funkcionális összevetését az 1. ábra szemlélteti.

A mesterséges neurális hálózatok (ANN-ek) egyik legmeghatározóbb tulajdonsága az adaptív tanulási képességük, amely lehetővé teszi számukra, hogy a tapasztalatok alapján folyamatosan fejlesszék teljesítményüket anélkül, hogy explicit újraprogramozásra lenne szükség (Techvidvan.com, 2024). A modellek általános felépítését az alábbi 2. ábra szemlélteti.



2. ábra: A mesterséges neurális hálózatok architektúrája (Forrás: Zhang et al., 2017)

Az ábrán egy mesterséges neurális hálózat szerkezete látható, amely három fő rétegből épül fel:

- Bemeneti réteg (*piros*): itt kerülnek a modellbe a vizsgált inputparaméterek, esetünkben az agronómiai és környezeti tényezők.
- Rejtett réteg (*kék*): ebben a szakaszban történik az adatok feldolgozása és a nemlineáris összefüggések feltárása.
- Kimeneti réteg (*zöld*): a hálózat végső előrejelzése a kimeneti változóra (kutatásom esetében a keményítőtartalom) vonatkozóan.

A rétegek közötti nyilak az információáramlást jelképezik, amelynek során minden csomópont kapcsolódik a következő réteg összes csomópontjához. Ez biztosítja, hogy a modell hatékonyan feldolgozza az adatokat és minél pontosabb becslést készítsen.

1. táblázat: A mesterséges neurális hálózatok (ANN) előnyei és hátrányai

Előnyök	Hátrányok
Képesek adatokból tanulni, vagyis explicit programozás nélkül is javíthatják teljesítményüket a tapasztalatok alapján. (Goodfellow, et al., 2016; Techvidvan.com, 2024)	Átláthatatlan döntéshozatal („fekete doboz” jelleg): nehéz értelmezni, hogyan jut a hálózat az eredményhez. (Lipton, 2016)
Párhuzamos információfeldolgozásra képesek, amely lehetővé teszi több feladat egyidejű kezelését. (Techvidvan.com, 2024)	Képzési idő kiszámíthatatlansága: a tanulási folyamat időigénye előre nem becsülhető pontosan. (Goodfellow et al., 2016)
Hibatűrők: egy-egy neurális egység meghibásodása nem feltétlenül befolyásolja az egész rendszer működését. (Techvidvan.com, 2024)	Hajlamosak a túlillesztésre, különösen túl sok paraméter tanulása esetén. (Goodfellow et al., 2016)
Nagy adatmennyiséget képesek feldolgozni, és sok bemeneti változót tudnak kezelni, így kiválóan alkalmazhatók kép-, beszéd- és szövegfeldolgozásra. (Bishop, 1995; LeCun, Bengio & Hinton, 2015)	Jelentős adatigény: hatékony működésükhöz nagy és reprezentatív adathalmazokra van szükség. (Goodfellow et al., 2016)
Összetett, nemlineáris összefüggések feltárására alkalmasak a bemenetek és kimenetek között. (LeCun et al., 2015)	Magas számítási igény: különösen komplex architektúrák és nagy hálózatok esetén jelentős erőforrásokat igényelhetnek. (Goodfellow et al., 2016)
Kiváló teljesítményt nyújtanak mintafelismerési és osztályozási feladatokban. (Techvidvan.com, 2024)	Érzékenyek a bemeneti adatok minőségére, és gyakran igényelnek előfeldolgozást. (Goodfellow et al., 2016)
Alkalmazkodnak az új adatokhoz, így képesek dinamikusan frissíteni tudásukat például spam-felismerés során. (LeCun et al., 2015)	Nagy adathalmazokkal való tanítás esetén a képzési idő jelentős lehet, ami problémát jelenthet gyors döntéshozatalt igénylő feladatoknál. (Goodfellow et al., 2016)

Forrás: Saját szerkesztés a Techvidvan.com (2024) és Mijvel (2021), valamint Goodfellow, Bengio & Courville (2016); LeCun et al. (2015); Bishop (1995); Lipton (2016) alapján.

Az ANN-ek számos olyan előnnyel rendelkeznek, amelyek különösen alkalmassá teszik őket összetett, nemlineáris problémák kezelésére. Ilyen előny például a párhuzamos információfeldolgozás képessége, amely lehetővé teszi több folyamat egyidejű kezelését, valamint a hibákkal szembeni viszonylagos ellenállóképességük, ami biztosítja, hogy egyes egységek meghibásodása nem jár az egész rendszer működésének összeomlásával. Mindemellett az ANN-ek alkalmazása nem mentes a kihívásoktól. Az egyik leggyakrabban említett korlát a „fekete doboz” jelenség, amely azt jelenti, hogy a hálózat döntéshozatali mechanizmusa nehezen visszafejthető, így az interpretálhatóság jelentősen korlátozott. További nehézséget jelent a megfelelő hálózati architektúra meghatározása, amely gyakran empirikus próbálkozások sorozatán alapul, mivel nem létezik egységesen elfogadott

módszertan e struktúrák optimális konfigurálására. A mesterséges neurális hálózatok főbb előnyeit és hátrányait az 1. táblázat foglalja össze.

Az ANN-ek egyik legfontosabb jellemzője, hogy explicit programozás nélkül képesek tanulni az adatokból (Dahmani et al. 2014). Ez egy képzésnek nevezett folyamat révén történik, amelynek során a hálózatnak bemenetek és a hozzájuk tartozó kimenetek halmazát mutatják be, és a neuronok közötti kapcsolatok súlyait és torzításait úgy állítják be, hogy minimalizálják a hibát a megjósolt kimenet és a kívánt kimenet között. Az ANN-ek képzésére számos algoritmus létezik, köztük a backpropagation, amely széles körben használt módszer a feedforward hálózatok (olyan hálózatok, amelyekben az információ csak egy irányban, a bemenetről a kimenetre áramlik) képzésére.

Az ANN-eknek több különböző típusa létezik (Agatonovic-Kustrin et al., 2000; Alizadeh et al., 2018), köztük a feedforward hálózatok, a konvolúciós neurális hálózatok (CNN-ek) és a rekurrens neurális hálózatok (RNN-ek). A feedforward hálózatok a legegyszerűbb ANN-típus, és egy bemeneti rétegből, egy vagy több rejtett rétegből és egy kimeneti rétegből állnak. A bemeneti réteg fogadja a bemeneti adatokat, a kimeneti réteg pedig a megjósolt kimenetet állítja elő. A rejtett rétegek feldolgozzák a bemeneti adatokat, és továbbítják azokat a kimeneti rétegnek.

A CNN-ek a feedforward hálózatok egy olyan típusa, amely különösen alkalmas a rácsszerű struktúrájú adatok, például képek feldolgozására. Több neuronrétegből állnak, amelyek mindegyike a bemeneti adatok egy-egy kis régiójának feldolgozásáért felelős. Ezek a rétegek gyakran hierarchikusan vannak elrendezve, a magasabb rétegek az adatok absztraktabb jellemzőit dolgozzák fel.

Az RNN-ek az ANN-ek egy olyan típusa, amely különösen alkalmas szekvenciális adatok, például idősorok vagy természetes nyelvi adatok feldolgozására. Olyan neuronokból állnak, amelyek belső memóriával rendelkeznek, ami lehetővé teszi számukra, hogy feldolgozásuk során figyelembe vegyék a bemeneti adatok kontextusát. Ez teszi az RNN-eket különösen hasznossá az olyan feladatokhoz, mint a nyelvi fordítás vagy a szöveggenerálás (LeCun et al., 2015).

Kivételes képességeik ellenére az mesterséges neurális hálózatoknak vannak bizonyos korlátai. Az egyik fő korlát az, hogy érzékenyek lehetnek a képzési adatok minőségére, és rosszul teljesíthetnek, ha az adatok zajosak, vagy ha nem reprezentatívak a megoldandó problémára. Szintén limitáló tényező, hogy az ANN-ek nehezen értelmezhetők, így nehéz megérteni, hogyan hozzák meg a döntéseket. Ez problémát jelenthet olyan helyzetekben, amikor fontos megérteni a hálózat által készített előrejelzések mögött álló okokat.

2.6.2. Gépi tanulási módszerek alkalmazása a mezőgazdaságban és a környezetvédelemben

A gépi tanulási módszereket, azon belül a mesterséges neurális hálózatokat (ANN) a mezőgazdaságban és a környezetvédelemben számos feladatra használják, többek között a terméshozam és beltartalmi paraméterek előrejelzésére, az öntözés optimalizálására, az éghajlat előrejelzésére, illetve betegségek és kártevők diagnosztizálására (Kujawa és Niedbała, 2021). A mesterséges neurális hálózatok (ANN) alkalmazása a mezőgazdaságban számos területen bizonyult hatékonynak, különösen a terméshozamok előrejelzésében. Az ANN-ek képesek olyan adatok alapján tanulni, mint az időjárási minták, talajviszonyok és gazdálkodási gyakorlatok, hogy pontos becsléseket adjanak a növények várható terméshozamára. Ez az információ lehetővé teszi a gazdálkodók számára, hogy megalapozott döntéseket hozzanak a vetés és betakarítás időzítéséről, valamint segíti az ellátási lánc vezetőit a termények hatékony elosztásának megtervezésében.

A hozamelőrejelzés területén az ANN-ek számos országban bizonyították hatékonyságukat. Nyéki et al. (2021) magyarországi kísérletekben az ANN-eken túlmenően több gépi tanulási algoritmust (CP-ANN, XY-F, SKN, SVM, XGBoost) hasonlított össze kukoricahozam előrejelzésére. A legjobb modell 95,38%-os pontosságot, 91,3%-os szenzitivitást és 97,62%-os specificitást ért el; a legfontosabb prediktorok között az NDVI, a májusi csapadék, a talaj pH és az agyagtartalom szerepelt. Baio et al. (2023) kimutatták, hogy a spektrális indexek, öntözési adatok és hőmérsékleti paraméterek kombinációja növeli az ANN- és SVM-modellek hozambecslési pontosságát. Miao et al. (2024) Kínában több adatforrás (klíma, műhold, talaj) integrálásával dolgozott BP-ANN, LSTM, RF és XGBoost modellekkel, $R^2 \geq 0,75$, $RMSE = 824\text{--}875 \text{ kg ha}^{-1}$ és $MAE = 626\text{--}651 \text{ kg ha}^{-1}$ értékeket elérve. Ennaji et al. (2024) kukoricahibridek hozamát becsülte gradient boosting módszerekkel, $MAE 0,26\text{--}0,27$,

RMSE 0,37–0,39 és R^2 0,86–0,87 eredményekkel. Li et al. (2025) CNN–BiGRU–attention architektúrával fekete talajú régiókban ért el $r^2 \approx 0,896$ és $RMSE \approx 908 \text{ kg ha}^{-1}$ pontosságot, demonstrálva a mélytanulási modellek potenciálját a tér- és időbeli adatok feldolgozásában.

A beltartalmi paraméterek (keményítő-, fehérje- és olajtartalom) becslése szintén egyre nagyobb figyelmet kap a precíziós mezőgazdaságban. Liu et al. (2020) közeli infravörös hiperspektrális képalkotást (NIR-HSI) és ANN-t alkalmazott egyedi kukoricaszemek keményítőtartalmának meghatározására. Long et al. (2025) hiperspektrális képalkotással és spektrális jellemzők feldolgozásával pontosította a keményítőtartalom-becslést. Zhang et al. (2022) figyelem-alapú kombinált konvolúciós neurális hálózatot (ACNNR) alkalmazott hiperspektrális képekre, olajtartalom-becslésnél $r^2 \approx 0,92$ eredménnyel.

Továbbá, az ANN-ek alkalmazhatók a növényi kultúrákban előforduló kártevők és betegségek felismerésére is. Az egészséges és fertőzött növények képein történő betanítással olyan rendszerek hozhatók létre, amelyek képesek pontosan azonosítani a fertőzött növényeket a szántóföldeken. Ez lehetővé teszi a gazdák számára a fertőzött növények gyors azonosítását és kezelését, csökkentve ezzel a termés kiesést és javítva a terméshozamot (Mohanty et al., 2016; Kumar, 2024).

Az öntözőrendszerek optimalizálása terén is hasznosíthatók az ANN-ek. Az időjárási minták, a talaj nedvességtartalma és a növények vízigénye alapján betanított ANN-ek képesek megjósolni az adott időpontban szükséges optimális vízmennyiséget egy adott szántóföldön. Ez elősegíti a víz hatékony felhasználását és csökkenti az öntözési költségeket (Azmat et al., 2023; Thakur et al., 2022).

A hibrid mesterséges neurális hálózatok egyre népszerűbbek a komplex, nemlineáris természeti folyamatok – például a folyók vízhozama vagy az agronómiai paraméterek – előrejelzésében. Wang et al. (2006) három típusú hibrid ANN-modell (TANN, CANN, PANN) teljesítményét hasonlította össze kínai folyók napi vízhozam előrejelzése során, és megállapították, hogy a szezonálisan strukturált PANN (periodic artificial neural network) modell eredményezte a legpontosabb előrejelzéseket.

2. táblázat: Példák a mesterséges neurális hálózatok (ANN) alkalmazási területeire a mezőgazdaságban

Módszer	Előre jelzett változó	Megjegyzés	Hivatkozás
ANN modellek távérzékelési eszközökkel	Terméshozam	A megfelelő változók kiválasztása jelentősen javítja az ANN-alapú terméshozam-előrejelzést.	Hara et al., 2021
ANN-alapú megközelítés	Hozam	Az ANN hatékonyan támogatja a termésbecslést.	Dahikar és Rode, 2014
ANN és regressziós modell összehasonlítása	Szezám-mag hozam	Az ANN pontosabb előrejelzést nyújtott, mint a hagyományos regresszió.	Emamgholizadeh et al., 2015
ANN + távérzékelte NDVI, vörös szél NDVI és SR-index	Kukorica és szójabab hozam	Az SR-index és a lejtési adatok a legerősebb előrejelzők mindkét kultúrában.	Kross et al., 2022
Felszíni regresszió és ANN kombinációja	Búzahozam	Az ANN regionális becslései jól illeszkedtek a valós adatokhoz, az RMSE az össztermés 7%-át tette ki.	Alvarez, 2009
ANN modell különböző feltételek között	Búzahozam	A modell $\pm 9\%$ -os hibahatárral ($\sim 0,89 \text{ t ha}^{-1}$) megbízható előrejelzést adott.	Safa et al., 2015
ANN modellezés regionális szinten	Kukoricahozam	A kiigazított R^2 értékek 0,67–0,86 között mozogtak, tartománytól függően, ami erős előrejelző képességre utal.	Adisa et al., 2019

Forrás: saját szerkesztés a megjelölt források alapján

A mesterséges neurális hálózatokat és más gépi tanulási algoritmusokat széles körben alkalmazták környezeti folyamatok, például erózió, szennyezés és aszály előrejelzésére világszerte. Például a többrétegű perceptron neurális hálózat (MLPNN) az egyik leggyakrabban használt modell a hidrológiai adatok előrejelzésére. Mishra és Desai (2006) az ARIMA/SARIMA modellek teljesítményét hasonlították össze különböző feed-forward neurális hálózati architektúrákkal az aszály (SPI) előrejelzésében, és eredményeik szerint a neurális hálózat alapú megközelítések rövid előrejelzési időtávon felülmúlták a klasszikus statisztikai módszereket.

Iránban Choubin és munkatársai (2016) MLP, ANFIS és többszörös lineáris regressziós modelleket alkalmaztak a csapadék előrejelzésére, és eredményeik szerint az MLP jobb

teljesítményt nyújtott. Emellett Gandhi és munkatársai (2016) mesterséges neurális hálózatokat használtak a rizs terméshozamának előrejelzésére, sikeresen demonstrálva az ANN-ek alkalmazhatóságát a mezőgazdasági előrejelzésekben. További példák az ANN-ek mezőgazdasági és környezeti változók előrejelzésére történő alkalmazására a 2. táblázatban található.

2.6.3. Az MLP modell

A Multilayer Perceptron (MLP), vagyis többrétegű perceptron modellek a gépi tanulás egyik legismertebb, és történetileg is az elsők között kutatott mesterséges neurális hálózat-típusát képviselik. Már az 1980-as évek végén, például az 1986-ban Rumelhart, Hinton és Williams által publikált tanulmányban bemutatták az MLP alapját jelentő visszaterjesztési (backpropagation) algoritmust, amely alapvető áttörést hozott az idegháló tanításában. Az MLP modellek többrétegű hálózatok, amelyekben a középső, úgynevezett rejtett rétegek meghatározó szerepet játszanak a tanulási képesség és az általánosító erő javításában. Az MLP képes univerzális közelítőként működni, vagyis elegendő egyetlen rejtett réteg ahhoz, hogy bármilyen folytonos függvényt tetszőleges pontossággal közelítsen, feltéve, hogy megfelelő számú rejtett egység áll rendelkezésre (Hornik et al., 1989).

Az MLP modellek a mesterséges neurális hálózatok első olyan képviselői közé tartoznak, amelyek széles körben alkalmazhatóvá váltak különféle problématerületeken, mint például mintafelismerés vagy összetett adatvezérelt függvények modellezése. A Rumelhart és munkatársai (1986) által ismertetett backpropagation algoritmus lehetővé tette az MLP számára, hogy a tanulási folyamat során folyamatosan csökkentse a hibát, a kimeneti és a kívánt célérték közötti különbség minimalizálásával. Ennek eredményeképpen a hálózat képes volt a bemeneti adatok rejtett mintázatait tükröző belső jellemzők kialakítására, ami jelentős előnyt biztosított számára az egyszerűbb modellekkel szemben az általánosítási képesség terén.

Az MLP modellek jelentősége abban áll, hogy ezek voltak az első olyan neurális hálózatok, amelyek képesek voltak komplex mintázatok és nemlineáris összefüggések felismerésére, mindezt visszacsatolás nélküli architektúrában. Az 1980-as évek kutatási eredményei – például Hornik és munkatársai munkája – szilárdan megalapozták azt az elméleti megállapítást, hogy az MLP hálózatok univerzális közelítőképességgel rendelkeznek, és

bármely mérhető függvény közelítésére alkalmasak, ha elegendő számú rejtett neuron áll rendelkezésre (Hornik et al., 1989; Zell et al. 1994). Ez a tulajdonság tette az MLP-t a mesterséges intelligencia és a gépi tanulás egyik alapvető építőelemévé, és a modell azóta is az egyik legszélesebb körben alkalmazott megközelítés maradt, különösen olyan területeken, mint a képfelismerés, beszéd felismerés vagy predikciós feladatok (Hosseini-Moghari et al. 2015). Ali et al. (2017) kutatásaik során az MLP-t modellt alkalmazták és megállapították, hogy a modell alkalmas az aszály előrejelzésére.

A kukoricatermesztésben az MLP egyre gyakrabban jelenik meg hozam- és beltartalmi paraméterek becslésében. Souza (2023) MLP-modellje, amely képes volt a hiányos adatsorok kezelésére is, RMSE = 71 kg ha⁻¹ hibával adott pontos hozambecslést. Maseko et al. (2023) kukorica hozam-előrejelzésnél több gépi tanulási modellt (MLP, RF, DT) hasonlítottak össze; az MLP stabil teljesítményt nyújtott különböző vetés- és tápanyag-kezelési környezetekben is. Galli et al. (2022) MLP-t alkalmazott genotípus- és fenotípusadatokon, automatizált hiperparaméter-optimalizálással, kukorica hibridek hozam- és növénymagasság-predikciójára, versenyképes eredményekkel a genomikus predikció hagyományos módszereivel szemben. Bár Sandhu et al. (2021) kutatása búzára irányult, MLP-modelljük egyszerre becsült hozamot és fehérjetartalmat, módszertani példát adva a kukorica beltartalmi összetevőinek predikciójához.

2.6.4. Az RBF modell

Az RBF modell, vagyis a radiális bázisfüggvényeken alapuló hálózat már a kezdetektől fogva jelentős figyelmet kapott a mesterséges neurális hálózatok kutatási területén. Az RBF hálózatok jelentőségét részletesen tárgyalják többek között Broomhead és Lowe (1988), valamint Park és Sandberg (1991) munkái is. A Broomhead és Lowe által készített, 1988-ban publikált tanulmány az elsők között vizsgálta az RBF modelleket adaptív hálózatként, rámutatva arra, hogy ezek a hálózatok alkalmasak többváltozós függvények interpolációjára. A tanulmány kiemelte, hogy az RBF hálózatok tanulása ekvivalens egy lineáris egyenletrendszer megoldásával, amely garantált konvergenciát biztosít. Ez a megközelítés jelentős előrelépést jelentett a nemlineáris összefüggések modellezésében, mivel lehetővé tette azok hatékony reprezentálását egy formálisan megalapozott tanulási szabály alkalmazásával. Az RBF modellek kiemelkedő jelentősége többek között abban rejlik, hogy

univerzális közelítőképességgel rendelkeznek – ahogy azt Park és Sandberg (1991) is bizonyította. Az RBF hálózatok egyetlen rejtett rétegben helyezik el a radiális bázisfüggvényeket, amelyek aktivációja a bemeneti adatok és a középpontjaik közötti távolságfüggő módon történik. Ennek az architektúrának az egyik fő előnye, hogy – ellentétben a hagyományos, többrétegű perceptronokkal – a tanulási folyamat lineáris algebrai optimalizálási feladatra redukálódik. Ez nemcsak gyorsabb, hanem stabilabb konvergenciát is eredményez, ami különösen értékes gyakorlati alkalmazások esetén. Az RBF hálózatok az 1980-as évek végén kezdtek elterjedni, különféle interpolációs és osztályozási problémák megoldására. Számos esetben az MLP hálózatokhoz képest előnyösebbnek bizonyultak, mivel egyszerűbb struktúrájuk mellett gyakran jobb általánosító képességet mutattak. Ez különösen olyan scénáriókban jelent előnyt, ahol a bemeneti és kimeneti adatok közötti kapcsolat komplex és nemlineáris, és ahol a perceptron-alapú megközelítések nem nyújtanak kielégítő teljesítményt. Összességében az RBF hálózatok jelentősége abban áll, hogy hatékony alternatívát kínálnak nemlineáris modellezési feladatok esetén, különösen akkor, ha az adatszerkezet összetett vagy nehezen kezelhető hagyományos módszerekkel. Az 1988-as úttörő kutatások – különösen Broomhead és Lowe munkája – megalapozták az RBF hálózatok széles körű alkalmazását. Ennek eredményeként napjainkra az RBF modellek a géptanulás és az adattudomány egyik alapvető eszközévé váltak, különösen az interpolációs és nemlineáris prediktív problémák kezelésében (Broomhead és Lowe, 1988).

A radiális bázisfüggvényű neurális hálózatok (RBFNN) a mezőgazdasági beltartalmi paraméterek becslésében is ígéretes módszernek bizonyultak. Jiang és Lu (2018) egy kombinált CC-PLSR-RBFNN modellt alkalmaztak közeli infravörös (NIR) spektroszkópiai adatokra, amely hatékonyan becsülte a kukoricaszemek keményítőtartalmát, kiemelve az RBF hálózatok jó illeszkedőképességét nemlineáris összefüggések esetében. Hasonló megközelítést alkalmaztak Xue et al. (2024), akik hiperspektrális adatok alapján több kukoricakomponens (pl. keményítő, fehérje, olaj) meghatározására fejlesztettek becslési modellt, és eredményeik szerint az RBF alapú hálózatok pontos és megbízható előrejelzést nyújtottak a különböző beltartalmi paraméterekre.

3. ANYAG ÉS MÓDSZER

3.1. Vizsgálati terület és kísérleti elrendezés

A kutatás alapjául szolgáló szántóföldi kukorica tartamkísérlet a Debreceni Egyetem Látóképi Növénytermesztési Kísérleti Telepén került beállításra. A kísérlet a Hajdúsági löszháton helyezkedik el, ideális helyszínt biztosít a komplex, többtényezős mezőgazdasági vizsgálatokhoz. A kísérlet helyszíne mészlepedékes csernozjom talajú terület, amely mély humusréteggel, jó vízmegtartó képességgel bír. Fizikai tulajdonságai alapján agyagos vályog (KA=42). A felső 20 cm-es réteg pHKCl értéke 6,6, ami közel semleges kémhatásnak felel meg, kedvező a tápanyagfelvétel szempontjából. A humusztartalom közepes (2,8%), a karbonátos réteg 100 cm mélységtől jelentkezik, így a talaj közepesen meszesnek minősíthető. A foszfor-ellátottság közepes (133 mg/kg), míg a káliumtartalom a közepes-jó tartományba esik (240 mg/kg), ami összességében kedvező termőképességet biztosít.

A kísérlet egy kétszeresen osztott parcellás (split-split-plot), polifaktoriális, háromismétléses, kisparcellás tartamkísérlet, amely lehetővé teszi nemcsak az egyes tényezők (talajművelés, műtrágyázás, öntözés) önálló hatásainak, hanem azok kölcsönhatásainak vizsgálatát is. A komplex talajművelési tartamkísérletet Prof. Dr. Nagy János alapította 1989-ben, jelenlegi parcella- és kezelés-összetételével 2015 óta működik. A parcellák elhelyezkedése és a három ismétlés biztosítják a statisztikailag értékelhető és reprodukálható eredményeket (3. ábra). A vizsgált évek 2017, 2018 és 2019 voltak. A vizsgált három év mindegyikében az alábbi korai, illetve középerésű kukorica hibridek kerültek bevonásra:

- Loupiac (FAO 380)
- Fornad (FAO 420)
- Armagnac (FAO 490)

Vizsgálataim eredményei a hibridek átlagában értendők, a kísérleti célkitűzés elsősorban az agrotechnikai tényezők (talajművelési mód, tápanyagellátás) és az évjárat hatások beltartalmi paraméterekre – különösen a keményítőtartalomra – gyakorolt hatásának feltárására irányult. Emiatt a statisztikai elemzések, majd a gépi tanulási módszerek alkalmazása során a hangsúly nem az egyes hibridek külön-külön történő értékelésén volt, hanem a teljes kísérlet eredményeinek értelmezésén.

öntözött parcellák adatait is figyelembe vettem, ezért ott évente összesen 432 parcella adatai szerepelnek.

3.2. Meteorológiai adatok


A klímaváltozás lokális hatásai egyre nagyobb jelentőséggel bírnak a hazai kukoricatermesztés szempontjából is. A kukoricatermesztés feltételeit alapvetően meghatározza a hőmérséklet és a csapadék éven belüli és évjáratok közötti ingadozása. A 4. ábra a 2017–2019 közötti időszak havi bontású adatai alapján mutatja a csapadék mennyiségének, valamint a minimum-, maximum- és átlaghőmérsékletnek az alakulását, míg az 5. ábra a vizsgált évek napi szintű hőtérképein keresztül mutatja be a hőmérsékleti viszonyokat.

A 2017-es év viszonylag kiegyensúlyozott éghajlati viszonyokat mutatott. Az éves átlaghőmérséklet 11,1 °C volt, míg a teljes évi csapadékmennyiség elérte az 569 mm-t, amely a három év közül a legmagasabb érték. A kukorica tenyészidőszakában (április–szeptember) összesen 242 mm csapadék hullott, amely aránylag egyenletes havi eloszlást mutatott (36–46 mm között), kedvező feltételeket biztosítva a növény fejlődéséhez. A hőmérsékleti viszonyok nem voltak szélsőségesek, a nyári hónapokban 21,6–23,2 °C közötti havi átlagértékekkel és 32–34 °C közötti napi maximumokkal. A hőtérkép alapján is jól látható, hogy a nyári hónapokban ugyan előfordultak meleg periódusok, de ezek nem voltak szélsőségesek.

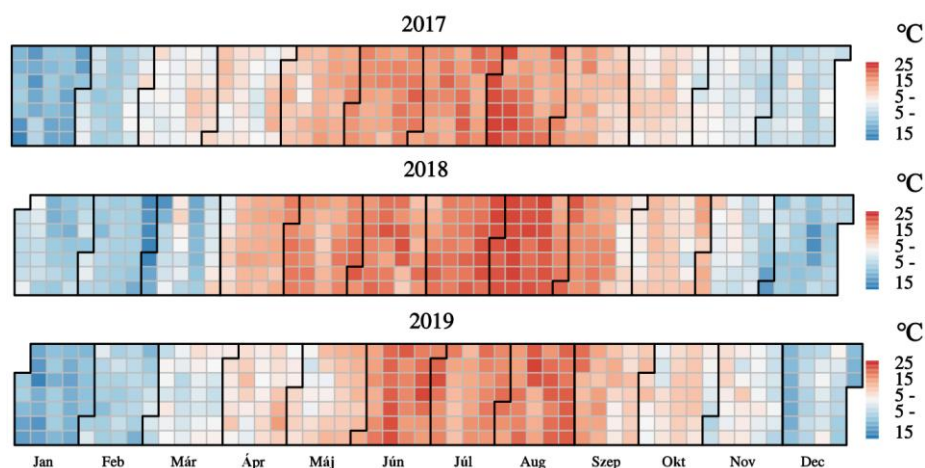
A 2018-as év melegebb volt az előző évnél, az éves átlaghőmérséklet 12,3 °C-ra emelkedett. A kukorica vegetációs időszakában több hónapban is 20 °C felett alakult a havi átlag (július: 22,4 °C; augusztus: 24,0 °C), és a melegedés hatása markánsan megjelenik a hőtérképen is. Ugyanakkor ez az év volt a legszárazabb mind éves szinten (435 mm), mind a tenyészidőszakban (230 mm). Különösen kritikus volt a július és augusztus, amikor csak 24 mm, illetve 17 mm csapadék hullott. A szárazságot csak részben kompenzálta a március és június csapadékmaximuma (72 mm és 79 mm), mivel ezek nem esnek egybe a kukorica fő vízigényes időszakaival. E körülmények fokozott vízhiányt és aszályos stresszt idézhetnek elő, ami a terméshozamok csökkenéséhez vezethetett.

2019 volt a három év közül a legmelegebb, 12,4 °C-os éves átlaggal, és számos hónapban 35 °C körüli napi maximumokkal. A nyári hónapok rendkívül melegek voltak, amit a hőtérkép

is alátámaszt: június, július és augusztus hónapokban kiterjedt és intenzív vörös színfoltok utalnak tartós hóhullámokra. Ennek ellenére csapadék tekintetében nem ez volt a legszárazabb év. Éves szinten 456 mm csapadék hullott, a tenyészidőszakban pedig 300 mm, amely meghaladta mind a 2017-es (242 mm), mind a 2018-as (230 mm) értéket. Következésképpen, a fokozott hőstressz ellenére, a megfelelő vízellátottság enyhítette a negatív hőmérsékleti hatásokat. A június (55 mm) és július (43 mm) hónapok mérsékelt csapadékosak voltak, de májusban például jelentős mennyiség hullott (93 mm), ami kedvezhetett a kezdeti fejlődési fázisnak.



4. ábra: Hőmérséklet- és csapadékadatok Debrecenben 2017 és 2019 között (https://www.ksh.hu/stadat_files/kor/en/kor0071.html)



5. ábra: A 2017-2019 évek hőmérsékletének alakulása napi szintű hőtérképeken (Forrás:www.met.hu)

3.3. A kukoricaminták elemzése

A 2017-2019-es időszakban begyűjtött kukoricaminták tápanyagtartalmának értékelése a Földhasznosítási, Technológiai és Területfejlesztési Intézetben található Foss Infratec™ 1241 Gabonaelemző (FITM) segítségével történt (6. ábra).

A FOSS Infratec™ 1241 egy transzmissziós közeli infravörös spektrofotométer (NIT), amelyet gabonafélék – például kukorica – beltartalmi értékeinek gyors, roncsolásmentes meghatározására fejlesztettek ki. A készülék működési elve azon alapul, hogy a 850–1048 nm közötti közeli infravörös (NIR) fény áthalad a mintán és az elnyelési spektrum alapján következtet az adott összetevők – például nedvesség, keményítő, fehérje és olaj – koncentrációjára. A spektrofotométer öt almintát mér automatikusan, és a mért adatok statisztikai kiértékelését az ISW 3.10 szoftver végzi, az eredményeket tömegszázalékban jelenítve meg.



6. ábra: A kukoricaminták keményítőtartalmának méréséhez használt FOSS Infratec 1241 készülék

3.4. Statisztikai elemzés

3.4.1. Leíró statisztikai elemzés, korrelációelemzés és többváltozós statisztikai vizsgálatok

Az adatelemzési folyamat során leíró statisztikai elemzést végeztem minden egyes vizsgált év (2017-2019) esetén. Ennek során meghatároztam a vizsgált változók alapvető leíró statisztikai paramétereit.

A leíró statisztikai elemzéssel egyszerre, éves bontásban, majd a három év összesített adataira vonatkozóan is korrelációs mátrixokat készítettem, hogy feltérképezsem a különböző változók közötti összefüggéseket. A számított korrelációs együtthatók lehetővé tették a páros változók kapcsolatának irányának és erősségének értékelését, ezáltal segítve annak megértését, hogy egy adott tényező változása milyen hatással van a keményítőtartalom alakulására.

A többváltozós elemzések során főkomponens-elemzést (PCA) alkalmaztam, amely lehetőséget biztosított az adathalmaz változószámának csökkentésére, miközben megőrizte a változók közötti variancia legnagyobb részét. A módszer különösen hasznos olyan komplex agronómiai rendszerek esetén, ahol számos egymással összefüggő változó befolyásolja az eredményeket, és cél a leginformatívabb komponensek kiválasztása (Jolliffe és Cadima, 2016).

3.4.2. Varianciaanalízis (ANOVA) és legkisebb szignifikáns különbség (LSD) vizsgálatok

A feltételezett összefüggések statisztikai szignifikanciájának ellenőrzése érdekében varianciaanalízist (ANOVA) végeztem Huzsvai és Balogh (2015) módszertanát követve. Az ANOVA hatékony eszközt biztosított az egyes vizsgálati tényezők hatásának értékelésére, lehetővé téve annak megállapítását, hogy a különböző kezelések közötti eltérések statisztikailag szignifikánsak-e. Az ANOVA eredményeinek részletesebb vizsgálatához a legkisebb szignifikáns különbség (Least Significant Difference, LSD) tesztet alkalmaztam, amely lehetőséget biztosított a többszörös összehasonlítások elvégzésére. Ezzel a módszerrel pontosan meghatározhatóvá vált, hogy mely kezelések közötti különbségek bizonyultak

statisztikailag szignifikánsnak, ami hozzájárult a keményítőtartalom alakulását befolyásoló legfontosabb tényezők azonosításához. Ezt az elemzést az RStudio segítségével végeztem.

3.5. A keményítőhozam előrejelzése ANN-algoritmusok alapján

A mezőgazdasági adatfeldolgozás során gépi tanulási technikákat alkalmaztam a szántóföldi kísérletekből származó keményítőtartalom-értékek elemzésére. A vizsgálathoz mesterséges neurális hálózati modelleket (ANN) használtam, amelyek segítségével megvizsgáltam a különböző agronómiai és környezeti tényezők hatását a keményítőtartalom alakulására, négy különböző forgatókönyv szerint. Fontos megjegyezni, hogy az ANN vizsgálatokhoz ugyanazon évek, ugyanazon vizsgálati helyszíneiről származó adatsorokat használtam fel, azonban több változó bevonásával. Ennek oka annak az alapfeltételezésnek a vizsgálati igénye, hogy a gépi tanulási modellek hatékony működése a bemeneti változók számának növelésével szavatolható. Emiatt jelennek meg a változók között az olajtartalom, a fehérjetartalom és –hozam, a hl-tömeg és a betakarításkori nedvességtartalom. Ettől függetlenül a vizsgálatok középpontjában továbbra is a keményítőtartalom áll. Emellett, míg a hagyományos vizsgálatok esetében csak az öntözetlen parcellák adatait használtam fel, az ANN vizsgálatokhoz az öntözött parcellák adatait is, egyrészt a fent leírt adatigény miatt, másrészt pedig mert a hagyományos elemzés évjáráthatás elemzése esetén torzította volna a meteorológia paraméterek hatását az öntözés.

3.5.1. Elemzési célok és módszerek

A kutatás célja az volt, hogy feltárjam a keményítőtartalom alakulását befolyásoló változók közötti rejtett összefüggéseket, valamint meghatározzam azt a modellt, amely a legjobb becslést adja a keményítőtartalom értékére. Az adatok feldolgozásához az SPSS 29.0.0.0 statisztikai szoftvert „Neural Networks” modulját használtam, amely lehetőséget biztosított a különböző gépi tanulási algoritmusok összehasonlítására.

3.5.2. Forgatókönyvek és modellezés

A vizsgálat során négy eltérő forgatókönyvet dolgoztam ki, amelyek különböző módon kombinálták a bemeneti változókat. Ezeket a forgatókönyveket egymástól függetlenül elemeztem a MLP és RBF modellek segítségével. Minden forgatókönyv esetében a vizsgált változókat bemeneti (input) adatokként adtam meg a modell számára, míg a

keményítőtartalom kimeneti (output) változóként szerepelt. A hálózat rejtett rétegei (hidden layers) az emberi neuronhálózatokhoz hasonló módon igyekeztek azonosítani a változók közötti mintázatokat és optimalizálni az előrejelzéseket.

A modell a betanítás során az adatok 70%-át tanulásra, míg 30%-át tesztelésre használta fel. Az előrejelzések pontosságát a tesztelési eredmények segítségével értékeltem, amely alapján megállapíthatóvá vált az egyes forgatókönyvek hatékonysága.

A keményítőtartalom előrejelzésére két különböző neurális hálózati modellt alkalmaztam:

1. Többrétegű perceptron (MLP) – amely képes a nemlineáris összefüggések azonosítására, és többszintű feldolgozással pontos predikciót ad.
2. Radiális bázisfüggvény-hálózat (RBF) – amely gyorsabb tanulási sebessége miatt hatékonyabban kezelte a nagyobb adathalmazokat.

A modellek segítségével feltártam, hogy mely tényezők befolyásolják leginkább a keményítőtartalom alakulását a különböző forgatókönyvek szerint. Az egyes modellek előrejelzéseit összehasonlítva értékeltem, hogy melyik algoritmus nyújt pontosabb becslést az adott szituációban. Az előrejelzési eredményeket grafikonokon keresztül szemléltettem, amelyek segítettek feltárni a bemeneti változók és a keményítőtartalom közötti kapcsolatokat. A vizuális megjelenítés révén jobban megérthetővé vált, hogy mely tényezők gyakorolnak meghatározó hatást a keményítőtartalomra az egyes forgatókönyvek szerint. A gépi tanulási módszerek alkalmazása lehetőséget biztosított a hagyományos statisztikai elemzéseknél mélyebb és pontosabb összefüggések feltárására, amely hozzájárulhat a szántóföldi kísérletek során kapott adatok hatékonyabb értékeléséhez és a termesztési döntések optimalizálásához.

3.5.3. A gépi tanulás révén végzett elemzéshez felhasznált scenáriók összetételének bemutatása

A kutatásban négy különböző scenáriót állítottam össze a gépi tanulási modellek számára. Ezek a scenáriók különböző mezőgazdasági változókat és agronómiai adatokat használtak bemeneti változóként, amelyek várhatóan hatással vannak a kukorica keményítőtartalmára

és hozamára. A scenáriók összetételét a 3. táblázat foglalja össze, a 7. ábra pedig grafikusán ábrázolja az egyes forgatókönyvekben szereplő változókat és azok összefüggéseit.

3. táblázat: A gépi tanulási elemzéshez összeállított scenáriók összetétele

Szenárió	Bevont változók	Rövid indoklás
SC1	Talajművelés, öntözés, tápanyagkezelések, hozam, olajtartalom, fehérjetartalom, nedvességtartalom	A talajművelés, öntözés és tápanyagellátottság közvetlenül befolyásolja a kukorica növekedését, a hozamot és a beltartalmat. Egyéb változókkal együtt szerepeltetve átfogó képet nyújt ez az összetétel.
SC2	Évjárat, hozam, fehérjetartalom, nedvességtartalom	A scenárió célja az időjárási és évjárat paraméterek szerepének feltárása volt, néhány egyéb változó bevonása mellett.
SC3	Évjárat, tápanyag, termés, olajtartalom, fehérjetartalom, hl-tömeg, fehérjehozam, keményítőhozam	A tápanyagellátás, hozam és minőségi mutatók (fehérje-, olaj-, és hl-tömeg) közötti összefüggéseket vizsgálja.
SC4	Évjárat, tápanyagkezelések, talajművelés, öntözés, hozam, olajtartalom, fehérjetartalom, hl-tömeg, fehérjehozam, nedvességtartalom, keményítőhozam	A komplex modell ötvözi az évjárat hatásokat, az agrotechnikai tényezőket és a beltartalmi paramétereket. A cél a teljes rendszer dinamikájának feltárása és a keményítőtartalom pontos előrejelzése.

Forrás: saját szerkesztés

Az alábbiakban bemutatom a négy scenárió összetételét és összeállításuk indokait:


SC1 scenárió: Ez a viszonylag átfogó scenárió a termesztéstechnológiai tényezők, a beltartalmi paraméterek és a terméshozam közötti kapcsolatra összpontosított. A bemeneti változók között szerepeltek a talajművelés, az öntözés, a tápanyagkezelések, a hozam, az olajtartalom, a fehérjetartalom és a nedvességtartalom.

SC2 scenárió: Ebben a szűkebb scenárióban az évjárat hatások és a terméshozam mellett korlátozott számú beltartalmi mutató szerepelt. A bemeneti változók közé tartozott az évjárat, a hozam, a fehérjetartalom és a nedvességtartalom.

SC3 scenárió: Ez a scenárió a termés és minőségi mutatók közötti összefüggéseket vizsgálta. A bemeneti változók között szerepeltek az évjárat, a tápanyag, a termés, az olajtartalom, a fehérjetartalom, a hl-tömeg, a fehérjehozam és a keményítőhozam. Ebben a

szintén átfogóbb forgatókönyvben egyszerre szerepelnek a keményítőre és fehérjére vonatkozó %-os és hozam adatok is.

SC4 scenárió: A negyedik scenárió a teljes agrotechnikai rendszer dinamikáját vizsgálta, amely magában foglalta az összes lehetséges változót, azaz az évjárat hatásokat, az agrotechnikai kezeléseket és a beltartalmi paramétereket. A bemeneti változók közé tartozott az évjárat, a tápanyagkezelések, a talajművelés, az öntözés, a hozam, az olajtartalom, a fehérjetartalom, a hl-tömeg, a fehérjehozam, a keményítőhozam és a nedvességtartalom. A cél a teljes rendszer átfogó elemzése volt.



7. ábra: A létrehozott scenáriók összetételének grafikus ábrázolása

Az elemzés az SPSS 29.0.0.0 szoftvercsomag „Analyze” funkciójából elérhető „Neural Networks” (neurális hálók) modul segítségével történt az alábbi lépések szerint:

- Először megtörtént az adatok ellenőrzése, rendszerezése, az adatsorok pontos megnevezése, kategorizálása, majd felvitele a szoftver adatkezelő moduljába.
- A kategorizálás során a különböző inputváltozókat jellegüknek megfelelő kategóriákba soroltam. Az alaphelyzetben is numerikus kategóriába tartozó, mért adatsorokhoz igazodva az opcionális vagy kategóriás (3 évjárat, 3 talajművelési mód, 3 tápanyagkezelési kezelés, öntözött/nem öntözött) változók esetében is numerikus változókká alakítottam az egyes parcellák vonatkozó adatait. A változók paramétereit a 4. táblázat tartalmazza. A tápanyagkezelések kivételével minden numerikusan kódolt kategóriás változó esetében a nominális kategóriát választottam, míg a tápanyagkezelés ordinális változóként szerepelt. Ennek oka, hogy az évjárat, a talajművelés és az öntözés kategóriái között nincs értelmezhető sorrendiség, így ezek csak megkülönböztetésre szolgálnak. A tápanyagkezelések esetében azonban a szintek között természetes sorrendiség áll fenn (kontroll < alacsonyabb dózis < magasabb dózis), ezért indokolt volt az ordinális mérési szint alkalmazása.
- Minden egyes változó szerepe inputként lett megjelölve, a vizsgálandó keményítőtartalom célváltozóként szerepelt.
- A forgatókönyvek futtatása egyenként történt, előbb az MLP, majd az RBF modellel. Az egyes modellek megnevezése a [modelltípus]_[szcenárió száma] alapján történt, azaz pl. MLP_SC1.
- Az adott forgatókönyv futtatása során a mért adatok kovariánsként, az opcionális adatok faktorként, míg a keményítőtartalom minden esetben függő változóként kerültek bevonásra.
- Az alapbeállítás szerint a szoftver az inputadatok 70%-át az algoritmusok betanítására és paramétereik finomhangolására használta, míg a fennmaradó 30%-ot a modellek előrejelző képességének tesztelésére
- Minden egyes futtatást (2 modell x 4-4 szcenárió, azaz összesen 8 db) követően a szoftver egy-egy becsült adatsort generált a keményítőtartalomra vonatkozóan.

4. táblázat: A bevont változók paramétereinek bemutatása

Változó neve	Adattípus	Mérési szint	Mértékegység	Minimum	Maximum	Átlag	Lehetséges értékek	Megjegyzés
Évjárat	Numerikusan kódolt kategóriás	Nominális	–	2017	2019	–	2017, 2018, 2019	A kísérlet éve
Talajművelés	Numerikusan kódolt kategóriás	Nominális	–	1	3	–	1=őszi szántás, 2=sávós művelés, 3=lazítás	Alkalmazott talajművelési mód
Öntözés	Numerikusan kódolt kategóriás	Nominális	–	1	2	–	1=öntözött, 2=nem öntözött	Öntözési kezelés típusa
Tápanyagkezelés	Numerikusan kódolt kategóriás	Ordinális	–	1	3	–	1=kontroll, 2=N 80 – P ₂ O ₅ 60 – K ₂ O 90 kg ha ⁻¹ , 3=N 160, P ₂ O ₅ 60, K ₂ O 90 kg ha ⁻¹	Tápanyagkezelés típusa
Terméshozam	Numerikus	Mennyiségi	t ha ⁻¹	2,3	14,04	9,21	mért értékek	Betakarított szemtermés mennyisége
Olajtartalom	Numerikus	Mennyiségi	%	1	4,9	4,03	mért értékek	Szemek olajtartalma
Fehérjetartalom	Numerikus	Mennyiségi	%	5,2	10,3	7,56	mért értékek	Szemek fehérjetartalma
Nedvességtartalom	Numerikus	Mennyiségi	%	11,1	18,5	13,91	mért értékek	Betakarításkori szemnedvesség
HL-tömeg	Numerikus	Mennyiségi	kg hl ⁻¹	65	78,8	73,37	mért értékek	Hektolitertömeg
Keményítőhozam	Numerikus	Mennyiségi	t ha ⁻¹	1,44	8,94	5,83	mért értékek	Keményítőtartalom * terméshozam
Fehérjehozam	Numerikus	Mennyiségi	t ha ⁻¹	0,16	1,19	0,71	mért értékek	Fehérjetartalom * terméshozam
Keményítőtartalom	Numerikus	Mennyiségi	%	55,8	68,4	63,51	mért értékek	Becsült célváltozó

3.5.4. A gépi tanulási modellek teljesítményének statisztikai értékelése

A modellek futtatását követően a szoftver értékelte a predikciós hatékonyságot és mind a tanítási, mind a tesztelési fázisra vonatkozóan megadta az adott szcenárió négyzetes hiba (sum of squares error – SSE) összegét és a relatív hibát (Relative Error – RE), amelyek alapján elvégezhető volt az elsődleges rangsorolás. A pontosabb eredmény érdekében azonban további mutatókat is alkalmaztam: Nash-Sutcliffe-hatékonyság (NSE), Pearson-féle korrelációs együttható (r), determinációs együttható (r^2) négyzetes középeltérés (RMSD), átlagos abszolút hiba (MAE) és átlagos abszolút százalékos hiba (MAPE). Ezek a mutatók átfogó értékelést adtak a modellek teljesítményéről, figyelembe véve mind a pontosságot, mind az előrejelzések megbízhatóságát (Harsányi et al. 2023).

Nash-Sutcliffe hatékonyság (NSE):

Ezt a mérőszámot általában a hidrológiai modellezésben használják, de más területeken is alkalmazható (Nash és Sutcliffe, 1970). Az NSE a reziduális variancia relatív nagyságát értékeli a mért adatok varianciájához képest. Az 1-es NSE érték tökéletes illeszkedést jelez, míg a 0-nál kisebb NSE érték azt jelenti, hogy a megfigyelt átlagérték jobb előrejelző, mint a modell kimenete.

Pearson-féle korrelációs együttható (r):

Ez a megfigyelt és az előre jelzett értékek közötti lineáris korreláció mértéke. Az 1 közeli r -érték erős pozitív lineáris kapcsolatot, míg a -1 közeli érték erős negatív kapcsolatot jelent (Pearson, 1896).

Determinációs együttható (r^2):

Ez az érték a függő változó varianciájának a független változó(k) által előre jelezhető arányát jelenti. Egy 1 közeli r^2 -érték azt jelenti, hogy a modell a kimenetel változékonyságának nagy részét figyelembe veszi.

Négyzetes középeltérés (RMSD):

Ez az érték az előrejelzési hiba átlagos nagyságát számítja ki. Az alacsonyabb RMSD-érték azt jelenti, hogy a modell jobban illeszkedik az adatokhoz.

Átlagos abszolút hiba (MAE):

Az MAE a megfigyelt és előre jelzett értékek közötti abszolút eltérések átlagát mutatja. Minél alacsonyabb az MAE érték, annál pontosabb a modell előrejelzése.

Átlagos abszolút százalékos hiba (MAPE):

A MAPE a relatív hibát százalékban fejezi ki, vagyis azt mutatja meg, hogy a modell átlagosan hány százalékkal tér el a valós megfigyelésektől.

Az SPSS elemzések eredményeként a szoftver minden egyes scenárió esetében megállapította a bevont input változók normalizált fontosságát, azaz rangsorolta, hogy adott forgatókönyv esetében mely változók hatása ítéhető a legjelentősebbnek. A kapott eredményeket Voronoi-diagramon ábrázoltam.

A fentieket követően a modellek teljesítményének grafikus ábrázolásához Taylor-diagramot alkalmaztam (Taylor, 2001). Ez a diagram a korrelációs, az RMSD és a szórásstatisztikák kombinációját mutatja be egyetlen ábrán, így átfogó képet ad a modellek előrejelző képességéről (Harsányi et al. 2023).

4. EREDMÉNYEK

4.1. A felhasznált adatbázis tulajdonságainak áttekintése

A három év során mért adatok értékelését leíró statisztikai elemzéssel kezdtem, amely lehetőséget biztosított az egyes paraméterek eloszlásának, alakulásának és változékonyságának részletes vizsgálatára. A kutatás során a kísérlet statisztikailag értékelhető, kvantitatív eredményeit és minőségi paramétereit mindhárom vizsgált évre (2017, 2018, 2019) vonatkozóan elemeztem.

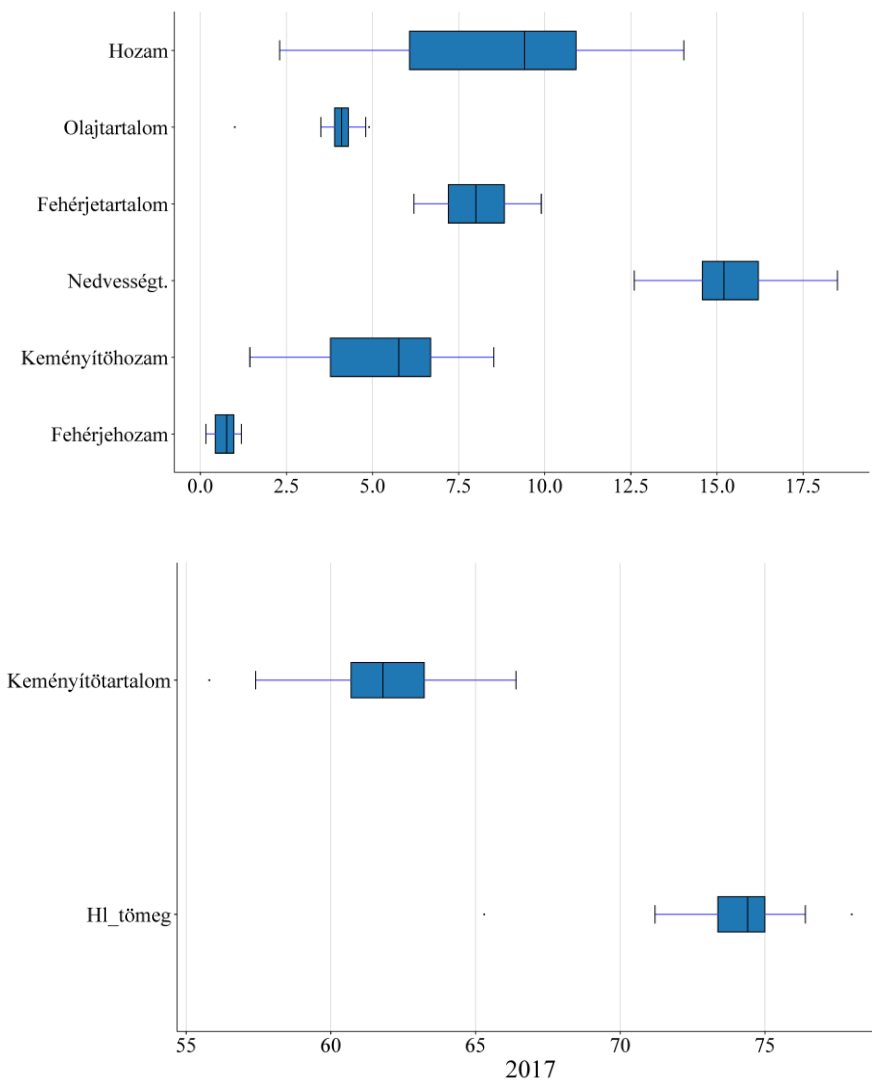
4.1.1. A bevont változók leíró statisztikai elemzése a 2017-es évre vonatkozóan

5. táblázat Leíró statisztika adatai a 2017-es évre vonatkozóan

	Termés hozam (t ha ⁻¹)	Olaj tartalom (%)	Fehérje tartalom (%)	Nedvesség tartalom (%)	Keményítő tartalom (%)	Hl-tömeg (kg hl ⁻¹)	Keményítő hozam (t ha ⁻¹)	Fehérje hozam (t ha ⁻¹)
Elemszám	216	216	216	216	216	216	216	216
Minimum	2,30	1,00	6,20	12,60	55,80	65,30	1,44	0,16
Maximum	14,04	4,90	9,90	18,50	66,40	78,00	8,52	1,19
Átlag	8,77	4,11	8,02	15,41	61,83	74,14	5,39	0,72
Szórás	2,78	0,41	0,94	1,17	1,88	1,31	1,65	0,28
Ferdeség	-0,32	-3,75	0,00	0,57	-0,31	-1,58	-0,32	-0,17
Kurtózis	-1,03	28,12	-1,28	-0,19	0,09	8,63	-0,96	-1,31

A 2017-es évben a kukorica terméshozama jelentős változékonyságot mutatott, átlagosan 8,77 t ha⁻¹ értékkel, 2,30 és 14,04 t ha⁻¹ közötti tartományban. A hozamok eloszlása enyhén balra ferde (-0,32), ami arra utal, hogy a magasabb hozamok kissé gyakoribbak voltak. Az olajtartalom viszonylag stabil volt, 4,11%-os átlaggal és alacsony szórással (0,41%), ugyanakkor az erősen negatív ferdeség (-3,75) és a kiugróan magas kurtózis (28,12) azt jelenti, hogy néhány alacsony érték torzította az eloszlást. A fehérjetartalom átlagosan 8,02% volt, mérsékelt szórással (0,94%), az eloszlás szimmetrikus (ferdeség: 0,00), de laposabb a normálisnál (kurtózis: -1,28). A nedvességtartalom 15,41% átlagértéket mutatott, enyhe pozitív ferdeséggel (0,57), tehát a magasabb nedvességtartalmú minták kissé gyakoribbak voltak. A keményítőtartalom 61,83%-os átlaggal és mérsékelt szórással (1,88%) viszonylag homogénnek bizonyult, az eloszlás enyhén balra ferde (-0,31). A hl-tömeg 74,14 kg hl⁻¹ átlaggal és alacsony szórással (1,31) jellemezhető, eloszlása azonban erősen negatív ferdeséget (-1,58) és kiugróan magas kurtózist (8,63) mutatott. A keményítőhozam átlagosan

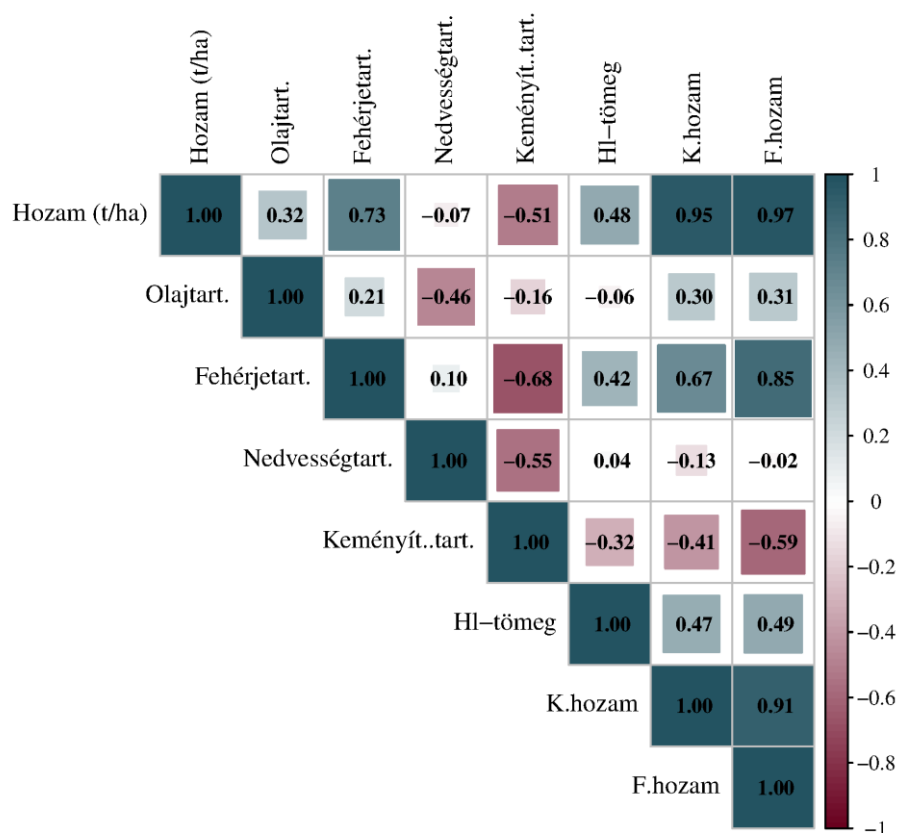
5,39 t ha⁻¹, míg a fehérjehozam 0,72 t ha⁻¹ volt; mindkét mutató viszonylag mérsékelt variabilitást mutatott (szórás: 1,65 és 0,28), az eloszlás enyhén negatív ferdesége a magasabb hozamértékek gyakoribb előfordulására utal. Összességében a 2017-es év terméseredményei kiegyensúlyozottak voltak, különösen a fehérje- és keményítőtartalom tekintetében, ugyanakkor az olajtartalom eloszlása szélsőségesnek bizonyult, míg a hl-tömeg kiugró értékei a mintán belüli heterogenitást jelzik (5. táblázat).



8. ábra A változók leíró statisztikai eredményeit ábrázoló boxplot diagramok (2017)

Az eredmények eloszlását szemléltető 8. ábra boxplotjai jól illusztrálják a leírt tendenciákat. Jól látható a terméshozam és a keményítőhozam nagyobb variabilitása, az olajtartalom

szélsőséges eloszlása az alacsony értékek kiugrásával, valamint a hl-tömeg erősen negatív ferdesége és több kiugró értéke. A fehérje- és keményítőtartalom eloszlása ezzel szemben kiegyensúlyozottabb képet mutat, összhangban a statisztikai jellemzőkkel. A keményítőtartalom és a hl-tömeg külön ábrán történő szerepeltetése azért indokolt, mert értékeik eltérő nagyságrendje miatt a közös ábrázolás nem tette volna láthatóvá az alacsonyabb mérőszámú változók részletes eloszlásbeli különbségeit. A 9. ábra a különböző agronómiai és beltartalmi paraméterek közötti Spearman-féle korrelációs együtthatókat mutatja be. A terméshozam ($t\ ha^{-1}$) és a keményítőhozam között erős pozitív korreláció figyelhető meg ($p = 0,95$), azaz a magasabb terméshozam jelentősen növeli a keményítőhozamot. Hasonlóan szoros pozitív kapcsolat áll fenn a terméshozam és a fehérjehozam között is ($p = 0,97$). A fehérjetartalom és a terméshozam között is erős pozitív korreláció mutatkozik ($p = 0,73$), míg a keményítőtartalom és a terméshozam között mérsékelt negatív kapcsolat látható ($p = -0,51$).



9. ábra A vizsgált paraméterek összefüggéseit vizsgáló Spearman korrelációs mátrix (2017)

4.1.2. A bevont változók leíró statisztikai elemzése a 2018-as évre vonatkozóan

A 6. táblázat a 2018-as év változóira vonatkozó statisztikai eredményeket mutatja be az előző évvel megegyező szerkezetben.

6. táblázat Leíró statisztika a 2018-as évre vonatkozóan

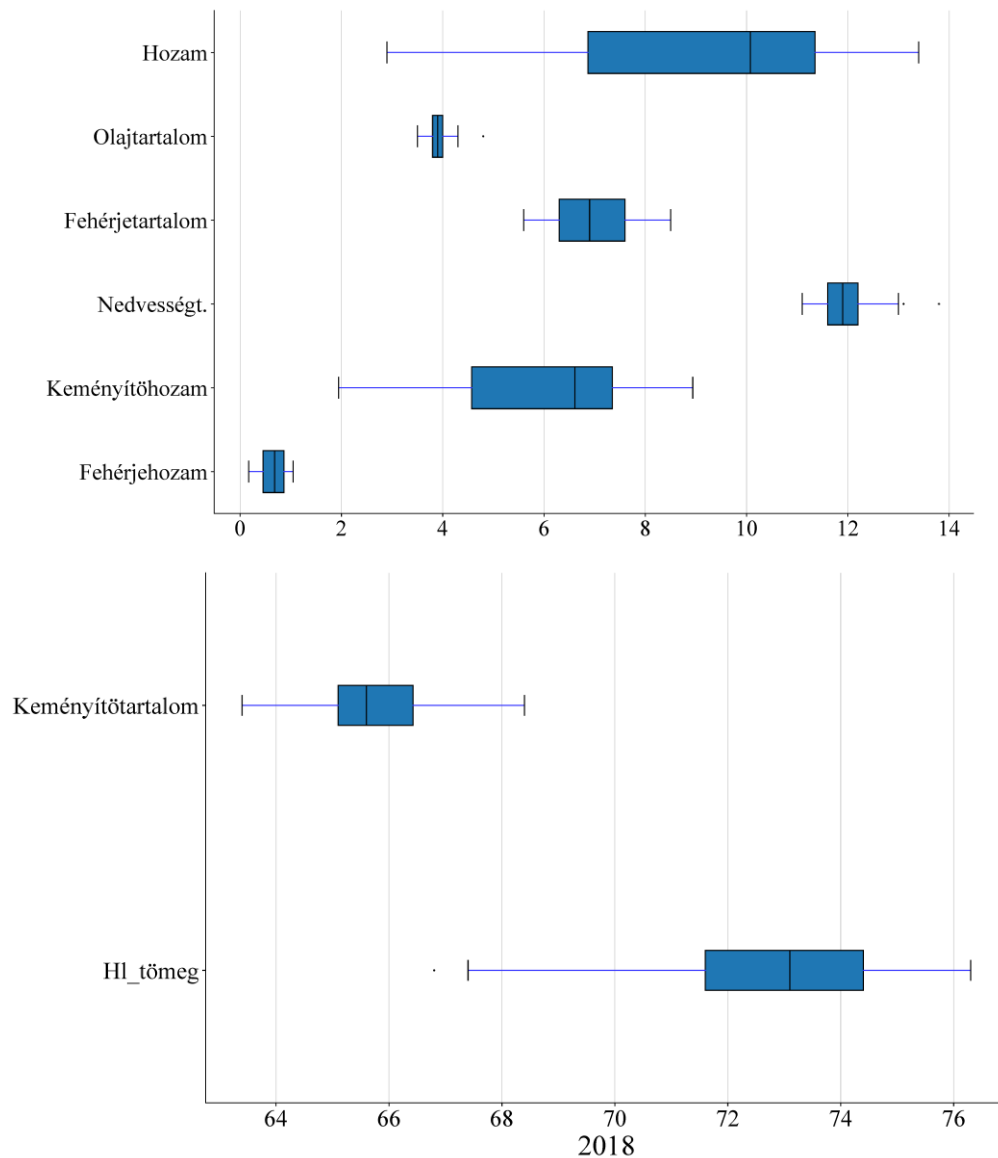
	Termés hozam (t ha ⁻¹)	Olaj tartalom (%)	Fehérje tartalom (%)	Nedvesség tartalom (%)	Keményítő tartalom (%)	Hl-tömeg (kg hl ⁻¹)	Keményítő hozam (t ha ⁻¹)	Fehérje hozam (t ha ⁻¹)
Elemzés	216	216	216	216	216	216	216	216
Minimum	2,90	3,50	5,60	11,10	63,40	66,80	1,94	0,17
Maximum	13,40	4,80	8,50	13,80	68,40	76,30	8,94	1,05
Átlag	9,27	3,90	6,96	11,93	65,76	72,68	6,08	0,66
Szórás	2,65	0,16	0,73	0,44	1,08	2,10	1,70	0,23
Ferdeség	-0,54	0,97	0,25	0,61	0,30	-0,79	-0,57	-0,27
Kurtózis	-0,86	4,58	-1,05	0,65	-0,25	-0,14	-0,81	-1,18

Az elemzés az előző évhez hasonlóan 216 minta alapján készült, és átfogó képet ad a hozamról, az olaj-, fehérje-, nedvesség- és keményítőtartalomról, valamint a hl-tömegről, a keményítőhozamról és a fehérjehozamról.

A terméshozam 2,90 és 13,40 t ha⁻¹ között változott, átlagosan 9,27 t ha⁻¹ értékkel. Az eloszlás enyhén balra ferde, tehát a nagyobb hozamok valamivel gyakoribbak voltak. Az olajtartalom viszonylag stabilnak bizonyult, 3,50% és 4,80% között alakult, az átlag 3,90% volt. Az eloszlás enyhe pozitív ferdeséget mutatott, vagyis az alacsonyabb értékek gyakrabban fordultak elő. A fehérjetartalom 5,60% és 8,50% között mozgott, az átlag 6,96% volt, ami kiegyensúlyozott eloszlásra utal. A nedvességtartalom átlagosan 11,93% volt, enyhe jobbra ferdeséggel, vagyis a magasabb nedvességtartalmú minták némileg gyakoribbak voltak. A keményítőtartalom viszonylag stabil maradt, 63,40% és 68,40% között alakult, az átlag 65,76%, enyhe pozitív ferdeséggel.

A hl-tömeg átlagosan 72,68 kg hl⁻¹ volt, de az eloszlás enyhén balra tolódott, ennek alapján a nagyobb hl-tömeg gyakrabban fordult elő. A keményítőhozam 1,94 és 8,94 t ha⁻¹ között mozgott, átlagosan 6,08 t ha⁻¹, szintén enyhén balra ferde eloszlással. A fehérjehozam átlaga 0,66 t ha⁻¹ volt, az értékek 0,17 és 1,05 t ha⁻¹ között ingadoztak, enyhe balra tolódással.

A 10. ábra az eredményekre vonatkozó boxplot diagramokat mutatja be.



10. ábra: A változók leíró statisztikai eredményeit ábrázoló boxplot diagramok (2018)

A 2018-as évben a terméshozam és a keményítőtartalom emelkedett, miközben a fehérjetartalom és a betakarításkori nedvességtartalom csökkent, az olajtartalom eloszlása kiegyensúlyozottabbá vált, a hl-tömeg pedig alacsonyabb átlagot, de szélesebb szóródást mutatott, ami mind a statisztikai jellemzőkben, mind a boxplotokon egyértelműen megfigyelhető.

A 11. ábra a vizsgált agronómiai és beltartalmi paraméterek közötti korrelációs kapcsolatokat mutatja be a 2018-as évre vonatkozóan. A terméshozam ($t\ ha^{-1}$) és a fehérjehozam között rendkívül erős, pozitív korreláció figyelhető meg ($p = 0,97$), tehát a magasabb terméshozam

szinte mindig magasabb fehérjehozammal jár együtt. Hasonlóan erős pozitív összefüggés figyelhető meg a terméshozam és a keményítőhozam között ($p = 0,97$), jelezve, hogy a nagyobb hozam egyúttal több keményítő előállításával is párosul.

A keményítőtartalom és a fehérjetartalom között erős negatív korreláció figyelhető meg ($p = -0,59$), azaz a magasabb fehérjetartalommal rendelkező minták a 2018-as év során is alacsonyabb keményítőtartalommal rendelkeznek. A hl-tömeg és a fehérjetartalom között viszont erős pozitív korreláció található ($p = 0,77$), ami azt sugallja, hogy a magasabb hektoliter tömegű szemek általában magasabb fehérjetartalommal rendelkeznek. Végül, az olajtartalom és a keményítőtartalom között negatív korreláció figyelhető meg ($p = -0,38$).



11. ábra A vizsgált paraméterek összefüggéseit vizsgáló Spearman korrelációs mátrix (2018)

4.1.3. A bevont változók leíró statisztikai elemzése a 2019-es évre vonatkozóan

A 7. táblázat a 2019-es évre vonatkozóan mutatja be a vizsgált változók leíró statisztikai paramétereit.

7. táblázat. Leíró statisztika a 2019-es évre vonatkozóan


	Termés hozam (t ha ⁻¹)	Olaj tartalom (%)	Fehérje tartalom (%)	Nedvesség tartalom (%)	Keményítő tartalom (%)	Hl-tömeg (kg hl ⁻¹)	Keményítő hozam (t ha ⁻¹)	Fehérje hozam (t ha ⁻¹)
Elemzés	216	216	216	216	216	216	216	216
Minimum	4,82	3,50	5,20	12,60	59,70	65,00	3,10	0,29
Maximum	13,13	4,70	10,30	18,00	66,20	78,80	8,27	1,14
Átlag	9,58	4,07	7,69	14,38	62,93	73,30	6,02	0,75
Szórás	1,96	0,21	1,00	0,50	1,32	2,02	1,19	0,21
Ferdeség	-0,37	-0,86	0,14	1,54	0,28	-1,09	-0,36	-0,21
Kurtózis	-0,91	1,69	-0,73	12,78	-0,37	2,65	-0,90	-1,13

A 2019-es év adatai alapján a terméshozam (t ha⁻¹) értékei 4,82 és 13,13 t ha⁻¹ között változtak, az átlagos terméshozam 9,58 t ha⁻¹ volt (ebben az évben a legmagasabb), enyhén negatív ferdeséggel (-0,37), ami a magasabb hozamok felé történő eltolódást jelez. Az olajtartalom viszonylag stabil (átlag: 4,07%), kis szórással (0,21), enyhén negatív ferdeséggel (-0,86), ami a magasabb olajtartalmú értékek dominanciájára utal. A fehérjetartalom mérsékelt változatosságot mutatott (5,20% - 10,30%), átlagosan 7,69%-kal, kis ferdeséggel (0,14), ami közel szimmetrikus eloszlást jelez. A nedvességtartalom átlagosan 14,38% volt, de szélesebb tartományban mozgott (12,60% - 18,00%), és erősen pozitív ferdeséget (1,54) mutatott, ami több alacsony nedvességtartalmú minta jelenlétét jelzi. A keményítőtartalom viszonylag kiegyensúlyozott (átlag: 62,93%), enyhén pozitív ferdeséggel (0,28). A hl-tömeg stabil, átlagosan 73,30 kg hl⁻¹, de enyhén negatív ferdeséggel (-1,09), ami a magasabb hl-tömegű értékek túlsúlyát mutatja.

A keményítőhozam átlagosan 6,02 t ha⁻¹, mérsékelt változatossággal (szórás: 1,19), enyhe negatív ferdeséggel (-0,36). A fehérjehozam szintén stabil (átlag: 0,75 t ha⁻¹), enyhén negatív ferdeséggel (-0,21), ami a magasabb hozamok felé történő eltolódást jelzi (7. táblázat).

A 12. ábra a fenti paramétereket ábrázolja boxplot formájában. A 2019-es évben a terméshozam átlagosan a legmagasabb értéket érte el a három év közül, miközben a boxploton is jól láthatóan szűkebb tartományba rendeződött, vagyis a szóródás csökkent. Az olajtartalom eloszlása kiegyensúlyozottabb lett, mint 2017-ben, de a boxplot alapján már nem

annyira homogén, mint 2018-ban. A fehérjetartalom a 2018-as alacsonyabb értékek után emelkedett. A terméshozam a három év közül a legmagasabb átlagot adta, ugyanakkor a boxploton is láthatóan kisebb szóródással, míg a keményítőtartalom értékei köztes szintet képviseltek a 2017-es alacsonyabb és a 2018-as magasabb átlaghoz képest.




12. ábra: A változók leíró statisztikai eredményeit ábrázoló boxplot diagramok (2018)

A 2019-es év adatait bemutató korrelációs mátrixban (13. ábra) több kiugró kapcsolat figyelhető meg. A legszorosabb pozitív korreláció a hozam és a fehérjehozam között

mutatkozik ($p = 0,91$), valamint a hozam és a keményítőhozam között is erős pozitív kapcsolat tapasztalható ($p = 0,91$). Ez természetesen nem meglepő, mivel logikus hogy a nagyobb terméshozam mindkét paraméter növekedésével jár. A fehérjetartalom és a keményítőtartalom között azonban ebben az évben is jelentős negatív korreláció áll fenn ($p = -0,73$), azaz a magasabb fehérjetartalmú minták esetében általános jelenség az alacsonyabb keményítőtartalom.

A keményítőtartalom és a nedvességtartalom között szintén negatív kapcsolat tapasztalható ($p = -0,38$), tehát magasabb nedvességtartalom esetén alacsonyabb keményítőtartalom jellemző a vizsgált évben. Az olajtartalom és a keményítőtartalom közötti negatív korreláció ($p = -0,59$) alapján az olajban gazdag minták keményítőtartalma kisebb.

A hl-tömeg és a fehérjetartalom között pozitív kapcsolat áll fenn ($p = 0,61$), tehát a nagyobb hektolitertömegű minták magasabb fehérjetartalommal rendelkeznek.



13. ábra A vizsgált paraméterek összefüggéseit vizsgáló Spearman korrelációs mátrix (2019)

4.2. Különböző agrotechnikai tényezők, illetve az évjárat hatása a keményítőtartalomra és a keményítőhozamra

Az alábbi alfejezetekben részletesen bemutatom a kukorica keményítőtartalmára és keményítőhozamára gyakorolt különböző agrotechnikai tényezők hatásait. Az elemzés során először a keményítőtartalom alakulását vizsgáltam az évjárat, a tápanyagkezelések és a talajművelési módok önálló és kombinált hatásának figyelembevételével. Ezt követően a keményítőhozam tekintetében is elemeztem ugyanezen tényezők hatásait, különös figyelmet fordítva az esetleges kölcsönhatásokra.


A statisztikai elemzések során varianciaanalízist (ANOVA) alkalmaztam, hogy feltárjam az egyes tényezők keményítőtartalomra és keményítőhozamra gyakorolt szignifikáns hatásait. Az ANOVA eredményeit követően LSD (Legkisebb Szignifikáns Különbség) tesztet végeztem, amellyel azonosítottam a kezelések közötti szignifikáns különbségeket. Az LSD teszt segítségével meghatároztam, hogy a kezelések közötti eltérések statisztikailag jelentősek-e, és megállapítottam a legkisebb szignifikáns különbség értékét. Az elemzéseket a tőszám és a hibridek átlagában végeztem el.

4.2.1. A különböző tápanyagkezelések hatása a keményítőtartalomra

A különböző tápanyagkezelések hatásának a vizsgált három év átlagában történt elemzése során megállapítottam, hogy a kukorica keményítőtartalmára jelentős hatással volt a tápanyag-adagolás. A vizsgálatok eredményei alapján a legmagasabb keményítőtartalmat (64,42%) a kontroll kezelés eredményezte, tehát a nitrogéntrágyázás hiánya kedvezően hatott a keményítőtartalomra. Ezzel szemben a legalacsonyabb keményítőtartalmat (62,61%) a 160 kg N ha⁻¹ + PK tápanyagkezelés eredményezte, azaz a magasabb nitrogéndózis csökkentette a keményítőtartalmat.

A vizsgálatok eredményei alapján a 80 kg N ha⁻¹ + PK kezelés (63,44%) mérsékelt hatást gyakorolt a keményítőtartalomra, amely alacsonyabb, mint a kontroll kezelés esetében, de magasabb, mint a 160 kg N ha⁻¹ kezelésé. A statisztikai elemzés során a legkisebb szignifikáns különbség a tápanyagkezelések között 0,428% volt, tehát a mért különbségek statisztikailag szignifikánsak. A 14. ábra jól szemlélteti a különböző tápanyagkezelések keményítőtartalomra gyakorolt hatását. Az oszlopdiagram egyértelműen mutatja a kontroll

kezeléshez kapcsolódó kiemelkedő keményítőtartalmat, valamint a 160 kg N ha⁻¹ + PK kezelés esetében bekövetkezett jelentős csökkenést. A csoportok közötti szignifikáns különbségeket az oszlopok alatti betűk (a, b, c) jelölik.




14. ábra: A tápanyagkezelések hatása a kukorica keményítőtartalmára (Debrecen-Látókép 2017-2019)

4.2.2. Az évjárat hatása a keményítőtartalomra

Az évjárat hatásának elemzése, amely az adott évet érintő meteorológiai paraméterek (havi átlag csapadékmennyiség adatok, napi hőmérsékleti adatok) figyelembevételével, illetve a kezelések és talajművelési módok átlagában történt, egyértelműen kimutatta, hogy a kukorica keményítőtartalma jelentős mértékben függ a termesztési évjáratától. Az elemzés eredményei alapján 2018 bizonyult a legkedvezőbb évnek a kukorica keményítőtartalma szempontjából a vizsgált mintákban, amikor a keményítőtartalom elérte a 65,76%-ot. Ez az eredmény összhangban áll a kedvező időjárási körülményekkel, amelyek ebben az évben a kukorica fejlődését és keményítőképződését támogatták. Ezzel szemben a vizsgált évek közül a legalacsonyabb keményítőtartalmat a 2017-es év hozta, amely mindössze 61,78% volt. Az adatok alapján megállapítható, hogy a 2017-es évjárat kedvezőtlenebb éghajlati feltételei hozzájárultak a keményítőtartalom csökkenéséhez. A 2019-es évben mért keményítőtartalom

62,93% volt, amely ugyan meghaladta a 2017-es szintet, de jelentősen elmaradt a 2018-as csúcstól.

A statisztikai elemzések során a legkisebb szignifikáns különbség (LSD) a termésévek között 0,309% volt, ami jelzi, hogy a különbségek a keményítőtartalom tekintetében szignifikánsnak tekinthetők. Az ANOVA és az LSD-teszt eredményei alapján megállapítható, hogy a különböző évjáratok között szignifikáns eltérések figyelhetők meg a kukorica keményítőtartalmában, különösen a 2018-as év javára. A 2018-as évjárat kiemelkedően kedvező volt, míg a 2017-es évjárat jelentősen kedvezőtlenebb a keményítőtartalom szempontjából. A 15. ábra szemléletesen mutatja be a keményítőtartalom alakulását a három vizsgált évjáratban. Az oszlopdiagram jól érzékelteti a 2018-as évjárat kiugró értékét, valamint a 2017-es és 2019-es évjáratok alacsonyabb, egymáshoz közeli keményítőtartalmát. A csoportok közötti szignifikáns különbségeket az oszlopok alatti betűk (a, b, c) jelölik. Az adott évekből származó adatok közötti szignifikáns eltérés tehát az egyes évek meteorológiai paramétereinek jelentőségére utal.




15. ábra: Az évjárat hatása a kukorica keményítőtartalmára (Debrecen-Látókép, 2017-2019)

4.2.3. A különböző talajművelési módok és az évjárat együttes hatása a keményítőtartalomra

A talajművelés és az évjárat hatása szignifikánsan befolyásolta a kukorica keményítőtartalmát, ami fontos tényező a termesztési technológiák hatékonyságának

értékelése során. A műtrágyakezelések átlagában lefolytatott vizsgálat eredményei azt mutatták, hogy a legalacsonyabb keményítőtartalom 2017-ben volt megfigyelhető, azon belül is a sávós talajművelés esetében. Ebben az évben nem volt statisztikailag szignifikáns különbség az őszi szántásos és a lazítással végzett talajművelés között, azaz a különböző művelési módszerek közötti különbségek ebben az évjáratban kevésbé voltak markánsak. A következő évben (2018-ban) a kukorica keményítőtartalma kiemelkedően magas volt, ami az eddigi megfigyeléseket támasztja alá, azonban fontos megemlíteni, hogy ebben évjáratban sem mutatkozott szignifikáns különbség a különböző talajművelési kezelések között, tehát a környezeti tényezők ebben az évben is dominánsabb hatást gyakoroltak a keményítőtartalomra, mint a talajművelési technológia.

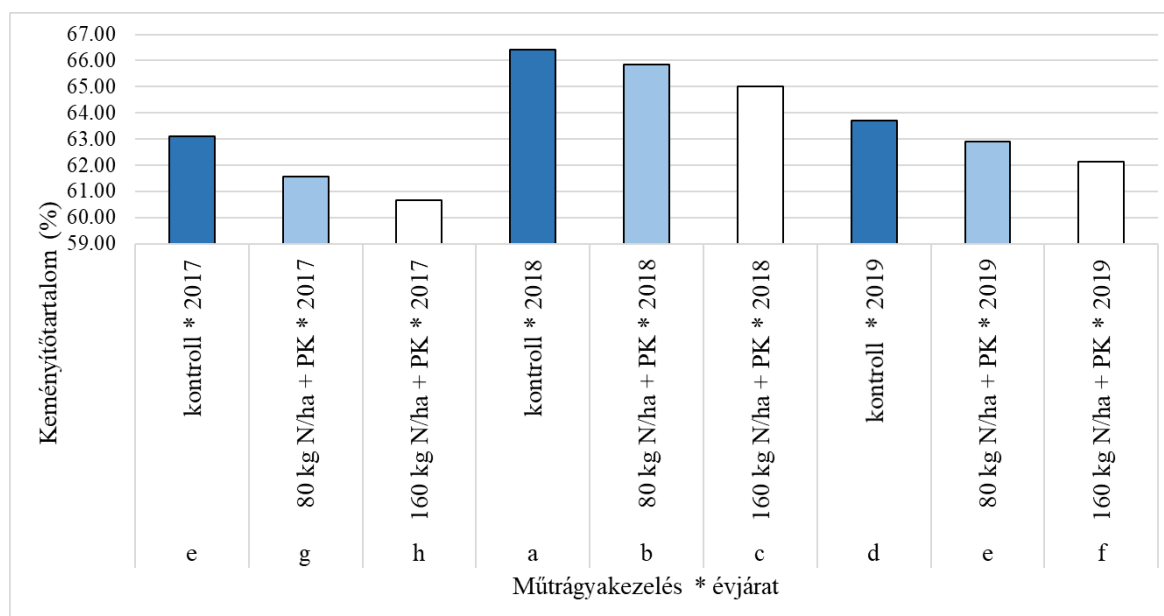
A 2019-es évben minden vizsgált talajművelési módszernél szignifikánsan alacsonyabb keményítőtartalom volt megfigyelhető, mint az előző évben (2018), azonban a 2017-es évhez képest a keményítőtartalom még így is magasabbnak bizonyult. Ez az eredmény arra enged következtetni, hogy a 2019-es termesztési körülmények, bár kedvezőtlenebbek voltak a keményítőtartalom szempontjából, mégis valamivel kedvezőbbek voltak, mint a 2017-es évjárat esetében. A 2019-es évben sem volt statisztikailag szignifikáns különbség a talajművelési eljárások között, ami tovább erősíti a megállapítást, miszerint ebben az évben is az évjárat hatások domináltak. (16. ábra).



16. ábra: Az elsődleges talajművelés és az évjárat hatása a kukorica keményítőtartalmára (Debrecen-Látókép, 2017-2019)

4.2.4. A tápanyagkezelések és az évjárat együttes hatása a keményítőtartalomra

Az talajművelési módok átlagában elvégzett elemzés eredményei azt mutatták, hogy a tápanyagkezelés és az évjárat jelentős hatással volt a vizsgált kukoricaminták keményítőtartalmára. Az évjárat hatások vizsgálata során bebizonyosodott, hogy 2018-ban a három tápanyagkezelés között nem volt szignifikáns különbség, ebben az évben a kedvező klimatikus körülmények domináltak a keményítőtartalom alakulásában. Ezzel szemben, bár 2019-ben sem mutatkozott statisztikai különbség a tápanyagkezelések között, ugyanakkor az előző évhez képest a keményítőtartalom minden kezelés esetében igazolhatóan alacsonyabb volt. A tápanyagkezelés és az évjárat közötti legkisebb szignifikáns különbség értéke 0,536 volt, ami megerősíti a kezelések közötti eltérések statisztikai jelentőségét. A tápanyagkezelés és az évjárat együttesen is befolyásolta a kukorica keményítőtartalmát, amely változásokat mutatott az egyes évek között. A vizsgált időszak legalacsonyabb keményítőtartalma 2017-ben volt, amikor a 160 kg N ha⁻¹-os kezelésben mindössze 60,67%-os keményítőtartalom volt megfigyelhető. Ez az eredmény ismét azt mutatja, hogy a magasabb N-műtrágya dózisok nem feltétlenül kedveznek a keményítőtartalom alakulásának.



17. ábra: A műtrágyázás és az évjárat hatása a kukorica keményítőtartalmára (Debrecen-Látókép, 2017-2019)

A vizsgálatok során megállapítottam, hogy a tápanyagkezelés minden vizsgált évben csökkentette a kukorica keményítőtartalmát a kontrollhoz képest. Ugyanakkor a 2018-as

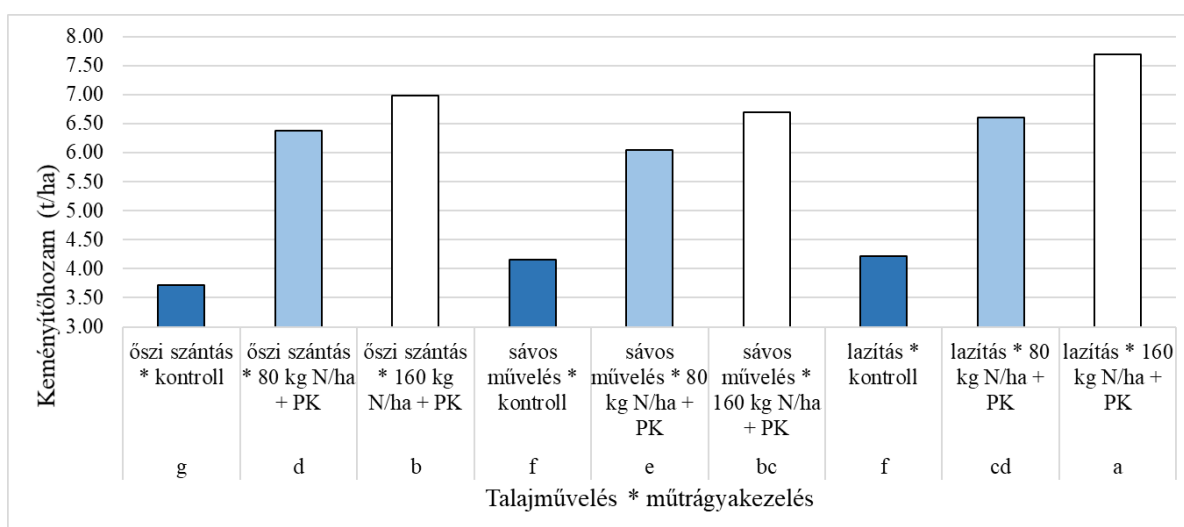
évjárat kiemelkedőnek bizonyult, mivel ebben az évben a kukorica keményítőtartalma minden tápanyagkezeléssel jelentősen nőtt az előző évhez képest. A vizsgált időszak statisztikailag legmagasabb keményítőtartalma (66,43%) 2018-ban a kontroll kezelés esetében volt, amely az évjárat hatása kedvező voltát tükrözi. A 2019-es évjárat azonban újra kedvezőtlenebb, a 2017-es hasonló eredményeket hozott, azaz minden kezelésben alacsonyabb volt a keményítőtartalom, mint 2018-ban. Ez a visszaesés valószínűleg az évjárat klimatikus körülményeinek köszönhető, amelyek nem kedveztek a keményítőtartalom alakulásának. (17. ábra). Az a tendencia, amely szerint a keményítőtartalom minden tápanyagkezelési szintnél szignifikánsan csökkent, minden évben megfigyelhető.

4.2.5. A talajművelés és a tápanyagkezelések hatása a keményítőhozamra

A kukorica keményítőhozamát befolyásoló tényezők közül kiemelt figyelmet kapott a talajművelés és a tápanyagkezelés kölcsönhatása, melyet a vizsgált évjáratok átlagában értékeltem. Az elemzés célja annak feltárása volt, hogy az egyes talajművelési módok és nitrogénalapú tápanyagkezelések milyen mértékben befolyásolják a keményítőhozamot, valamint, hogy ezek a hatások önállóan vagy egymással kombinálva okoznak-e szignifikáns változásokat. Az alkalmazott talajművelési módok közül a legmagasabb keményítőhozamot a lazításos talajművelés hozta, amelynek átlagos értéke elérte a $6,17 \text{ t ha}^{-1}$ -t. Ezzel szemben az őszi szántás ($5,69 \text{ t ha}^{-1}$) és a sávos művelés ($5,63 \text{ t ha}^{-1}$) eredményei statisztikailag nem különböztek egymástól, mivel a talajszerkezet kíméletesebb, mélyebb lazítására épülő módszer kedvezőbb feltételeket teremtett a keményítőhozam szempontjából.

A különböző tápanyagkezelések hatása szintén szignifikánsan megmutatkozott a keményítőhozam alakulásában (16. ábra). A kontrollkezelés eredményezte a legalacsonyabb hozamot (átlagosan $4,0 \text{ t ha}^{-1}$), míg a $80 \text{ kg N ha}^{-1} + \text{PK}$ dózis mellett ez az érték $6,3 \text{ t ha}^{-1}$ -ra, a $160 \text{ kg N ha}^{-1} + \text{PK}$ dózissal pedig $7,1 \text{ t ha}^{-1}$ -ra emelkedett. Az eredmények egyértelműen rámutatnak arra, hogy a nitrogéntrágyázás jelentősen hozzájárul a keményítőhozam növeléséhez. A két tényező együttes hatása tovább erősítette ezt a tendenciát. A kontrollkezelések közül a legkisebb keményítőhozam az őszi szántás esetében volt megfigyelhető, ahol az érték mindössze $3,7 \text{ t ha}^{-1}$ volt. Ezzel szemben a sávos művelés ($4,16 \text{ t ha}^{-1}$) és a lazítás ($4,22 \text{ t ha}^{-1}$) kontrollparcellái között nem volt statisztikailag kimutatható

különbség. A tápanyagkezelések közül a 80 kg N ha⁻¹ + PK dózis mellett a legalacsonyabb keményítőhozam a sávos talajművelésnél jelentkezett. A legmagasabb keményítőhozamot (7,69 t ha⁻¹) a lazításos művelés és a 160 kg N ha⁻¹ + PK kombinációja biztosította. Ugyanezen tápanyagszint mellett az őszi szántás (6,98 t ha⁻¹) és a sávos művelés (6,7 t ha⁻¹) hozamai között nem volt szignifikáns eltérés, eszerint magasabb nitrogéndózis esetén a talajművelési mód szerepe kevésbé meghatározó a keményítőhozam szempontjából. A 18. ábra bemutatja az egyes kezelések közötti különbségeket, jól látható, hogy a kombinált tápanyagkezelés és a megfelelő talajművelés együttes alkalmazása jelentősen növelte a keményítőhozamot.

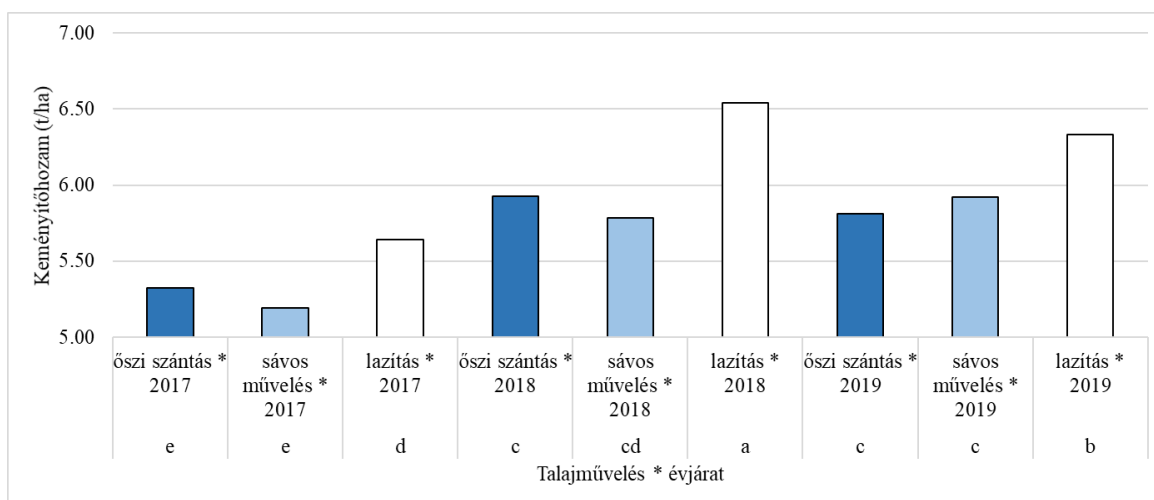


18. ábra: A talajművelés és a műtrágyázás hatása a kukorica keményítőhozamára (Debrecen-Látókép 2017-2019)

4.2.6. A talajművelési módok és az évjárat együttes hatása a keményítőhozamra

A kukorica keményítőhozamát jelentősen befolyásolta az évjárat hatása, amely a vizsgálatok esetében az adott év meteorológiai paramétereinek (csapadékmennyiség és hőmérséklet) hatását jelenti. Az elemzések során megállapítást nyert, hogy az évjáratok közül 2017 bizonyult a legkedvezőtlenebbnek a keményítőhozam szempontjából, amikor az átlagos hozam mindössze 5,37 t ha⁻¹ volt. A csapadékosabb és melegebb időjárás miatt ebben az évben a különböző talajművelési módok közül a lazításos talajművelés biztosította a legmagasabb keményítőhozamot. Az őszi szántás és a sávos művelés között ebben az évben nem mutatkozott szignifikáns különbség (17. ábra). A 2018-as évjárat kedvezőbb feltételeket


biztosított, mivel a csapadék és hőmérséklet szempontjából átlagosnak mondható időjárási viszonyok alakultak ki. Ez az év produkálta a legmagasabb keményítőhozamot ($6,54 \text{ t ha}^{-1}$), amelyet a lazításos talajművelés biztosított. A sávos művelés és az őszi szántás ebben az évjáratban szintén nem különböztek szignifikánsan egymástól, ami azt sugallja, hogy az optimális klimatikus körülmények mellett a talajművelési mód hatása kevésbé jelentős. A 2019-es évjárat, amely szárazabb és melegebb volt, szintén hatással volt a keményítőhozamokra. Ebben az évben a lazításos talajművelés ismét a legmagasabb hozamot eredményezte ($6,33 \text{ t ha}^{-1}$), amely szignifikánsan magasabb volt az őszi szántás és a sávos művelés hozamainál. Eszerint, kevésbé csapadékos időjárási körülmények között a lazításos módszer előnyt jelent a keményítőképződés szempontjából. A 19. ábra jól szemlélteti az évjáratok és talajművelési módok közötti különbségeket. A lazításos talajművelés minden évjáratban kiemelkedő keményítőhozamot biztosított, különösen 2018-ban, amikor a klimatikus feltételek kedveztek a keményítőképződésnek. A tápanyagkezelések átlagában végzett vizsgálat eredményei alapján egyértelműen megállapítható, hogy a megfelelő talajművelési mód alkalmazása, illetve az évjárat optimális meteorológiai feltételei együttesen jelentős hatást gyakorolnak a keményítőhozam maximalizálására.



19. ábra: A talajművelés és az évjárat hatása a kukorica keményítőhozamára (Debrecen-Látókép, 2017-2019)

4.2.7. A tápanyagkezelések és az évjárat együttes hatása a keményítőhozamra

A kukorica keményítőhozamát szintén befolyásolta a tápanyagkezelések és az évjárat kölcsönhatása. A művelési módok átlagában elvégzett vizsgálat eredményei azt mutatták, hogy az évjárat önállóan is meghatározó szerepet játszott a keményítőhozam alakulásában, ugyanakkor a megfelelő tápanyagkezelések alkalmazása minden évjáratban növelte a hozamot. A vizsgálatok alapján a három vizsgált év közül a 2017-es évjárat bizonyult a legkedvezőtlenebbnek a keményítőhozam szempontjából, amikor az átlagos hozam mindössze 3,4 t ha⁻¹ volt a kontrollparcellákon. Ez az évjárat klimatikus szempontból kedvezőtlen volt, amely visszatükröződött a hozamadatokban is. A kontrollkezelés esetében a kukorica keményítőhozama minden évjáratban szignifikánsan alacsonyabb volt, mint a tápanyaggal kezelt parcellákon. Az alkalmazott tápanyagkezelések hatása minden vizsgált évben egyértelműen pozitív volt: a műtrágyázás következetesen növelte a kukorica keményítőhozamát. Az eredmények szerint a vizsgált időszak legmagasabb keményítőhozam-értékeit a 160 kg N ha⁻¹ + PK kezelés hozta. Ez a dózis minden évjáratban a legkedvezőbb hatást fejtette ki, különösen a 2018-as évjáratban, amely önmagában is kedvezőbb volt a keményítőképződés szempontjából (20. ábra).



20. ábra: A tápanyagkezelések és az évjárat hatása a kukorica keményítőhozamára (Debrecen-Látókép, 2017-2019)

4.3. Főkomponens-elemzés (PCA) különböző bemeneti adatok alapján

A fenti eredmények további alátámasztása okán főkomponens elemzést végeztem a keményítőtartalomra vonatkozóan. A főkomponens-elemzés (principal component analysis, PCA) egy többváltozós statisztikai eljárás, amelyet nagy adathalmazok belső struktúrájának feltárására, valamint a változók közötti összefüggések szemléletes vizualizálására használnak. A PCA célja a nagyszámú eredeti változó információjának tömörítése néhány úgynevezett főkomponensbe, amelyek megőrzik az eredeti információ jelentős részét. Ennek során a PCA az adathalmaz varianciáját maximalizáló irányokat azonosít, így csökkenti a dimenziók számát és megkönnyíti a komplex összefüggések értelmezését.

Évjáráthatás

A PCA elemzés jól elkülönülő klasztereket mutatott ki a vizsgált évek (2017, 2018, 2019) adatai között. A három év adathalmazai közül a 2018-as év eredményei mutatták a legerősebb elkülönülést, egy különálló klasztert képezve a PCA koordináta-rendszerében. A 2017-es és 2019-es évek adatai ezzel szemben jelentős átfedést mutattak egymással, jelezve ezen évek környezeti és termesztési feltételeinek nagyobb hasonlóságát, valamint a 2018-as év körülményeitől való eltérésüket (21. ábra).

Talajművelési módok hatása


A különböző talajművelési módok (őszi szántás, sávos talajművelés, lazítás) PCA-val történő összehasonlítása során nem volt megfigyelhető egyértelmű klaszteresedési mintázat. Az eredményekből láthatóan az eltérő művelési technológiákhoz tartozó adatok nagyfokú átfedést mutattak, tehát a talajművelési technikák közvetlen hatása a vizsgált változóra (keményítőtartalom) korlátozott, vagy legalábbis kevésbé meghatározó, mint más vizsgált tényezőké (22. ábra).

Műtrágyadózisok hatása


A PCA eredmények a trágyázási dózisok (kontroll, 80 kg N ha⁻¹ + PK, 160 kg N ha⁻¹ +PK) esetében jól körülhatárolható csoportosításokat mutattak. Különösen a kontroll (műtrágya nélküli) kezelés csoportja különült el egyértelműen a két műtrágyázási kezeléstől, ami alátámasztja, hogy a műtrágyázási intenzitás jelentős hatással van a kukorica

keményítőtartalmára vonatkozóan. Az elemzés alapján tehát igazolható, hogy a tápanyagellátás döntően meghatározza a vizsgált változó alakulását (23. ábra).


A PCA elemzés eredményei megerősítették, hogy az évjárat különbségek és a műtrágyázási dózisok a keményítőtartalom fő befolyásoló tényezői. Ezzel szemben a talajművelési technológiák szerepe korlátozott volt, mivel ezek az adatok nem mutattak szignifikáns elkülönülést a PCA elemzés során. Ezen eredmények alapján a jövőbeni kutatásokban és termelési gyakorlatban érdemes a tápanyag-gazdálkodási stratégiákra és az évjárat-specifikus kezelések kidolgozására fókuszálni.



21. ábra: Főkomponens-elemzés (PCA) az évjárat alapján



22. ábra: Főkomponens-elemzés (PCA) a talajművelési módok alapján




23. ábra: Főkomponens-elemzés (PCA) a tápanyagkezelések alapján


4.4. A kukorica keményítőtartalmát befolyásoló változók összehasonlító elemzése a hároméves kísérleti időszakban (2017-2019)

A fenti vizsgálatok eredményeit megerősítendő, a kiválasztott változók (évjárat, talajművelés és műtrágyázás) kukorica keményítőtartalmára gyakorolt hatásának részletes vizsgálatához Wilcoxon-tesztet alkalmaztam. Ez a vizsgálat alkalmas a különböző csoportok közötti statisztikailag szignifikáns különbségek feltárására.


Az elemzés egyértelműen igazolta, hogy az évjárat jelentős hatással van a kukorica keményítőtartalmára. Mindhárom vizsgált év (2017, 2018 és 2019) között erősen szignifikáns különbség ($p < 0,001$) volt kimutatható. A 2018-as évben mért keményítőtartalom szignifikánsan magasabb volt a 2017-es és 2019-es évhez viszonyítva. Továbbá a 2019-es év keményítőtartalma is jelentősen eltért a 2017-es évtől ($p < 0,001$). Ez a következetes és erős szignifikancia azt mutatja, hogy az éves környezeti változások meghatározó tényezőként szerepelnek a kukorica beltartalmi tulajdonságainak alakulásában (24. ábra). A különböző talajművelési technikák (lazítás, sávos művelés, őszi szántás) összehasonlítása során nem volt kimutatható statisztikailag szignifikáns különbség a kukorica keményítőtartalmában. Ez az eredmény arra enged következtetni, hogy a vizsgált talajművelési technológiák nem gyakorolnak lényeges hatást a keményítőtartalom alakulására (25. ábra). A kukorica keményítőtartalmát jelentősen befolyásolta a műtrágyázás szintje. Az elemzés során erősen szignifikáns ($p < 0,001$) különbségeket találtam mindhárom csoport összehasonlításakor: a kontroll (műtrágya nélküli) és a $80 \text{ kg N ha}^{-1} + \text{PK}$ dózis között, a kontroll és a $160 \text{ kg N ha}^{-1} + \text{PK}$ dózis között, valamint a két műtrágyázott csoport ($80 \text{ kg N ha}^{-1} + \text{PK}$ és $160 \text{ kg N ha}^{-1} + \text{PK}$) között egyaránt. A legmagasabb műtrágya dózis ($160 \text{ kg N ha}^{-1} + \text{PK}$) egyértelműen alacsonyabb keményítőtartalomhoz vezetett, míg a kontrollcsoport mutatta a legmagasabb értékeket. Ez alátámasztja, hogy a nitrogén-alapú trágyázás jelentős, bár negatív irányú hatást gyakorol a kukorica keményítőtartalmára, valószínűleg a szemtermés fehérjetartalmával szoros összefüggésben (26. ábra). A vizsgált változók közül az évjárat és a műtrágyadózisok bizonyultak kulcsfontosságú, szignifikánsan befolyásoló tényezőnek a kukorica keményítőtartalmát tekintve. A talajművelési technikák ezzel szemben nem mutattak statisztikailag kimutatható hatást.



24. ábra: A keményítőtartalom különbségei a kísérlet különböző éveiben Wilcoxon-teszt alapján



25. ábra: A keményítőtartalom különbségei a különböző talajművelési rendszerekben (2017-2019) Wilcoxon-teszt alapján



26. ábra: A keményítőtartalom különbségei a műtrágyadózisok alapján Wilcoxon-teszt alkalmazásával

4.5. A keményítőtartalom előrejelzésének mesterséges neurális hálózatokkal (ANN) történő értékelése

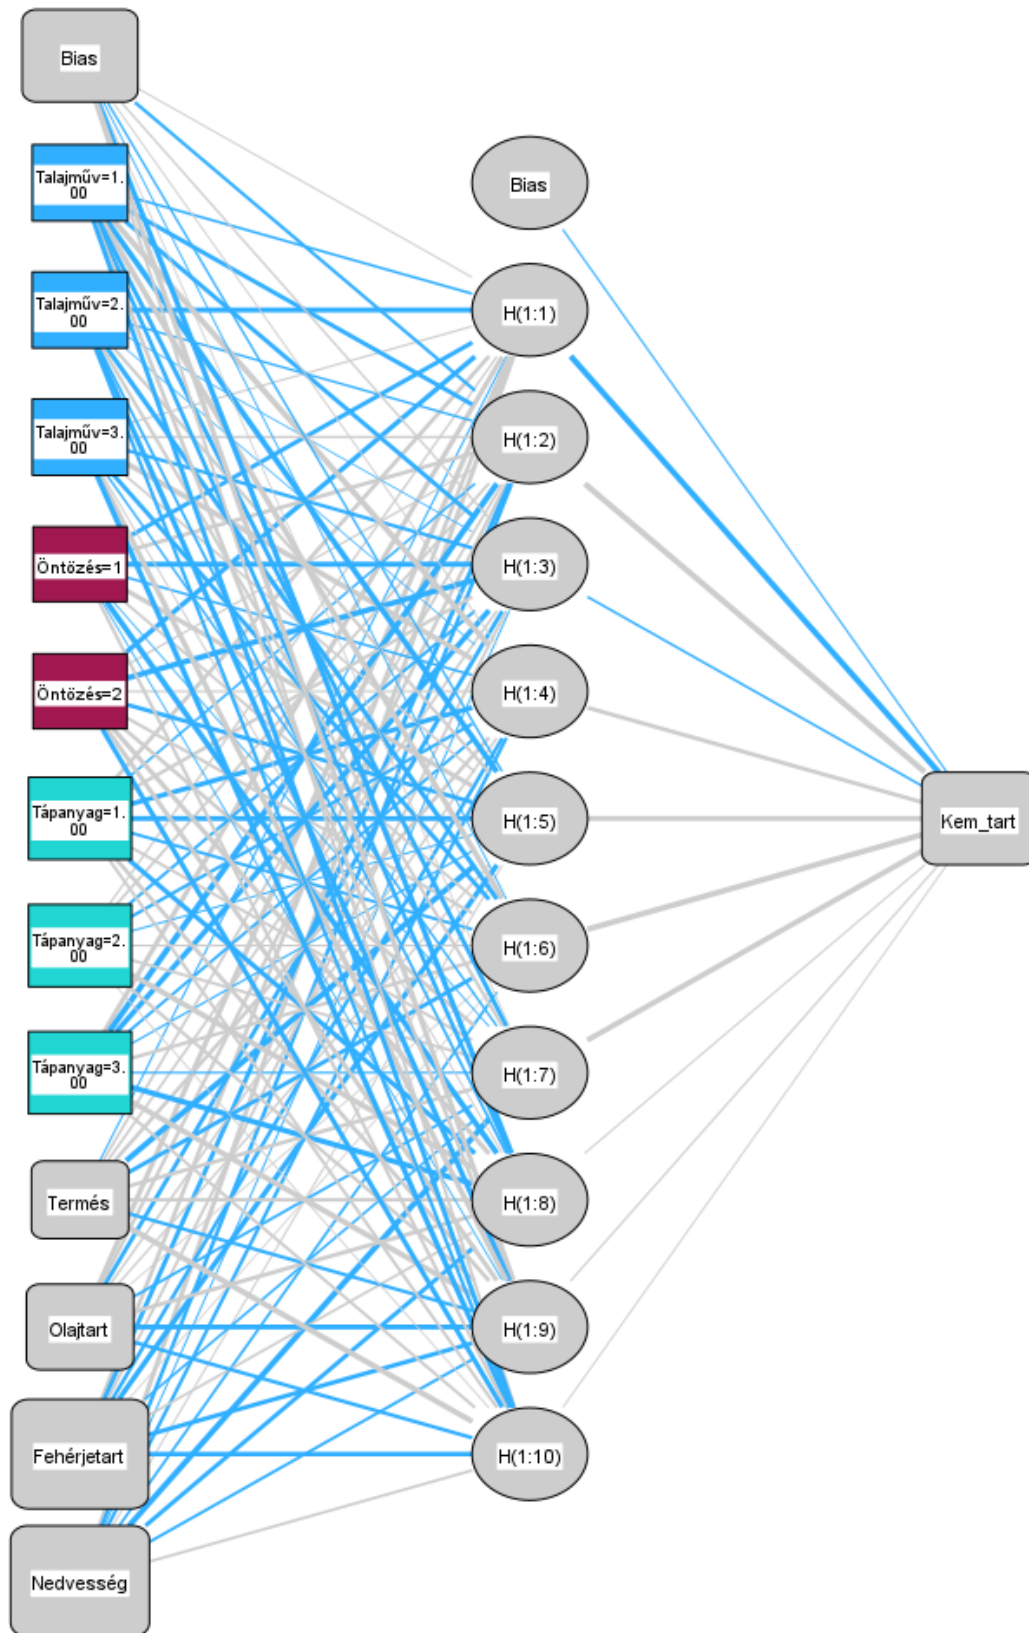
A hagyományos elemzési módszereket követően a kísérleti adatok elemzéséhez és a keményítőtartalom előrejelzéséhez gépi tanulási módszereket alkalmaztam, mégpedig két mesterséges neurális hálózat (ANN) modellt, a többrétegű perceptron (MLP) és a radiális bázis függvény (RBF) modellt. Az MLP egy több rétegű neurális hálózat, amely komplex összefüggések felismerésére képes, míg az RBF modell egy speciális neurális hálózat, amely a bemeneti adatok és a célváltozók közötti nemlineáris összefüggések modellezésére szolgál. A vizsgálat célja annak megállapítása volt, hogy a különböző változók predikciós hatékonyságát elemezzem a keményítőtartalomra vonatkozóan, négy előre meghatározott scenárió alapján.

Az alábbi alfejezetek célja az egyes forgatókönyvek részletes bemutatása és értékelése. A vizsgálatok során minden scenáriót egyenként tekintettem át, elsőként ismertetve annak felépítését, a bevont bemeneti változókat és az alkalmazott modell architektúráját. Az egyes

forгатókönyvek értékelése során a lefutтatott modellek eredményeit a kapott teljesítménymutatók alapján vizsgáltam. A teljesítmény összehasonlítására elsősorban a négyzetes hiba összege (SSE) és a relatív hiba (RE) szolgál, amelyek együttesen megbízható képet nyújтanak a modellek illeszkedőképességéről, valamint a predikciók pontosságáról. Az értékelést követően minden esetben grafikus megjelenítést (szórásképek, raincloud diagramok) is alkalmaztam az eredmények szemléletesebb formában történő bemutatásához. A szórásképek lehetővé teszik a becсült és a tényleges értékek kapcsolatának közvetlen összehasonlítását, jól érzékeltetve, hogy a modell mennyiben képes a változók közötti összefüggések visszaadására. A raincloud diagramok pedig kiegészítő eszközként szolgálnak: egyszerre jelenítik meg az eloszlásokat és a minták variabilitását, ezáltal átfogóbb képet adva az előrejelzések bizonytalanságáról és szóródásáról.

4.5.1. Az ANN-MLP modell eredményeinek bemutatása

Az **MLP_SC1** modell (27. ábra) szerkezetét tekintve 7 db változóból álló bemeneti réteggel rendelkezik, azonban a korábban leírtaknak megfelelően azokban az esetekben, ahol a változóhoz kapcsolódó adatok nem egy adatsorból származnak, hanem annak ellenére, hogy nominális adatok, mégis vagylagosak (pl. öntözött parcella 0 = nem, 1 = igen) ott a változók az opciókkal megegyező számú alváltozókra bomlanak tovább (ezért van összesen 12 db bemeneti változó). Az MLP_SC1 esetében a talajművelés, az öntözés és a tápanyagkezelés ilyen, ez magyarázza az eltérő színeket. A színekre vonatkozó utóbbi megállapítás az összes további forгатókönyvre is érvényes. A modell rejtett rétege 10 db neuront tartalmaz. A kimeneti réteg egyetlen kimeneti változóból áll, amely az előrejelzett keményítőtartalom. A modell vizuális megjelenítése jól érzékelteti, hogy a bemeneti változók és a kimenet közötti kapcsolat nem közvetlen, hanem több szinten keresztül, a rejtett neuroncsoportok feldolgozásán át valósul meg. Ez a struktúra biztosítja, hogy a hálózat képes legyen a változók közötti nemlineáris összefüggések felismerésére és a keményítőtartalom pontosabb becslésére. Az összekötő vonalak vastagsága a szinaptikus súlyok nagyságát mutatja, vagyis minél erősebb a kapcsolat két neuron között, annál vastagabb vonallal ábrázolja a modell.




27. ábra Az MLP_SC1 szcenárió modelljének szerkezeti felépítése

Az MLP_SC1 modell teljesítménye mind a tanítási, mind a tesztelési fázisban kiemelkedőnek bizonyult. A tanítási fázisban a négyzetes hibák összege 36,536 volt, míg a relatív hiba értéke 0,081, azaz a modell jól illeszkedett a tanító adathalmazhoz. A tesztelési fázisban a modell továbbra is jól teljesített: a négyzetes hibák összege 14,948, a relatív hiba pedig 0,069 volt, ami azt jelenti, hogy a modell megfelelően általánosít, és a tanító adathalmazon kívüli adatokra vonatkozóan is pontos előrejelzést nyújt. A 8. táblázat az eredmények összefoglalását tartalmazza.

8. táblázat: A modell teljesítménye az MLP_SC1 forgatókönyv esetében

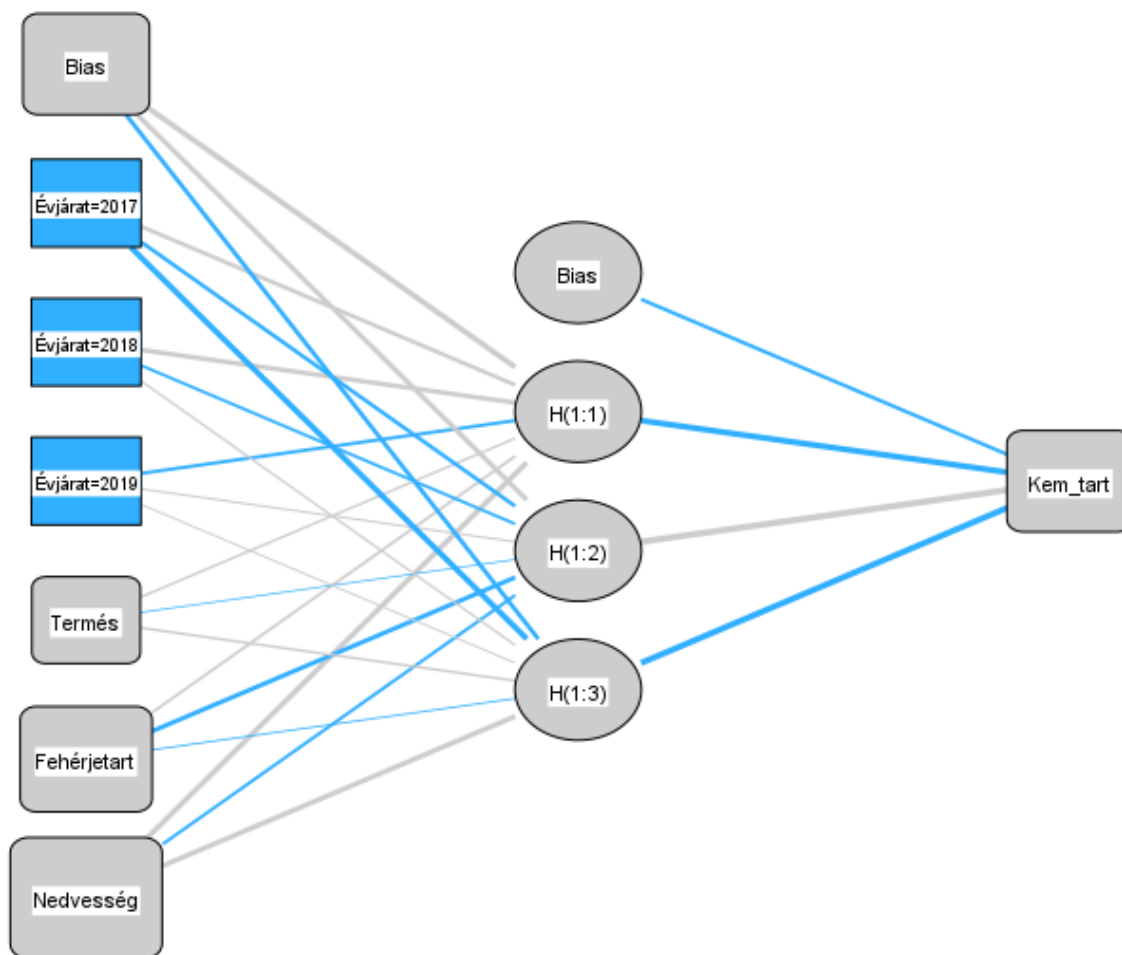
Modell összefoglaló		
Tanítás	Négyzetes hiba összege	36,536
	Relatív hiba	0,081
	Képzési idő	0:00:00.05
Tesztelés	Négyzetes hiba összege	14,948
	Relatív hiba	0,069
Függő változó: keményítőtartalom		

A becült és a mért keményítőtartalom értékeinek összehasonlítását a 28. ábra mutatja be. A bal oldali szóráskép alapján megfigyelhető, hogy az előrejelzett értékek jellemzően a valós értékek körül koncentrálnak, azonban néhány esetben az előrejelzés pontatlanabb, főként magasabb keményítőtartalom értékek esetén. A jobb oldalon látható raincloud diagram az előrejelzett és a valós keményítőtartalom eloszlását és variabilitását szemlélteti. Az ábrán jól látható, hogy a két eloszlás jelentős átfedést mutat, ami az előrejelzés pontosságát erősíti meg.



28. ábra: Az MLP_SC1 becült értékeinek szórás- és raincloud diagramjai

Az **MLP_SC2** modell (29. ábra) bemeneti rétege 4 db input változóból áll, amelyek egyike (évjárat) további alváltozókra bomlik, így összesen 6 db változó szerepel. A bemeneti változók között szerepel tehát az évjárathatás, a termés mennyisége, a fehérjetartalom és a nedvességtartalom. A modell rejtett rétege 3 db neuront tartalmaz.



29. ábra Az MLP_SC2 szcenárió modelljének szerkezeti felépítése

Az MLP_SC2 modell teljesítménye mind a tanítási, mind a tesztelési fázisban kielégítőnek bizonyult. A tanítási fázisban a négyzetes hibák összege 59,893 volt, míg a relatív hiba értéke 0,132, ami a modell megfelelően illeszkedésére utal a tanító adathalmaz esetében. A képzési idő 0,14 másodperc volt, ami viszonylag gyorsnak tekinthető, bár hosszabb az SC1 szcenárióhoz képest.

A tesztelési fázisban a modell továbbra is megfelelő teljesítményt mutatott: a négyzetes hibák összege 27,611, a relatív hiba pedig 0,156 volt. A modell általánosítási képessége


elfogadható, és az előrejelzési pontosság a tanító adathalmazon kívüli minták esetében is megfelelően megmaradt. A modell előrejelzése viszonylag megbízhatónak mondható (9. táblázat).

9. táblázat: A modell teljesítménye az MLP_SC2 forгатókönyv esetében

Modell összefoglaló		
Tanítás	Négyzetes hiba összege	59,893
	Relatív hiba	0,132
	Képzési idő	0:00:00.14
Tesztelés	Négyzetes hiba összege	27,611
	Relatív hiba	0,156
Függő változó: keményítőtartalom		

Az MLP_SC2 becsült és a mért keményítőtartalom értékeinek összehasonlítását a 30. ábra mutatja be. Az első ábrán látható szóráskép alapján megfigyelhető, hogy az előrejelzett értékek általában a valós értékek körül helyezkednek el, ami a modell jó teljesítményére utal. Az MLP_SC1-hez hasonlóan azonban néhány esetben az előrejelzés pontatlanabb, különösen a magasabb keményítőtartalom értékeknél, ahol a szórás kissé megnövekedett.

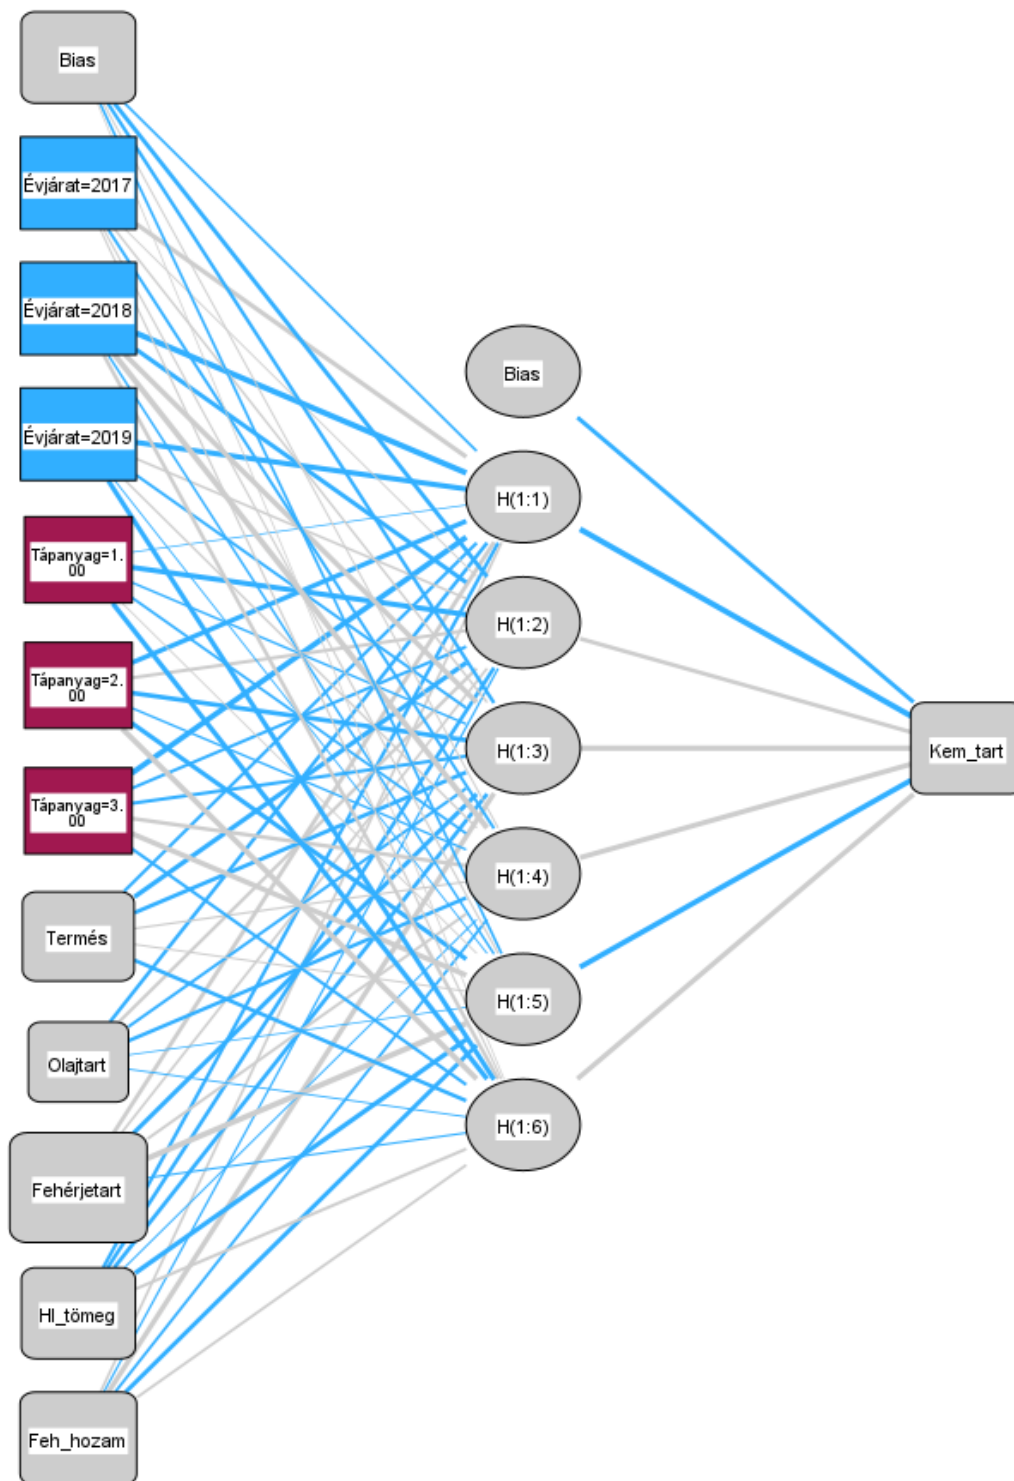
A bal oldali raincloud diagramon egyértelműen látszik, hogy a két eloszlás átfedése kevésbé pontos, mint az előző esetben, ahogyan azt a relatív hiba értékek alapján is feltételezni lehetett. Ettől függetlenül a modell középértékei közel állnak egymáshoz, ami szintén a modell kielégítő illeszkedését jelzi.



30. ábra: Az MLP_SC2 becsült értékeinek szórás- és raincloud diagramjai

A 31. ábra az MLP_SC3 forгатókönyv esetében mutatja be a hálózat felépítését és konfigurációját. A modell bemeneti rétege 8 db változóból épül fel. A változók között

megtalálhatók az évjárat, a tápanyagkezelések, a termés mennyisége, az olajtartalom, a fehérjetartalom, a hl-tömeg, a fehérjehozam és a keményítőhozam. A modell rejtett rétege összesen 9 neuront tartalmaz.



31. ábra Az MLP_SC3 scenárió modelljének szerkezeti felépítése

Az MLP_SC3 modell teljesítménye mind a tanítási, mind a tesztelési fázisban kedvezőnek bizonyult. A tanítási fázisban a négyzetes hibák összege 42,323 volt, míg a relatív hiba értéke 0,095, azaz a modell megfelelően illeszkedett a tanító adathalmazhoz. A képzési idő mindössze 0,05 másodperc volt, ami rendkívül gyorsnak tekinthető, és hasonlóan rövid, mint az MLP_SC1 modell esetében.

A tesztelési fázisban a modell továbbra is jó teljesítményt mutatott: a négyzetes hibák összege 26,979, a relatív hiba pedig 0,131 volt, tehát a modell általánosítási képessége megfelelő, és az előrejelzési pontosság a tanító adathalmazon kívüli minták esetében is megbízhatóan megmaradt. A modell előrejelzése tehát stabilnak mondható, különösen a korábbi MLP_SC2 modellhez képest, amelynél a tesztelési hiba nagyobb (27,611) és a relatív hiba is magasabb volt (0,156).


Az MLP_SC1 modellhez viszonyítva az MLP_SC3 valamivel magasabb négyzetes hibát mutat a tesztelési fázisban (SC1: 14,948, míg SC3: 26,979), de a relatív hiba csak kismértékben nagyobb (SC1: 0,069, azonban az SC3 esetében 0,131). Az MLP_SC3 modell tehát hatékonyságában a két előző modell közé helyezhető, azonban még mindig megbízhatónak tekinthető a keményítőtartalom előrejelzésében (10. táblázat).

10. táblázat: A modell teljesítménye az MLP_SC3 foratókönyv esetében

Modell összefoglaló		
Tanítás	Négyzetes hiba összege	42,323
	Relatív hiba	0,095
	Képzési idő	0:00:00.05
Tesztelés	Négyzetes hiba összege	26,979
	Relatív hiba	0,131
Függő változó: keményítőtartalom		

Az MLP_SC3 modell becsült és valós keményítőtartalom értékeinek összehasonlítását a 32. ábra szemlélteti. A szóráskép alapján megállapítható, hogy az előrejelzett értékek jellemzően a valós adatok körül helyezkednek el, tehát a modell alapvetően jól teljesít. Az MLP_SC1-hez hasonlóan azonban itt is előfordulnak pontatlanabb becslések, különösen a magasabb keményítőtartalom esetében, ahol a szórás enyhén megnövekedett. Az MLP_SC2-vel összevetve az MLP_SC3 modell illeszkedése valamivel pontosabb, amit a relatív hiba csökkenése is alátámaszt. A raincloud diagramon látható, hogy a becsült és a valós keményítőtartalom eloszlása jelentős mértékű átfedést mutat, ami a modell előrejelzési

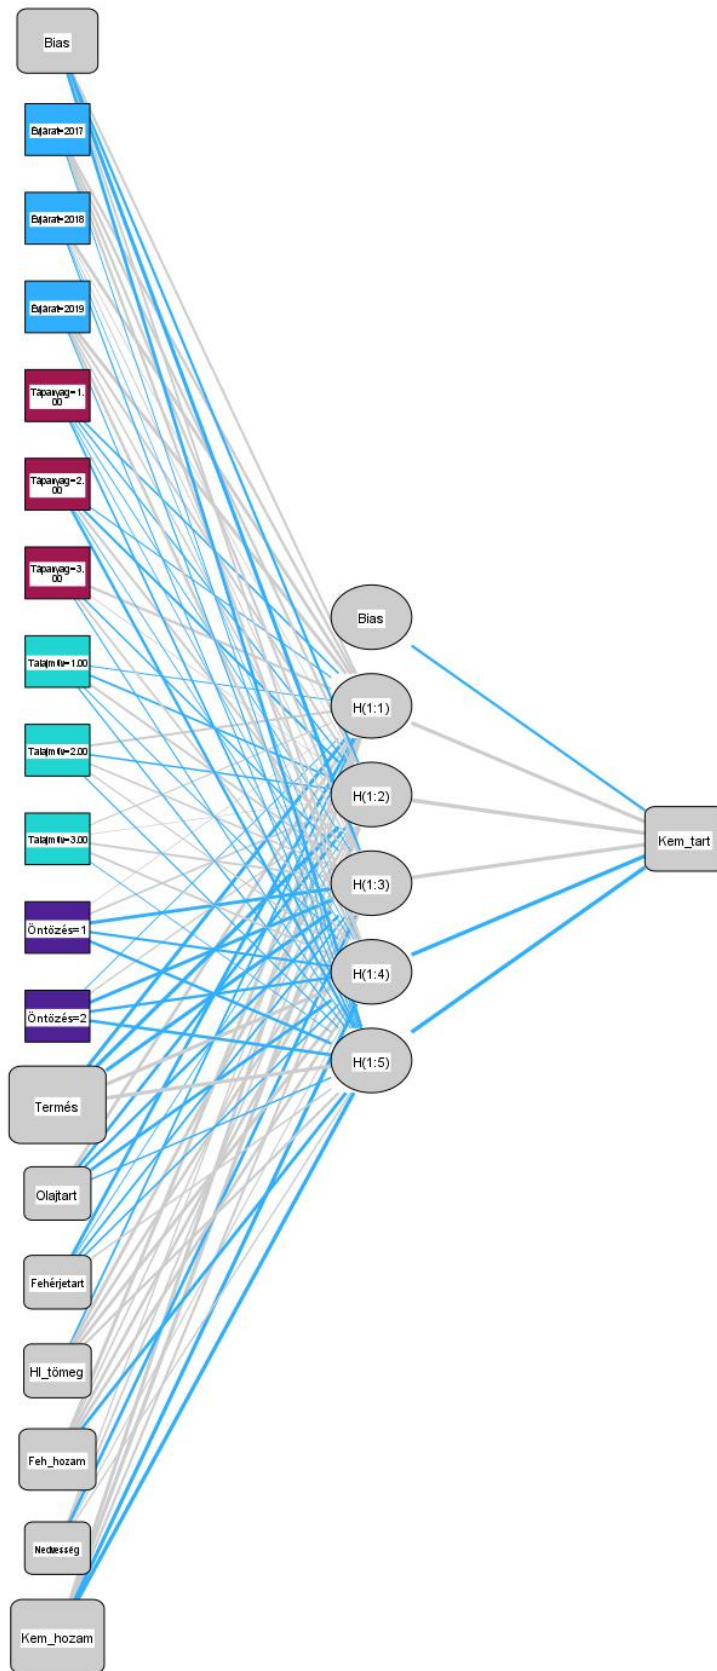
képességének stabilitását jelzi. Az eloszlások formája és a középértékek egymáshoz való közelsége alapján a modell képes a valós trendek követésére, így az előrejelzések összességében megbízhatónak tekinthetők. Az MLP_SC3 modell teljesítménye tehát kedvezőbb az MLP_SC2 modellhez viszonyítva, mivel az előrejelzési hibák mértéke kisebb, és az illeszkedési pontosság javulást mutat. Ugyanakkor az MLP_SC1 modellhez képest az előrejelzési pontosság némiképp elmarad, különösen a magasabb keményítőtartalom esetén. Ennek ellenére az MLP_SC3 modell előrejelzései stabilabbak és pontosabbak, mint az SC2 szcenárió esetében, így a modell továbbra is megbízhatónak tekinthető.



32. ábra: Az MLP_SC3 becsült értékeinek szórás- és raincloud diagramjai

A 33. ábra az MLP_SC4 forgatókönyv esetében mutatja be a hálózat felépítését és konfigurációját. A modell bemeneti rétege 11 db bemeneti változóból és azok alváltozóiból (összesen 18 változó) épül fel, amelyek az összes vizsgált agronómiai és technológiai paramétert tartalmazzák. A bemenetek között szerepel az évjárat, a tápanyagkezelések különböző szintjei, a talajművelési módok, az öntözési kezelések, valamint a termés mennyisége, az olajtartalom, a fehérjetartalom, a hl-tömeg, a fehérjehozam, a nedvességtartalom és a keményítőhozam. A modell rejtett rétege összesen 5 neuront tartalmaz.

Az összes bemeneti változó bevonásának célja annak megállapítása volt, hogy igaz-e az a gyakran hangoztatott hipotézis, miszerint az ANN modellek hatékonysága jelentősen függ a bemeneti változók számától. A teljes változókészlet bevonásával arra kerestem a választ, hogy a komplexitás növelése javítja-e a modell predikciós teljesítményét.



33. ábra Az MLP_SC4 szcenárió modelljének szerkezeti felépítése

Az MLP_SC4 modell teljesítménye mind a tanítási, mind a tesztelési fázisban kiemelkedőnek bizonyult. A tanítási fázisban a négyzetes hibák összege mindössze 17,173 volt, míg a relatív hiba értéke rendkívül alacsony, 0,038, ami egyértelműen jelzi, hogy a modell kiválóan illeszkedett a tanító adathalmazhoz. A képzési idő 0,29 másodperc volt, ami hosszabb, mint az MLP_SC1 és MLP_SC3 esetében, ugyanakkor figyelembe véve a bemeneti változók nagy számát és a komplexitást, ez a tanítási idő még mindig megfelelőnek tekinthető. A tesztelési fázisban a modell szintén kiváló teljesítményt mutatott: a négyzetes hibák összege mindössze 1,179, a relatív hiba pedig csupán 0,006 volt. A modell általánosítási képessége kimagasló és az előrejelzési pontosság a tanító adathalmazon kívüli minták esetében is megbízhatóan fennmaradt.

A modell előrejelzései tehát stabilnak és pontosnak mondhatók, különösen a korábbi MLP_SC2 modellhez képest, amelynél a tesztelési hiba jóval magasabb volt (27,611) és a relatív hiba is jelentősen nagyobb értéket mutatott (0,156). Az MLP_SC1 modellhez viszonyítva az MLP_SC4 jelentősen jobb eredményeket mutat mind a tanítási, mind a tesztelési fázisban. Míg az SC1 esetében a tesztelési szakaszban a négyzetes hiba összege 14,948 volt, az SC4 esetében ez az érték mindössze 1,179, ami több mint tízszeres javulást jelent. A relatív hiba tekintetében is hasonló tendencia figyelhető meg: az SC1 modell 0,069-es hibájához képest az SC4 mindössze 0,006-os relatív hibát produkált.

Az MLP_SC3 modellhez képest az SC4 szintén kiemelkedő javulást mutat. Az SC3 esetében a négyzetes hiba összege 26,979 volt, a relatív hiba pedig 0,131, míg az SC4 ezekhez képest lényegesen alacsonyabb hibákat mutatott.

Összességében elmondható tehát, hogy az MLP_SC4 modell minden tekintetben felülmúlta a korábbi három scenáriót, így a legjobb predikciós teljesítményt nyújtotta a vizsgált MLP modellek tekintetében.


11. táblázat: A modell teljesítménye az MLP_SC4 forgatókönyv esetében

Modell összefoglaló		
Tanítás	Négyzetes hiba összege	17,173
	Relatív hiba	0,038
	Képzési idő	0:00:00.29
Tesztelés	Négyzetes hiba összege	1,179
	Relatív hiba	0,006
Függő változó: keményítőtartalom		

Az eredmények azt támasztják alá, hogy a bemeneti változók számának növelése - feltéve, hogy azok releváns információt hordoznak - jelentősen növelheti az MLP modellek hatékonyságát és általánosítási képességét. (11. táblázat).

Az MLP_SC4 modell becsült és valós keményítőtartalom értékeinek összehasonlítását a 34. ábra szemlélteti. A szóráskép alapján egyértelműen megállapítható, hogy az előrejelzett értékek szinte pontosan a valós adatok mentén helyezkednek el, ami azt mutatja, hogy a modell kiemelkedően jól teljesít. A pontok szorosan követik az átlós trendvonalat, tehát az előrejelzések és a tényleges értékek közötti eltérés minimális. A szórás a magasabb keményítőtartalom értékeknél is rendkívül alacsony, ami az MLP_SC4 modell stabilitását és pontosságát mutatja. A raincloud diagramon látható, hogy a becsült és a valós keményítőtartalom eloszlása gyakorlatilag teljes mértékben átfed, ami a modell kivételes előrejelzési képességét bizonyítja. Az eloszlások alakja és a középértékek szinte teljes egyezése alapján az MLP_SC4 modell az eddigi vizsgálatok során a legjobb illeszkedést produkálta.

Összehasonlítva az MLP_SC1, MLP_SC2 és MLP_SC3 modellekkel, az MLP_SC4 modell egyértelműen a legpontosabb. Míg az előző modellek esetében a magasabb keményítőtartalom értékeknél enyhe szóródás tapasztalható volt, itt az előrejelzési hibák szinte teljesen eltűntek. Az MLP_SC4 tehát nemcsak az előrejelzési pontosság, hanem az általános stabilitás szempontjából is felülmúlja a korábbi scenáriókat, megerősítve azt az előzetes feltételezést, hogy az összes bemeneti változó bevonása jelentősen növeli a modell teljesítményét.



34. ábra: Az MLP_SC4 becsült értékeinek szórás- és raincloud diagramjai

A korábbi vizsgálatok során az MLP modellek teljesítményét a négyzetes hibák összege és a relatív hiba alapján értékeltem. Ezek a mutatók jól szemléltették az előrejelzési pontosságot mind a tanítási, mind a tesztelési fázisban, azonban amennyiben még átfogóbb képet kívánunk kapni a modell általános teljesítményéről és megbízhatóságáról, szükség van további teljesítménymutatók vizsgálatára, amelyek pontosabban mutatják be a forgatókönyvek közötti különbségeket.

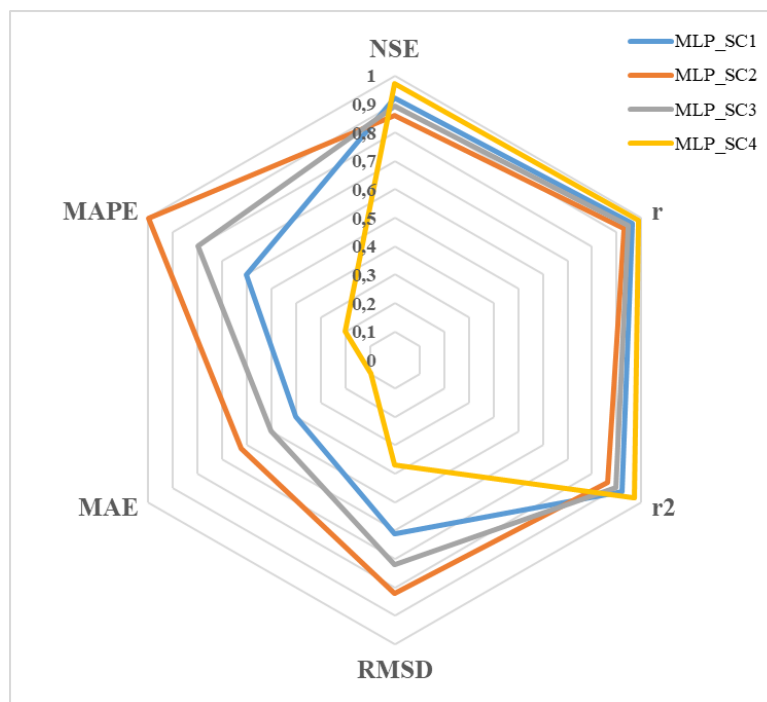
Ennek érdekében az alábbi hat mutatót számítottam ki minden egyes forgatókönyv esetében: Pearson-korrelációs együttható (r), determinációs együttható (r^2), négyzetes középeltérés (RMSD), Nash-Sutcliffe hatékonysági együttható (NSE), átlagos abszolút hiba (MAE) és átlagos abszolút százalékos hiba (MAPE). A kapott eredményeket a 12. táblázat foglalja össze.

12. táblázat: Az MLP modell forgatókönyveinek teljesítménye további teljesítménymutatók alapján

	Modell teljesítménymutatók					
	r	r²	RMSD	NSE	MAE	MAPE
MLP_SC1	0,961	0,923	0,611	0,923	0,401	0,6
MLP_SC2	0,928	0,861	0,820	0,861	0,623	1
MLP_SC3	0,945	0,894	0,718	0,894	0,501	0,8
MLP_SC4	0,986	0,972	0,368	0,972	0,098	0,2

A fenti táblázat egyértelműen bemutatja, hogy az MLP_SC4 modell az új mutatók szerint is minden szempontból a legjobb eredményt produkálta. A Pearson-korrelációs együttható (r) értéke 0,986, ami a legmagasabb az összes modell közül, jelezve az előrejelzett és a valós értékek közötti erős lineáris kapcsolatot. Az r^2 értéke (0,972) kiemelkedő, az RMSD értéke az MLP_SC4 modellnél a legalacsonyabb (0,368), míg az NSE értéke 0,972, ami a modell nagyfokú hatékonyságát támasztja alá, ahogyan a MAE és MAPE értékek is.

Az alábbi, 35. ábrán látható sugárdiagram is megerősíti az MLP_SC4 modell kiemelkedő teljesítményét. A diagram a 12. táblázat adatai alapján készült.



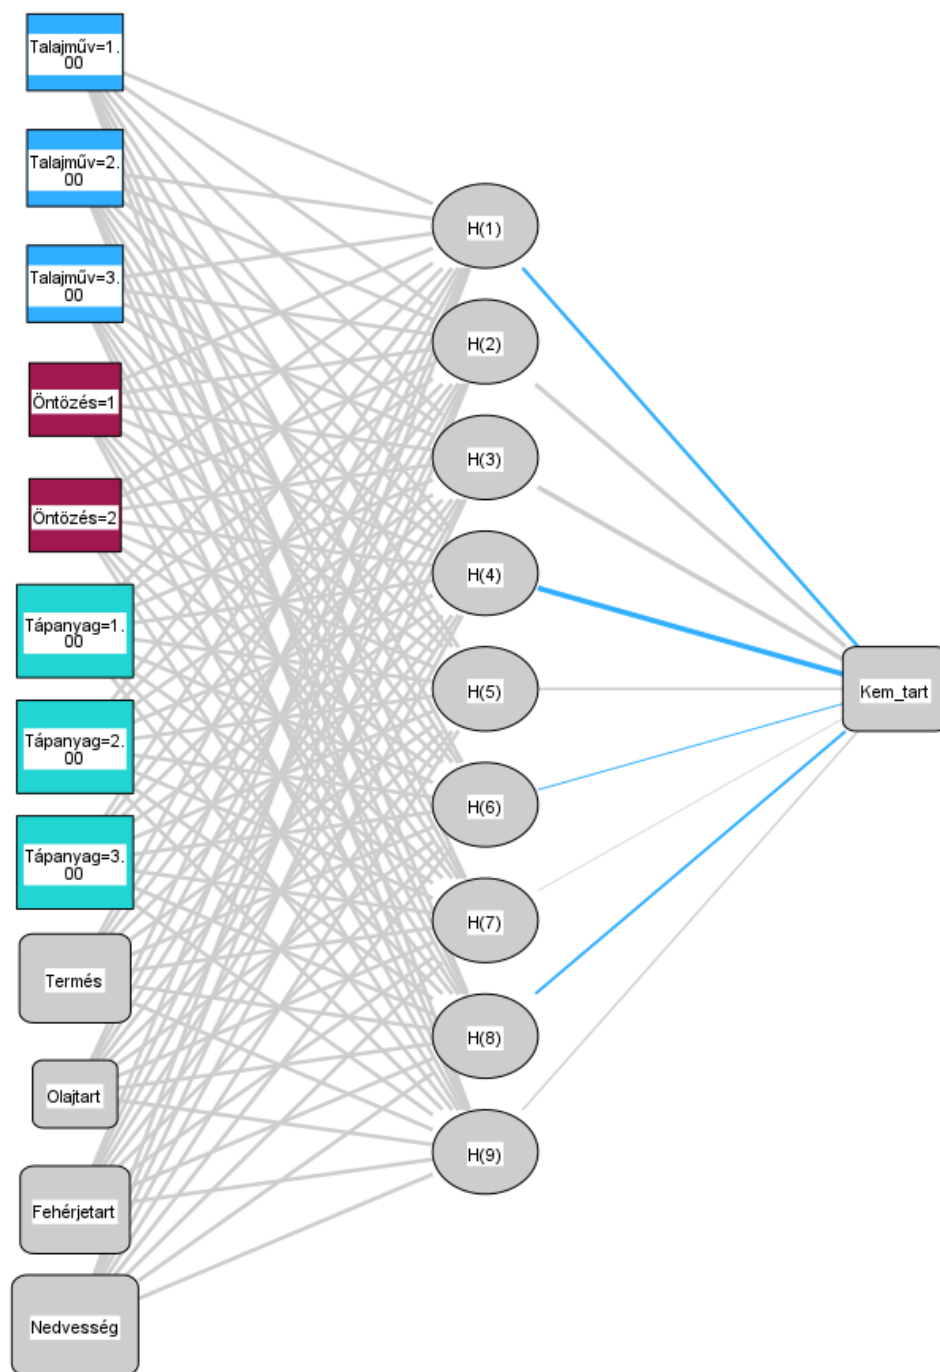
35. ábra: Az MLP modell további teljesítménymutatóit értékelő sugárdiagram (Saját szerkesztés)

A sugárdiagram átfogóan szemlélteti az MLP modellek teljesítménymutatóit. Az ábrán egyértelműen látszik, hogy az MLP_SC4 modell teljesítménye kiemelkedő: az r , r^2 és NSE értékei mind közel állnak az 1-hez, ami a modell kimagasló előrejelzési pontosságát és megbízhatóságát jelzi. Ezzel szemben az RMSD, a MAE és a MAPE az MLP_SC4 esetében a legalacsonyabb; ez azért fontos, mert az alacsony RMSD alapján a modell által becsült értékek szórása a valós értékek körül kicsi, tehát az előrejelzések stabilak és pontosak.

4.5.2. Az ANN-RBF modell eredményeinek bemutatása

A következő lépésben a radiális bázisfüggvény (RBF) modellt alkalmaztam a kukorica keményítőtartalmának előrejelzésére. Az RBF modell alkalmazása indokolt, mivel az előző fejezetben bemutatott MLP modellek ugyan jó eredményeket produkáltak, azonban felmerül a kérdés, hogy a nemlineáris összefüggések kezelésében az RBF modellek eltérő teljesítményt nyújtanak-e. Az RBF modellek különösen alkalmasak a bonyolult, nemlineáris kapcsolatok feltárására, mivel rejtett rétegeik hatékonyan kezelik a lokális mintázatokat és az adatpontok közötti távolságokat. Emiatt a célom annak vizsgálata, hogy az RBF modellek alkalmazása mennyiben hoz eltérő eredményt az MLP modellekhez képest a kukorica

keményítőtartalmának előrejelzésében. Az RBF modell alkalmazásával lehetőség nyílik a kukorica keményítőtartalmának az MLP-től eltérő jellegű előrejelzésére, így előfordulhat, hogy esetenként pontosabb eredményeket kapunk, különösen azokban az esetekben, ahol az MLP modellek teljesítménye nem volt optimális.



36. ábra Az RBF_SC1 szcenárió modelljének szerkezeti felépítése

Az elsőként elemzett forgatókönyv az **RBF_SC1**, amelynek szerkezeti felépítését a 36. ábra szemlélteti. Az RBF_SC1 modell bemeneti rétege az alváltozókkal együtt 12 db, összesen 7 db bemeneti változóból áll, amelyek a talajművelési módok, az öntözés, a tápanyagkezelések, valamint a termés mennyisége, az olajtartalom, a fehérjetartalom és a nedvességtartalom. A modell rejtett rétege 9 neuront tartalmaz.

A kimeneti réteg egyetlen változót tartalmaz, amely - az MLP modellekhez hasonlóan - továbbra is a keményítőtartalom előrejelzésére szolgál.

Az RBF_SC1 modell teljesítménye mind a tanítási, mind a tesztelési fázisban jelentős eltéréseket mutat az MLP_SC1 modellhez képest. Ahogyan a 13. táblázat adataiból is látható, a tanítási fázis során a négyzetes hibák összege 280,262 volt, míg a relatív hiba értéke 0,611, ami lényegesen magasabb, mint az MLP_SC1 esetében mért értékek. A képzési idő 0,34 másodperc volt, ami szintén hosszabb, mint az MLP modell esetében, bár ez még mindig viszonylag gyorsnak tekinthető.


A tesztelési fázisban a modell teljesítménye továbbra is gyengébb az MLP-hez képest: a négyzetes hibák összege 144,479, míg a relatív hiba 0,638 volt. Ez arra enged következtetni, hogy az RBF_SC1 modell általánosítási képessége korlátozott, emiatt a tanító adathalmazon kívüli mintákra adott előrejelzések pontossága elmarad az MLP modell eredményeitől.

13. táblázat: A modell teljesítménye az RBF_SC1 forgatókönyv esetében

Modell összefoglaló		
Tanítás	Négyzetes hiba összege	280,262
	Relatív hiba	0,611
	Képzési idő	0:00:00.34
Tesztelés	Négyzetes hiba összege	144,479
	Relatív hiba	0,638
Függő változó: keményítőtartalom		

A becült és a mért keményítőtartalom értékeinek összehasonlítását a 37. ábra mutatja be. A szóráskép alapján jól látható, hogy az előrejelzett értékek nem követik szorosan a valós értékeket, azaz az RBF modell előrejelzési pontossága ebben a scenárióban nem megfelelő. A pontok szétszóródása különösen a közepes keményítőtartalom-tartományban figyelhető meg, ahol az előrejelzések szisztematikusan eltérnek a valós adatoktól. Ez az eltérés a modell általánosítási képességének gyengeségére utal. A raincloud diagramon szintén jól látszik,

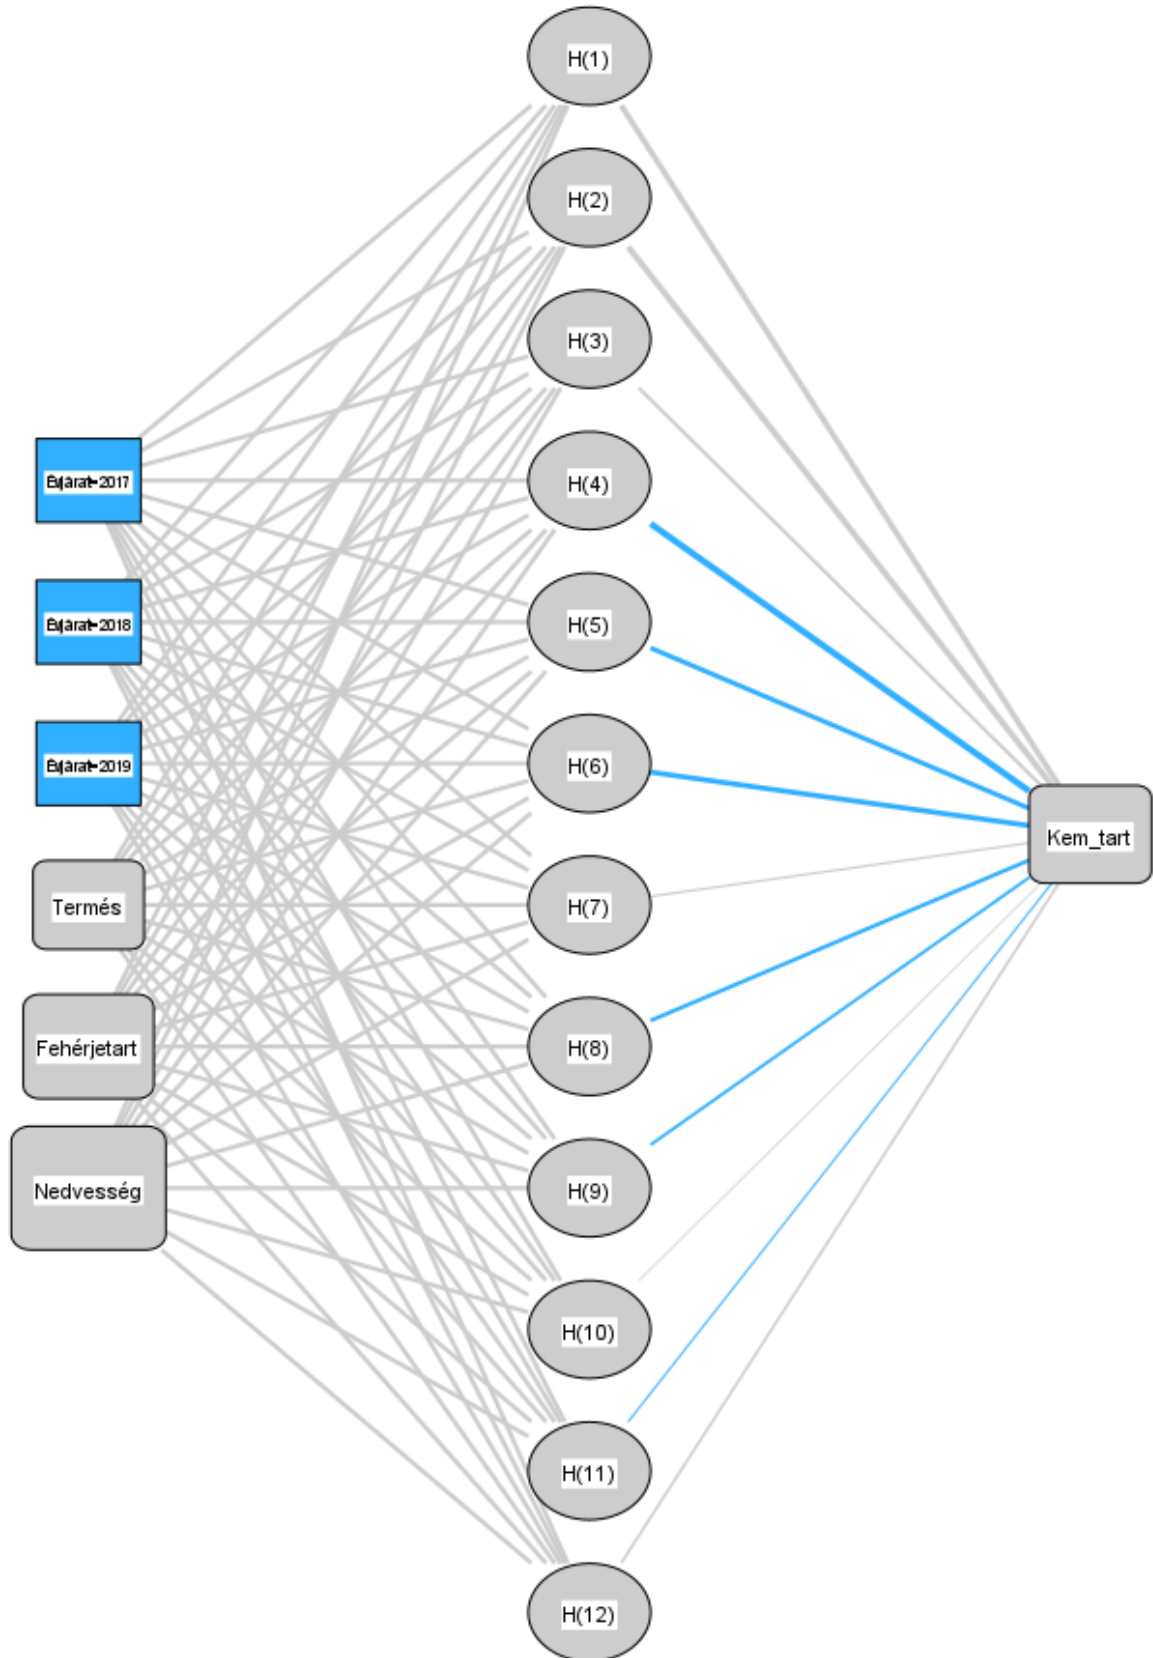
hogy az előrejelzett és a valós keményítőtartalom eloszlása között jelentős különbség van. Az előrejelzett adatok eloszlása szűkebb és eltolódott, azaz a modell nem tudta megfelelően leképezni az adatok változékonyságát. Az eloszlások közötti korlátozott átfedés tovább erősíti azt a megállapítást, hogy az RBF_SC1 modell nem biztosít kielégítő predikciós pontosságot ebben a scenárióban.



37. ábra: Az RBF_SC1 becsült értékeinek szórás- és raincloud diagramjai

A 38. ábrán látható, hogy az RBF_SC2 modell bemeneti rétege változók tekintetében megegyezik az MLP_SC2 modellel, mivel a scenáriók páronként kerültek kialakításra az összehasonlíthatóság érdekében. Így az RBF_SC2 modell bemeneti rétege 6 db input változóból áll, amelyek az évjárat (3 alváltozóként), a termés mennyisége, a fehérjetartalom és a nedvességtartalom.

A szerkezeti különbségek azonban jelentősek a két modell között. Míg az MLP_SC2 modell rejtett rétege 3 neuront tartalmaz, addig az RBF_SC2 modell rejtett rétege lényegesen komplexebb, összesen 12 neuront tartalmaz. Fontos megjegyezni, hogy a rejtett rétegek számának meghatározása automatizált folyamat volt, a szoftver határozta meg minden egyes scenárió rejtett rétegének összetételét a bemeneti változók és az alkalmazott modell alapján.



38. ábra Az RBF_SC2 scenárió modelljének szerkezeti felépítése

A 14. táblázat adatai alapján az RBF_SC2 modell teljesítménye mind a tanítási, mind a tesztelési fázisban jelentősen elmarad az MLP_SC2 modell eredményeitől. A tanítási fázis során a négyzetes hibák összege 95,621 volt, míg a relatív hiba értéke 0,212, ami viszonylag magasnak tekinthető, azaz a modell illeszkedése a tanító adathalmazhoz nem volt teljesen megfelelő. A képzési idő 0,36 másodperc volt, ami némileg hosszabb az RBF_SC1 modellhez képest, ugyanakkor továbbra is gyorsnak mondható a hálózat komplexitását figyelembe véve.

A tesztelési fázisban az RBF_SC2 modell teljesítménye továbbra is mérsékelt maradt: a négyzetes hibák összege 43,717, a relatív hiba pedig 0,214 volt. A modell általánosítási képessége ebben az esetben korlátozott volt, mivel a tesztelési adathalmazon mért hiba értékei magasabbak, mint amit egy jól illeszkedő modell esetében várnánk. Az eredmények alapján azonban elmondható, hogy az RBF_SC2 modell teljesítménye némiképp javult az RBF_SC1 szcenárióhoz képest.

14. táblázat: A modell teljesítménye az RBF_SC2 foratókönyv esetében


Modell összefoglaló		
Tanítás	Négyzetes hiba összege	95,621
	Relatív hiba	0,212
	Képzési idő	0:00:00.36
Tesztelés	Négyzetes hiba összege	43,717
	Relatív hiba	0,214
Függő változó: keményítőtartalom		

Az MLP_SC2 modellel való összevetés során egyértelműen látszik az eltérés: az MLP_SC2 tanítási fázisában a négyzetes hiba mindössze 58,893, míg a tesztelési fázisban 27,611 volt, ami lényegesen alacsonyabb az RBF modell értékeinél. A relatív hiba az MLP modell esetében szintén kedvezőbb volt (0,132 a tanítási és 0,156 a tesztelési fázisban), ami azt mutatja, hogy az MLP_SC2 modell megbízhatóbban általánosít, és a tanításon kívüli minták esetében is pontosabb előrejelzést biztosít.

Összességében az RBF_SC2 modell nem tudta felülmúlni MLP_SC2 modellt. Feltételezhető, hogy az RBF modell eltérően reagál a bemeneti változók jellegére és a hálózat szerkezetére.

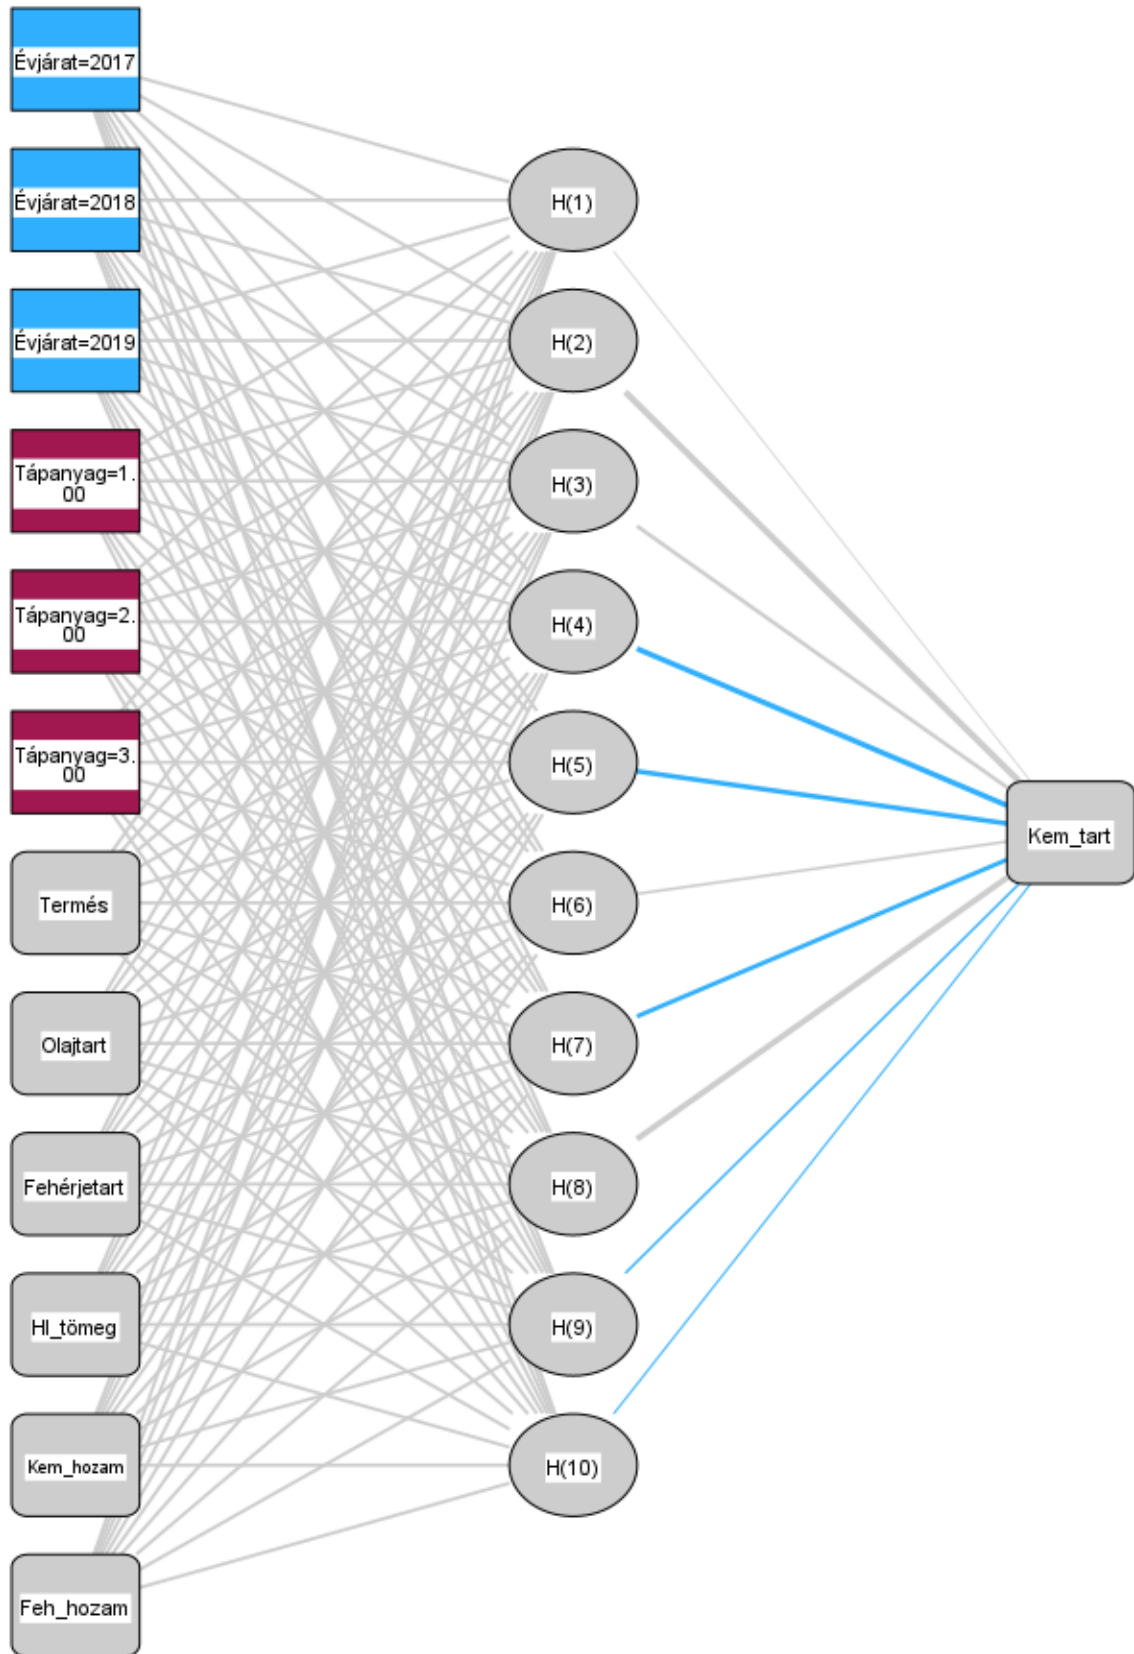
A 39. ábra szórásképe alapján jól látható, hogy az előrejelzett értékek nem követik szorosan a valós értékeket, tehát az RBF_SC2 modell előrejelzési pontossága ebben a scenárióban gyenge. Az ábrán megfigyelhető, hogy az előrejelzett értékek lépcsőzetes mintázatot mutatnak, tehát a modell bizonyos értéktartományokban nem képes megfelelően differenciálni a keményítőtartalom változásait. Ez különösen a közepes keményítőtartalom-tartományban figyelhető meg, ahol az előrejelzések szisztematikusan eltérnek a valós adatoktól. Ez a jelenség a modell általánosítási képességének hiányosságait jelzi.

A raincloud diagram szintén megerősíti ezt az értékelést: az előrejelzett és a valós keményítőtartalom eloszlása között jelentős eltérés van. Az előrejelzett adatok eloszlása szűkebb és torzult, ami azt mutatja, hogy a modell nem volt képes megfelelően leképezni a valós adatok variabilitását. Az eloszlások közötti korlátozott átfedés és a lépcsőzetes eloszlási mintázat alapján megállapítható, hogy az RBF_SC2 modell nem biztosít kielégítő predikációs pontosságot ebben a scenárióban.



39. ábra: Az RBF_SC2 becsült értékeinek szórás- és raincloud diagramjai

A 40. ábra az RBF_SC3 forgatókönyv hálózatának felépítését és konfigurációját mutatja be. Az RBF_SC3 modell bemeneti rétege 8 db (alváltozókkal együtt 12 db) bemeneti változóból épül fel. A bemenetek között megtalálhatók a talajművelési módok, az évjáráthatás, a termés mennyisége, az olajtartalom, a fehérjetartalom, a hl-tömeg, a fehérjehozam, valamint a keményítőhozam. A modell rejtett rétege 10 neuront tartalmaz.



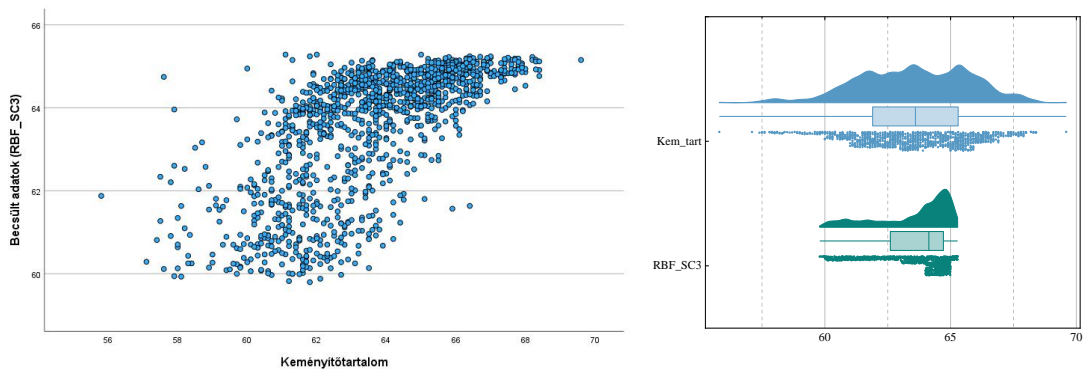
40. ábra Az RBF_SC3 scenárió modelljének szerkezeti felépítése

A 15. táblázat adatai alapján az RBF_SC3 modell teljesítménye mind a tanítási, mind a tesztelési fázisban jelentősen elmaradt az MLP_SC3 modell eredményeitől, és az eddig vizsgált RBF modellek között is az egyik leggyengébbnek bizonyult. A tanítási fázis során a négyzetes hibák összege 256,587 volt, míg a relatív hiba értéke 0,558, azaz a modell illeszkedése a tanító adathalmazhoz nem megfelelő. A képzési idő 0,78 másodperc volt, ami az eddigi RBF modellek közül a leghosszabb, jelezve a modell nagyobb számítási igényét. A hosszú képzési idő ellenére a tesztelési fázisban a modell továbbra is gyengén teljesített: a négyzetes hibák összege 98,352, a relatív hiba pedig 0,488 volt, ami korlátozott általánosítási képességre mutat. Az MLP_SC3 modellel összevetve az RBF_SC3 lényegesen gyengébb eredményeket mutat: az MLP_SC3 tesztelési négyzetes hibája mindössze 26,979, a relatív hibája pedig 0,131 volt. Az előző RBF modellekhez képest (RBF_SC1 és RBF_SC2) szintén alulteljesít, különösen a tesztelési fázisban, ahol a relatív hiba magasabb értéket mutat.

15. táblázat: A modell teljesítménye az RBF_SC3 foratókönyv esetében

Modell összefoglaló		
Tanítás	Négyzetes hiba összege	256,587
	Relatív hiba	0,558
	Képzési idő	0:00:00.78
Tesztelés	Négyzetes hiba összege	98,352
	Relatív hiba	0,488
Függő változó: keményítőtartalom		

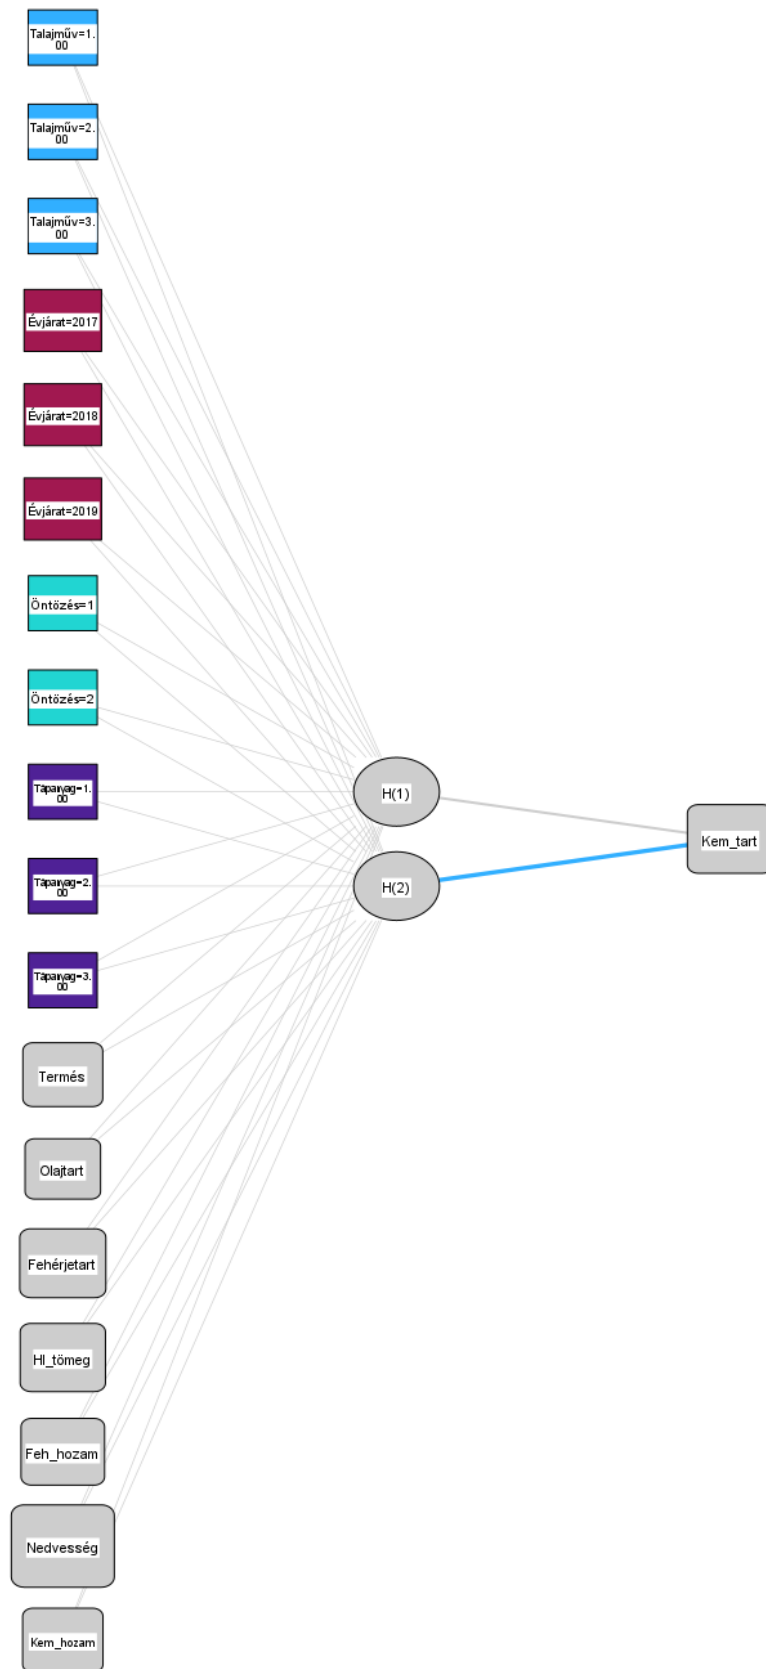
Az RBF_SC3 modell becsült és valós keményítőtartalom értékeinek összehasonlítását a 41. ábra tartalmazza. A szóráskép alapján megállapítható, hogy az előrejelzett értékek jelentős mértékben eltérnek a valós adatoktól, különösen a közepes keményítőtartományban. Az adatok szétszóródása és a becsült értékek rendezetlensége arra enged következtetni, hogy a modell nem volt képes megfelelően leképezni a keményítőtartalom és a bemeneti változók közötti összefüggéseket. A raincloud diagram szintén alátámasztja a modell gyengébb teljesítményét, mivel a becsült és a valós keményítőtartalom eloszlása között jelentős különbség mutatkozik. Az előrejelzett adatok eloszlása nemcsak szűkebb, hanem az eloszlás csúcsa is eltér a valós adatokétól, ami az előrejelzési pontosság hiányára utal.



41. ábra: Az RBF_SC3 becsült értékeinek szórás- és raincloud diagramjai

A 42. ábra az utolsó scenárió, az RBF_SC4 szerkezeti felépítését mutatja be. A modell szerkezete az MLP_SC4 modellhez hasonlóan az összes rendelkezésre álló bemeneti változót tartalmazza, hiszen az SC4 scenárió célja éppen az volt, hogy megvizsgáljam, mennyiben javul az előrejelzési pontosság, ha minden releváns változót bevonunk az elemzésbe. A bemeneti réteg így az alváltozókkal együtt 18 változóból áll, amelyek a talajművelési módok, az évjárat, az öntözés, a tápanyagkezelések, a termés mennyisége, az olajtartalom, a fehérjetartalom, a hl-tömeg, a fehérjehozam, a nedvességtartalom, valamint a keményítőhozam.

Az RBF_SC4 modell egyik legszembevetőbb eltérése az MLP_SC4 modellhez képest a rejtett réteg felépítéséhez kapcsolódik. Míg az MLP_SC4 modell rejtett rétege 10 neuront tartalmazott, addig az RBF_SC4 modell rejtett rétegében mindössze 2 neuron található. Ez az eltérés az RBF hálózat sajátosságaiból fakad, mivel a radiális bázisfüggvények esetenként kevesebb neuron alkalmazását teszik szükségessé. A kevesebb neuron alkalmazása viszont felveti azt a kérdést, hogy vajon az RBF modell mennyire képes ezekkel a feltételekkel pontosan kezelni az összes változót. Mindemelett, ahogyan a korábbi forgatókönyvek esetében már említésre került, a rejtett réteg paramétereinek meghatározása minden forgatókönyv esetében automatizált folyamat volt.



42. ábra Az RBF_SC4 scenárió modelljének szerkezeti felépítése

Az RBF_SC4 modell teljesítménye (16. táblázat) mérsékelten kielégítőnek tekinthető az RBF modellek között, azonban nem érte el az RBF_SC2 modell eredményeit, amely az RBF forgatókönyvek közül a legjobbnak bizonyult. A tanítási fázis során a négyzetes hibák összege 156,305 volt, a relatív hiba pedig 0,341, ami az RBF modellek között a második legjobb értéknek számít. A képzési idő 0,54 másodperc volt, ami a komplex bemeneti változók miatt valamelyest hosszabb, de még mindig gyorsnak tekinthető.


A tesztelési fázisban az RBF_SC4 modell teljesítménye javulást mutatott az SC1 és SC3 modellekhez képest: a négyzetes hibák összege 51,767, a relatív hiba pedig 0,307 volt. Ezek az értékek jobbak az RBF_SC1 (144,479 és 0,638) és RBF_SC3 (98,352 és 0,488) eredményeinél, ugyanakkor elmaradnak az RBF_SC2 modell eredményeitől, amelynél a tesztelési négyzetes hiba 43,717, a relatív hiba pedig 0,214 volt. A bemeneti változók teljes körű bevonása javított a predikciós pontosságon, de az eredmény elmaradt az SC2 scenáriótól. Megállapítható tehát, hogy az RBF-modell esetében megdőlt az a feltételezés, hogy a változók számának növelésével javul az előrejelzési hatékonyság, mivel nem a legtöbb változót tartalmazó forgatókönyv érte el a legjobb eredményt, ahogyan az MLP modell esetében.

16. táblázat: A modell teljesítménye az RBF_SC4 forgatókönyv esetében

Modell összefoglaló		
Tanítás	Négyzetes hiba összege	156,305
	Relatív hiba	0,341
	Képzési idő	0:00:00,54
Tesztelés	Négyzetes hiba összege	51,767
	Relatív hiba	0,307
Függő változó: keményítőtartalom		

Az RBF_SC4 modell becült és valós keményítőtartalom értékei közötti kapcsolatot a 43. ábra mutatja be. A bal oldalon látható szóráskép alapján az előrejelzett értékek bizonyos tartományokban sűrűsödnek, míg más szakaszokon szórtabbak, ez a predikció pontosságának heterogenitását és rendszertelenségét jelzi.

A raincloud diagramon az előrejelzett és valós adatok eloszlása között látható különbségek alapján a modell nem volt képes követni a keményítőtartalom változásait.



43. ábra: Az RBF_SC3 becsült értékeinek szórás- és raincloud diagramjai

Az MLP modell elemzéséhez hasonlóan ebben az esetben is további teljesítménymutatókat vizsgáltam. Az elemzés eredményeit a 17. táblázat mutatja be.

17. táblázat: Az MLP modell forgatókönyveinek teljesítménye további teljesítménymutatók alapján

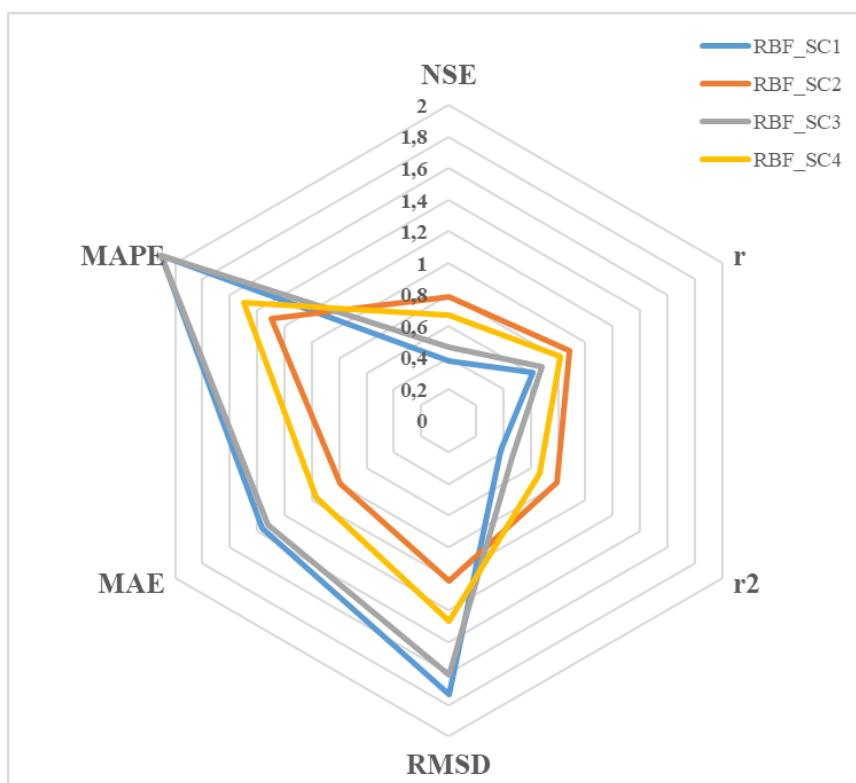
	Modell teljesítménymutatók					
	r	r²	RMSD	NSE	MAE	MAPE
MLP_SC1	0,617	0,381	1,732	0,381	1,362	2,1
MLP_SC2	0,887	0,787	1,015	0,787	0,797	1,3
MLP_SC3	0,681	0,463	1,612	0,463	1,323	2,1
MLP_SC4	0,818	0,669	1,266	0,669	0,971	1,5

A kibővített vizsgálat eredményei alapján is az RBF_SC2 modell bizonyult a legjobbnak a négy RBF forgatókönyv közül. Az r értéke 0,887, ami erős pozitív kapcsolatot jelez az előrejelzett és a valós értékek között. Az r^2 értéke 0,787, ami azt jelenti, hogy az előrejelzések a variancia jelentős részét magyarázzák. Az RMSD értéke viszonylag alacsony (1,015), míg az NSE mutatója 0,787, ami szintén a modell viszonylag jó teljesítményére utal.

Az RBF_SC4 modell szintén jónak mondható eredményeket ért el, azonban elmarad az SC2 mögött. Az r értéke 0,818, az r^2 pedig 0,669, ami mérsékelt erős kapcsolatot jelez. Az RMSD 1,266, míg az NSE értéke 0,669, ami megfelelő, de nem kiemelkedő teljesítményt jelez, hasonlóan a kapott MAE és MAPE értékekhez

Az RBF_SC3 és RBF_SC1 forgatókönyvek eredményei azonban jelentősen gyengébbek. Értékeik alapján ezek a modellek a többi scenárióhoz képest is kevésbé voltak alkalmasak a valós adatok leképezésére, és az előrejelzési pontosságuk alacsony.

A fenti adatok alapján készített sugárdiagram (44. ábra) szintén jól szemlélteti az RBF modellek közötti különbségeket. Egyértelműen látszik, hogy az RBF_SC2 modell teljesítménye a legkedvezőbb, mivel az r , r^2 és NSE értékei a legmagasabbak, míg az RMSD, MAE és MAPE értékei a legalacsonyabbak a vizsgált RBF modellek közül. Ez megerősíti a korábbi következtetést, miszerint az SC2 scenárió rendelkezik a legjobb előrejelzési képességgel az RBF forgatókönyvek között.



44. ábra: Az RBF modell további teljesítménymutatóit értékelő sugárdiagram (Saját szerkesztés)

4.5.3. Az MLP és RBF ANN algoritmusok teljesítménye a keményítőtartalom előrejelzésében

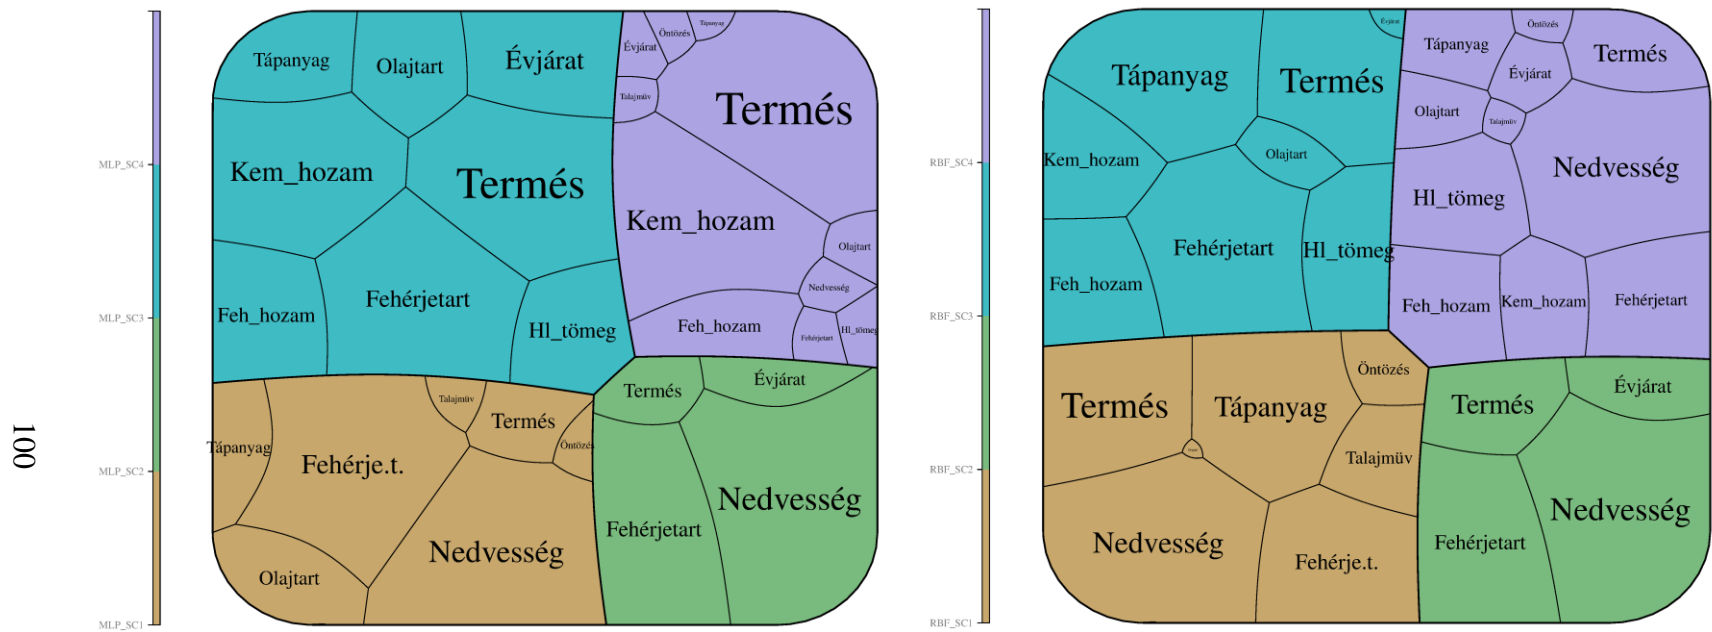
A fentiek alapján tehát kiderült, hogy az MLP modell minden esetben jobban teljesített, mint az RBF modell. Amellett, hogy a legjobb teljesítményű kombináció az MLP_SC4 volt, a legrosszabb pedig az RBF_SC1, az MLP modell legkevesbé hatékony forgatókönyve is felülmúlta a legjobb RBF forgatókönyvet. A 18. táblázat összefoglalva mutatja be az egyes forgatókönyvek paramétereit és hatékonysági mutatóit.

18. táblázat: A modellek alapvető paramétereinek, illetve teljesítményének összefoglalása

Modell	Input változók száma (db)	Inputváltozók száma alváltozókkal együtt (db)	Rejtett réteg neuronjai (db)	Képzési idő (s)	Tanítás		Tesztelés	
					Négyzetes hibák összege	Relatív hiba	Négyzetes hibák összege	Relatív hiba
MLP_SC1	7	12	10	0,05	36,536	0,081	14,948	0,069
MLP_SC2	4	6	3	0,14	59,893	0,132	27,611	0,156
MLP_SC3	8	12	9	0,05	42,323	0,095	26,979	0,131
MLP_SC4	11	18	5	0,29	17,173	0,038	1,179	0,006
RBF_SC1	7	12	9	0,34	280,262	0,611	144,479	0,638
RBF_SC2	4	6	12	0,36	95,621	0,212	43,717	0,214
RBF_SC3	8	12	10	0,78	256,587	0,558	98,352	0,488
RBF_SC4	11	18	2	0,54	156,305	0,341	51,767	0,307


Az eredmények alapján egyértelműen igazolódott, hogy a keményítőtartalom becslésére az MLP modell hatékonyabbnak bizonyult, mint az RBF. Az összehasonlító vizsgálatok során az RBF valamennyi scenárióban magasabb relatív hibákat produkált (0,214–0,638 között), míg az MLP esetében lényegesen alacsonyabb hibák jelentkeztek, különösen az MLP_SC4 scenárióban, ahol a relatív hiba a tesztelési adathalmazon mindössze 0,006 volt (a 18. táblázatban zöld színnel jelölve).

Az elemzések során az egyes scenáriók esetében meghatározásra került az inputváltozók normalizált fontossága, azaz hogy az adott modell az egyes forgatókönyvek esetében mely változókat ítélte a legjelentősebbeknek a predikció szempontjából. A vizsgálatok egyértelműen rámutattak arra, hogy a nedvességtartalom szinte minden scenárióban kulcsszerepet játszott, hiszen hat futtatásból öt esetben (3-3 scenárióban szerepelt ez a változó) a legfontosabb prediktornak bizonyult, modellfüggetlenül. Ez mutatja, hogy a betakarításkori szemnedvesség általánosan erős kapcsolatban állt a keményítőtartalom alakulásával a modellek szerint. Az RBF esetében a nedvesség mellett több esetben a tápanyagellátás is hangsúlyos szerepet kapott, míg az MLP modell a nedvesség kiemelése mellett többváltozós szerkezetet mutatott, és a termést, a keményítőhozamot és a fehérjetartalmat is fontos prediktorként kezelte. Megállapítható, hogy az MLP modell nemcsak a becslési hatékonyságban, hanem a magyarázó tényezők rangsorolásában is pontosabban teljesített. Az eredmények részben összhangban vannak a korábban készített korrelációs mátrixok alapján feltárt kapcsolatokkal is, hiszen az MLP által fontosnak ítélt változók (pl. keményítőhozam, fehérjetartalom) mind erős pozitív vagy negatív összefüggést mutattak a keményítőtartalommal, így az MLP nem csupán tanulási szempontból teljesített jobban, hanem a tényleges biológiai és agronómiai kapcsolatokra is hatékonyabban reflektált. A normalizált fontosságokat bemutató Voronoi-diagramok (45. ábra) szintén jól szemléltetik ezt a különbséget. Ugyanakkor érdemes kiemelni, hogy az RBF által fontosnak ítélt tényezők mögött is valós biológiai összefüggések húzódnak: korábbi vizsgálatokban például kimutatható volt, hogy a magas tápanyagdózisok negatív korrelációban álltak a keményítőtartalommal, azaz a kontroll parcellákon mérték a legmagasabb értékeket. Ezt a negatív kapcsolatot az RBF modell megfelelően jelezte, még ha a predikciós pontosság tekintetében az MLP felül is múlta.




45. ábra: Az MLP és RBF modellek inputváltozóinak normalizált fontossága az egyes szcenáriókban (Saját szerkesztés)

A 46 és 47. ábrán látható Taylor-diagramok összefoglaló módon szemléltetik a forgatókönyvek előrejelzési teljesítményét. A diagram célja, hogy egyetlen ábrán vizuálisan hasonlítsa össze a modellek predikciós pontosságát a megfigyelt értékekkel, a szórás, a korrelációs együttható és a középhiba együttes figyelembevételével. Az ábrán jól látható, hogy az MLP_SC4 modell helyezkedik el legközelebb a referencia tartományhoz, ami azt jelenti, hogy ez a modell rendelkezik a legmagasabb predikciós hatékonysággal és a legpontosabb illeszkedéssel.




46. ábra Az MLP modellben alkalmazott forgatókönyvek hatékonyságának ábrázolása Taylor-diagram segítségével

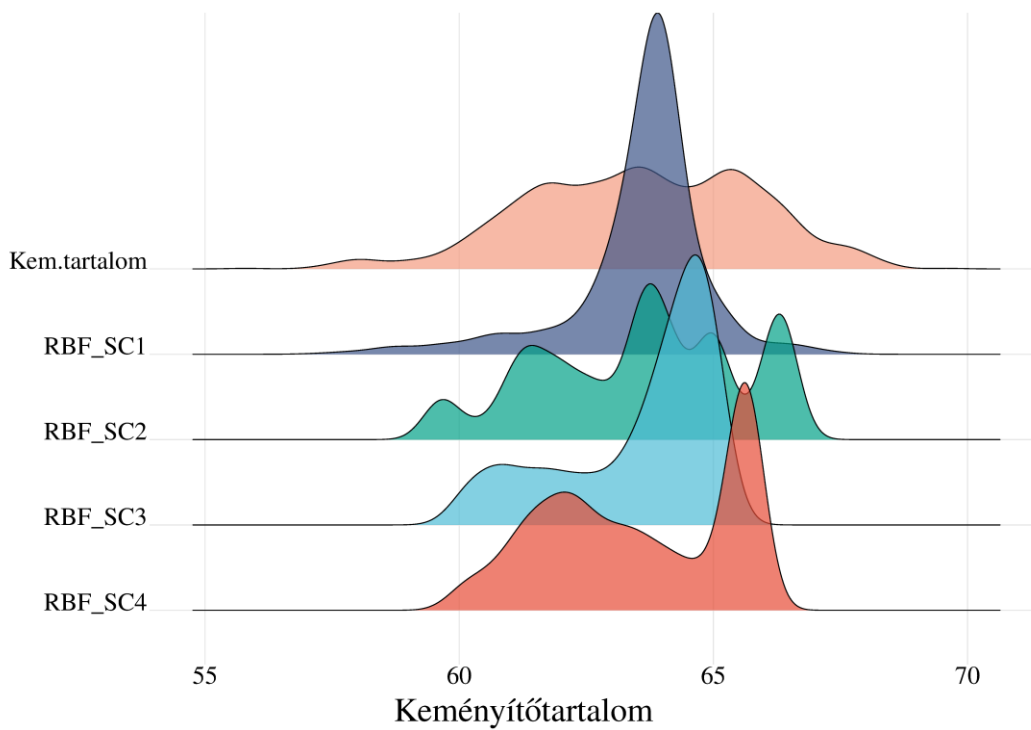


47. ábra Az RBF modellben alkalmazott forgatókönyvek hatékonyságának ábrázolása Taylor-diagram segítségével

Végül, a mesterséges neurális hálózat (ANN) algoritmusok - a többrétegű perceptron (MLP) és a radialis bázisfüggvény (RBF) - hatékonyságának összehasonlító elemzése érdekében a keményítőtartalom előrejelzésében a 48. és 49. ábrán látható ridgeline diagramokat alkalmaztam. E grafikonok vizsgálatakor nyilvánvalóvá válik, hogy az MLP algoritmus által generált előrejelző kimenet nagyobb fokú hasonlóságot mutat a megfigyelt mérésekkel. Ezzel szemben az RBF algoritmus előrejelző képessége kevésbé pontos ebben az összefüggésben.



48. ábra A megfigyelt és az ANN-MLP alapján megjósolt értékek ridgeline diagramjai a vizsgált forgatókönyvek esetében.



49. ábra A megfigyelt és az ANN-MLP alapján megjósolt értékek ridgeline diagramjai a vizsgált forgatókönyvek esetében.

5. KÖVETKEZTETÉSEK, JAVASLATOK

A kukorica szemtermésének keményítőtartalmát célzó vizsgálatok három év adatai alapján igazolták, hogy e beltartalmi paraméter közepes mértékű, de jól értelmezhető évjáratonkénti eltéréseket mutat. A 2018-as év kiemelkedett a sorból, átlagosan 65,76%-os keményítőtartalommal, míg a 2017-es és 2019-es évek közepes értékeket eredményeztek (61,83% és 62,93%). A 2018-as év kedvező klimatikus viszonyai nemcsak a beltartalom szintjére, de annak stabilitására is pozitívan hatottak: a keményítőtartalom szórása ebben az évben volt a legalacsonyabb, ami homogénebb minőséget tükröz.

A korrelációs elemzések alapján világosan kirajzolódott, hogy a keményítőtartalom és a fehérjetartalom között évről évre fennállt az erős negatív kapcsolat (összevontan $p = -0,72$), amit a nedvességtartalomhoz való viszony tovább erősített ($p = -0,78$). Ezek az összefüggések az anyagcsere-folyamatok biológiai alapjait tükrözik: a nitrogén-intenzív anyagcserét folytató növények nagyobb arányban építenek be fehérjét, miközben a keményítő-szintézis háttérbe szorul. E tendencia nemcsak az élettani háttér szempontjából fontos, de gyakorlati vonatkozásai is jelentősek, hiszen a tárolhatóság, ipari feldolgozhatóság és energiaérték szempontjából a keményítőtartalom preferált jellemző.

Az ANOVA és LSD tesztek megerősítették, hogy a keményítőtartalomra a legnagyobb befolyást az évjárat és a műtrágyázás gyakorolja. A kontroll parcellák minden esetben magasabb keményítőtartalommal rendelkeztek, míg a 160 kg N ha^{-1} kezelés a beltartalom csökkenésével járt együtt. Ugyanakkor ugyanezen magas N-dózis biztosította a legnagyobb keményítőhozamot (2018-ban pl. $7,69 \text{ t ha}^{-1}$), jelezve, hogy a mennyiségi és minőségi paraméterek nem minden esetben mozdíthatók el párhuzamosan. A terméshozam és keményítőhozam között rendkívül erős pozitív korreláció mutatkozott ($p = 0,94$), ezzel szemben a keményítőtartalom és terméshozam között – különösen 2017-ben – mérsékelt negatív kapcsolat állt fenn ($p = -0,51$).

A PCA-elemzés több szempontból is megerősítette a korábbi statisztikai következtetéseket. A főkomponensek mentén az évjáratok jól elkülönültek, különösen a 2018-as minták képeztek jól definiált klasztert, míg a talajművelési módok nem voltak egyértelműen szétválaszthatók, azaz a beltartalmi értékek alakulását leginkább az évjárat, konkrétan az

adott év meteorológiai sajátosságai dominálták, míg a művelési módok inkább közvetett hatásként érvényesültek.

A tápanyagkezelések viszont jól szétváltak a PCA elemzés során: a kontroll parcellák világosan elkülönültek a műtrágyázott kezelésektől. Ez az eredmény teljes összhangban állt az ANOVA tesztek és Wilcoxon-elemzések eredményeivel, amelyek szintén szignifikáns különbségeket mutattak ki a különböző műtrágyázakezelések között ($p < 0,001$). A legmagasabb keményítőtartalmat minden évben a kontrollparcellák produkálták, a legnagyobb N-kezelés pedig a legalacsonyabbat.

A gépi tanulási modellek alkalmazása során a legjobb eredményeket a többrétegű perceptron (MLP) modell SC4 változata érte el, amely az összes releváns bemeneti paramétert tartalmazta. A modell predikciója rendkívül pontosnak bizonyult: 0,006 relatív hiba, 0,986 Pearson-korreláció és 0,972 determinációs együttható jellemezte a tesztelési szakaszt. Ezzel szemben az RBF modellek jelentősen gyengébb teljesítményt mutattak, még a legjobb konfiguráció esetén is (SC2 relatív hiba: 0,214), jelezve, hogy az MLP hálózat nemcsak pontosabb, de stabilabb is az adatszerkezet változásai mellett. A bemeneti változók számának növelése egyértelműen javította az előrejelzési teljesítményt, ami rámutat az inputválasztás stratégiai jelentőségére.

A kutatás alapján világossá vált, hogy a kukorica keményítőtartalmának alakulását dominánsan az évjárat hatások és a nitrogénellátás szabályozzák, míg a talajművelés hatása közvetett és az adott környezeti kontextusban érvényesül. A gépi tanulási modellek különösen alkalmasak a komplex mintázatok feltárására, és a mezőgazdasági beltartalmi predikációs rendszerek szerves részévé válhatnak.

Javaslatok:

- A termesztéstechnológia tervezése során elsődlegesen az évjáratok kockázataira és a tápanyagellátás hatására kell figyelmet fordítani;
- A magas N dózisokat célszerű elkerülni, amennyiben a cél a magas keményítőtartalom;
- A fajtaszelekció során előnyt kell élvezzenek azok a hibridek, amelyek alacsony fehérjetartalom mellett is magas keményítőszerintet képesek biztosítani;
- Az MLP-alapú prediktív modellek bevezetése a precíziós mezőgazdasági gyakorlatba megkönnyítheti a beltartalom előrejelzését és az inputoptimalizálást;
- A jövőben érdemes a modellpalettát bővíteni más gépi tanulási módszerekkel (pl. Random Forest, SVM, XGBoost), amelyek tovább növelhetik az előrejelzések pontosságát.

6. ÚJ TUDOMÁNYOS EREDMÉNYEK

1. Az évjáráthatás szignifikánsan befolyásolta a keményítőtartalmat. Az ANOVA és LSD tesztek alapján bizonyítást nyert, hogy a kukorica szemtermésének keményítőtartalma szignifikáns eltérést mutatott az évjáratok között. A 2018-as évjáratban mért átlagos keményítőtartalom (65,76%) szignifikánsan magasabb volt mind a 2017-es (61,78%), mind a 2019-es (62,93%) évhez képest (LSD $p < 0,01$), ami az évjárat sajátosságainak kiemelt szerepét igazolja a beltartalom alakulásában a vizsgált helyszínen és időszakban.
2. A vizsgált években a műtrágyadózisok növekedése csökkentette a keményítőtartalmat. A három különböző tápanyagkezelés (kontroll, 80 kg N ha^{-1} , 160 kg N ha^{-1}) összehasonlítása során statisztikailag szignifikáns különbség mutatkozott a keményítőtartalom esetében. A kontroll kezelés esetén mért átlagos keményítőtartalom 65,01% volt, míg a legmagasabb nitrogénszint mellett ez 60,67%-ra csökkent (LSD $p < 0,001$). Ez az eredmény a vizsgált kísérleti körülmények és évek esetében bizonyítja azt a feltételezést, hogy a magasabb N-dózisok a keményítőtartalom csökkenéséhez vezetnek, azonban mivel a terméshozamot növelik, a fajlagos keményítőhozamra is pozitív hatást gyakorolnak.
3. A kukorica keményítőtartalma és fehérjetartalma között erős negatív korreláció mutatkozott. A Spearman-féle korrelációs elemzés alapján az adatok összevont vizsgálatánál $-0,72$ korrelációs együttható volt kimutatható a keményítőtartalom és a fehérjetartalom között. A kapott eredmény azt bizonyítja, hogy a vizsgált időszak és a kísérlet körülményei tekintetében teljesült az előzetes feltételezés, amely a fenti negatív korrelációra vonatkozott. Az eredményt továbbá alátámasztják az ANN vizsgálatok (különösen a legjobb eredményt hozó MLP_SC4 scenárió) inputváltozói esetében kapott normalizált fontossági adatok, ahol a fehérjetartalom kiemelkedő szereppel bírt, mint fontos befolyásoló tényező a keményítőtartalom becslésekor.
4. A többrétegű perceptron (MLP) modell kiemelkedő pontossággal becsülte meg a keményítőtartalmat. A gépi tanulási elemzés során az MLP_SC4 modell a tesztelési szakaszban $0,006$ relatív hibát, $0,986$ Pearson-korrelációs együtthatót és $0,972$ Nash-Sutcliff értéket ért el, ami rendkívül pontos illeszkedést mutat a tényleges értékekhez. A

modell teljesítménye felülmúlta az összes RBF alapú modellt és más scenáriókat, igazolva az MLP-modell jobb hatékonyságát a mezőgazdasági beltartalom-predikcióban. Ezzel kisparcellás szántóföldi kukorica kísérlet és az abból származó szerteágazó adattípusok esetén is teljesült a kutatás elején megfogalmazott egyik feltételezés, nevezetesen, hogy az MLP modell hatékonyabb becslést ad majd mint az RBF modell.

7. GYAKORLATBAN ALKALMAZHATÓ EREDMÉNYEK

A kutatás során feltárt eredmények számos módon hozzájárulhatnak a korszerű kukoricatermesztés gyakorlati fejlesztéséhez. A keményítőtartalom – mint iparilag és takarmányozás szempontjából is kiemelt jelentőségű beltartalmi mutató – alakítását célzó döntések szempontjából kulcsfontosságú, hogy mely környezeti és agrotechnikai tényezők gyakorolnak rá mérhető hatást.

A többéves eredmények alapján egyértelmű, hogy a nitrogéntrágyázás intenzitásának visszafogása jelentősen javíthatja a keményítőtartalmat. A legmagasabb N-dózis alkalmazása esetén a keményítőtartalom jelentősen csökkent a kontrollhoz képest, ami közvetlen hatással van az ipari feldolgozhatóságra és tárolhatóságra. A fentiek alapján a hozam maximalizálása nem minden esetben jár együtt a minőség javulásával, és a beltartalom optimalizálása érdekében a tápanyag-utánpótlási stratégiát differenciáltan, célzottan célszerű megtervezni.

A talajművelési módok közül a lazításos technológia bizonyult a leginkább kedvezőnek a keményítőhozam szempontjából, különösen aszályos évjáratokban. A mélyebb gyökérszónák feltárása tehát javítja a vízhasznosítást, ami közvetve a keményítőtartalom stabilizálását is elősegíti.

A kutatás során alkalmazott MLP típusú gépi tanulási modellek a keményítőtartalom előrejelzésében kiemelkedő pontosságot értek el. Ez alapot nyújthat precíziós döntéstámogató rendszerek fejlesztéséhez, amelyek valós időben képesek előrejelezni a beltartalmi értékeket termőhely, technológia és évjáratok alapján.

Eredményeim hozzájárulnak ahhoz, hogy a termelők és nemesítők egyaránt képesek legyenek célzott, adatvezérelt módon befolyásolni a keményítőtartalmat, növelve ezzel a kukoricatermesztés gazdasági és minőségi hatékonyságát.

8. ÖSSZEFOGLALÁS (magyar nyelven)

A globális élelmezésbiztonság egyik kulcskérdése a mezőgazdasági termelés hatékonyságának és minőségének fenntartása és fejlesztése. A kukorica (*Zea mays L.*) mint stratégiai jelentőségű növény központi szerepet játszik az élelmiszer-, takarmány- és ipari alapanyag-ellátásban. A kukorica szemtermésének keményítőtartalma – mint beltartalmi minőségi mutató – különösen fontos a tápérték, a feldolgozhatóság és a gazdaságosság szempontjából. Jelen doktori értekezés célja az volt, hogy feltárja a keményítőtartalom alakulását befolyásoló környezeti és agrotechnikai tényezőket, valamint azok előrejelzésére alkalmas gépi tanulási modelleket vizsgáljon meg és bemutassa azok hatékonyságát. A kutatás a Debreceni Egyetem látóképi kísérleti telepén valósult meg, három egymást követő év (2017–2019) kisparcellás tartamkísérleteinek adataira támaszkodva. A vizsgálatok során három eltérő talajművelési rendszer (őszi szántás, sávos művelés, lazítás) és három műtrágyakezelés (kontroll, N 80 – P₂O₅ 60 – K₂O 90 kg ha⁻¹, illetve N 160 – P₂O₅ 60 – K₂O 90 kg ha⁻¹) hatását vizsgáltam a keményítőtartalom változásaira vonatkozóan. Az adatfeldolgozáshoz klasszikus statisztikai módszereket (leíró statisztika, korrelációanalízis, ANOVA, LSD-teszt, Wilcoxon-próba) és multivariáns eljárásokat (PCA) is alkalmaztam. A különböző módszerek eredményei az alábbi következtetésekhez vezettek: a keményítőtartalmat legnagyobb mértékben az évjárat (klimatikus tényezők) és a trágyázási szint befolyásolta, míg a talajművelés hatása mérsékeltebb volt.

Az eredmények alapján egyértelművé vált, hogy a kedvező éghajlati feltételek – különösen a vegetációs időszak csapadéeloszlása és hőmérsékleti dinamikája – kedvezően hatnak a szemtermés beltartalmi mutatóira. A csapadékosabb évjáratban nemcsak a hozam, hanem a keményítőtartalom is magasabb értékeket mutatott, míg a szárazabb években jelentős csökkenést figyeltem meg. Ez alátámasztja az évjárat hatás kritikus szerepét a minőségi mutatók szempontjából. A tápanyagellátás vizsgálata során kimutattam, hogy a közepes dózisú műtrágyakezelés (N80 kg ha⁻¹ + PK) biztosította az optimális egyensúlyt a hozam és a keményítőtartalom között. A legmagasabb dózisú kezelés (N160 kg ha⁻¹ + PK) viszont több évben is jelentős keményítőtartalom-csökkenést eredményezett, különösen a vízellátottság szempontjából stresszesebb időszakokban. Ennek hátterében az áll, hogy a nitrogén túladagolása hátrányosan befolyásolja a szénhidrát-anyagcserét és ezáltal a keményítőszintézist. A talajművelési módok hatása differenciáltan jelent meg a különböző évjáratokban. Az őszi szántás

biztosította a legkiegyensúlyozottabb eredményeket, míg a lazítás és a sávos művelés bizonyos évjáratokban – különösen a szárazabbakban – kedvezőbb hatást gyakorolt a keményítőtartalomra. A gépi tanulási eljárások közül a mesterséges neurális hálózatokat (ANN) alkalmaztam, azon belül is a többrétegű perceptron (MLP) és a radiális bázisfüggvény (RBF) hálózatokat. A modellek tanítását különböző forгатókönyvek szerint végeztem, eltérő számú és típusú bemeneti változók bevonásával. Az MLP-modellek minden értékelési mutató alapján jobban teljesítettek, mint az RBF-hálózatok: alacsonyabb hibával, magasabb determinációs együtthatóval és nagyobb robusztussággal működtek. A legjobb predikciós teljesítményt nyújtó modell (MLP_SC4) közel tökéletes illeszkedést mutatott a valós adatokhoz, amely megerősítette a mesterséges neurális hálózatok alkalmazhatóságát a mezőgazdasági prediktív modellezés területén. Az eredmények azt is igazolták, hogy a bemeneti paraméterek számának növelése – például a meteorológiai, talajtani és agrotechnikai adatok kombinálása – szignifikánsan növeli a modellek előrejelzési pontosságát.

Kutatásom hozzájárul az agrárdigitalizáció fejlesztéséhez, mivel bemutatja, hogy a hagyományos statisztikai eszközökkel nyert eredmények jól összeegyeztethetők a gépi tanulási technológiák által kínált modellekkel. Ez lehetőséget teremt arra, hogy a kukoricatermelők a jövőben helyspecifikus, adatvezérelt döntéseket hozzanak, növelve ezzel a termelés fenntarthatóságát és jövedelmezőségét. A további kutatások során célom a predikciós modellek bővítése más algoritmusokkal (pl. Random Forest, XGBoost, Deep Learning), valamint távérzékelési adatok és térinformatikai rendszerek integrálása. Ezek révén a predikciók nemcsak pontosabbak, hanem térben is részletesebbek lehetnek.

Összességében az értekezés igazolta, hogy a kukorica keményítőtartalmának alakulását többtényezős, nemlineáris rendszerek befolyásolják, amelyek hatékonyan modellezhetők neurális hálózatokkal. Az ANN-alapú modellek alkalmazása a jövőben kulcsszerepet játszhat az agronómiai döntéshozatal támogatásában, különösen a klímaváltozáshoz való alkalmazkodás és az inputanyagok optimalizált felhasználása tekintetében. Mindez hozzájárulhat egy fenntarthatóbb mezőgazdasági termelés kialakításához, amely képes megfelelni a 21. század kihívásainak.

9. ÖSSZEFOGLALÁS (angol nyelven)

One of the key issues in global food security is maintaining and improving the efficiency and quality of agricultural production. Maize (*Zea mays L.*), as a crop of strategic importance, plays a central role in the supply of food, feed, and industrial raw materials. The starch content of maize grain - an important qualitative parameter - is particularly significant in terms of nutritional value, processability, and economic efficiency. The aim of this doctoral dissertation was to explore the environmental and agrotechnical factors affecting starch content, to examine machine learning models suitable for its prediction, and to present their effectiveness. The research was conducted at the Látókép Experimental Station of the University of Debrecen, based on data from small-plot long-term experiments over three consecutive years (2017–2019). During the studies, I investigated the effects of three different soil tillage systems (winter ploughing, strip tillage, ripping) and three fertilizer treatments (control, N 80 – P₂O₅ 60 – K₂O 90 kg ha⁻¹, and N 160 – P₂O₅ 60 – K₂O 90 kg ha⁻¹) on changes in starch content. For data processing, I used classical statistical methods (descriptive statistics, correlation analysis, ANOVA, LSD test, Wilcoxon test) as well as multivariate techniques (PCA). The results of the various methods led to the following conclusions: starch content was most significantly influenced by the year (climatic factors) and the fertilization level, while the effect of soil tillage was more moderate.

The results clearly showed that favorable climatic conditions - especially the distribution of precipitation and temperature dynamics during the growing season - positively affect the internal quality parameters of the grain. In more humid years, both yield and starch content showed higher values, while in drier years, I observed a significant decrease. This confirms the critical role of the year effect in terms of quality parameters. In the examination of nutrient supply, I found that the medium-dose fertilizer treatment (N80 kg ha⁻¹ + PK) provided the optimal balance between yield and starch content. However, the highest dose (N160 kg ha⁻¹ + PK) resulted in a significant reduction in starch content in several years, especially during periods with water stress. This suggests that nitrogen over-application can negatively affect carbohydrate metabolism and thereby starch synthesis. The impact of soil tillage methods appeared differently across the various years. Winter ploughing provided the most consistent results, while ripping and strip tillage had more favorable effects on starch content in certain years - especially the drier ones.

Among machine learning methods, I applied artificial neural networks (ANNs), specifically multilayer perceptron (MLP) and radial basis function (RBF) networks. I trained the models under different scenarios, involving varying numbers and types of input variables. The MLP models outperformed the RBF networks across all evaluation metrics: they operated with lower error, higher coefficients of determination, and greater robustness. The best-performing predictive model (MLP_SC4) showed near-perfect fit with the actual data, confirming the applicability of artificial neural networks in the field of agricultural predictive modeling. The results also demonstrated that increasing the number of input parameters—such as combining meteorological, soil, and agrotechnical data—significantly improves the prediction accuracy of the models.

My research contributes to the development of agricultural digitalization by showing that results obtained through traditional statistical tools are compatible with models offered by machine learning technologies. This creates opportunities for maize producers to make site-specific, data-driven decisions in the future, thereby increasing the sustainability and profitability of production. In future research, I aim to expand the predictive models with other algorithms (e.g., Random Forest, XGBoost, Deep Learning), as well as to integrate remote sensing data and geoinformation systems. These would not only enhance prediction accuracy but also provide more spatially detailed outputs.

Overall, the dissertation demonstrated that the starch content of maize is influenced by multifactorial, nonlinear systems, which can be effectively modeled using neural networks. The application of ANN-based models may play a key role in supporting agronomic decision-making in the future, particularly in adapting to climate change and optimizing the use of inputs. All of this can contribute to the development of more sustainable agricultural production that can meet the challenges of the 21st century.

10. RÖVIDÍTÉSEK JEGYZÉKE

11. Rövidítés	Jelentés
ANOVA	Varianciaanalízis (analysis of variance)
FAO	Élelmezésügyi és Mezőgazdasági Szervezet (Food and Agriculture Organization)
LSD	Legkisebb szignifikáns különbség (least significant difference)
MAE	Átlagos abszolút hiba (mean absolute error)
MAPE	Átlagos abszolút százalékos hiba (mean absolute percentage error)
MLP	Többrétegű perceptron (multilayer perceptron)
NSE	Nash–Sutcliffe modellhatékonysági együttható (Nash–Sutcliffe efficiency)
PCA	Főkomponens-analízis (principal component analysis)
R	Korrelációs együttható (correlation coefficient)
R²	Determinációs együttható (coefficient of determination)
RBF	Radiális bázisfüggvény (radial basis function)
RE	Relatív hiba (relative error)
RMSD	Négyzetes középeltérés (root mean square deviation)
SSE	Négyzetes hiba (sum of squares error)

11. FELHASZNÁLT IRODALOM

1. Adisa, O. M. – Botai, J. O. – Adeola, A. M. – Hassen, A. – Botai, C. M. – Darkey, D. – Tesfamariam, E.: 2019b. Application of artificial neural network for predicting maize production in South Africa. *Sustainability*. 11. (4): 1145.
2. Agatonovic-Kustrin, S. – Beresford, R.: 2000. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*. 22. (5): 717–727.
3. AKI Agrárközgazdasági Intézet: 2025 Agrárpiaci jelentések – Gabona és ipari növények XXVIII. évfolyam 7. szám; <https://www.aki.gov.hu/termek/agarpiaci-jelentesek-gabona-es-ipari-novenyek-459/>
4. Ali, Z. – Hussain, I. – Faisal, M. – Nazir, H. M. – Hussain, T. – Shad, M. Y. – Shoukry, A. M. – Hussain Gani, S.: 2017. Forecasting drought using multilayer perceptron artificial neural network model. *Advances in Meteorology*. 2017.: 5681308. <https://doi.org/10.1155/2017/5681308>
5. Alizadeh, M. R. – Nikoo, M. R.: 2018. A fusion-based methodology for meteorological drought estimation using remote sensing data. *Remote Sensing of Environment*. 211.: 229–247. 10.1016/j.rse.2018.04.001
6. Alvarez, R.: 2009. Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. *European Journal of Agronomy*. 30. (2): 70–77.
7. Archontoulis, S. V.–Licht, M. A.–Herzmann, D.–et al.: 2020, Predicting crop yields and soil–plant nitrogen dynamics in the US Corn Belt, *Crop Science*, 60.(2): 721–738. <https://doi.org/10.1002/csc2.20039>
8. Azmat, M. – Madondo, M. – Bawa, A. – Dipietro, K. – Horesh, R. – Jacobs, M. – O’Donncha, F.: 2023. Forecasting soil moisture using domain inspired temporal graph convolution neural networks to guide sustainable crop management. *IJCAI Proceedings*: 5897–5905. <https://doi.org/10.24963/ijcai.2023/654>
9. Bagula, E. M., Majaliwa, J. G. M., Basamba, T. A., Mondo, J. G. M., Vanlauwe, B., Gabiri, G., Tenywa, M. M. *Land* 2022. Water use efficiency of maize (*Zea mays* L.) crop under selected soil and water conservation practices along the slope gradient in Ruzizi watershed, eastern DR Congo. *Land* 11(10): 1833. <https://doi.org/10.3390/land11101833>

10. Baio, F. H. R.–Santana, D. C.–Teodoro, L. P. R.–de Oliveira, I. C.–Gava, R.–de Oliveira, J. L. G.–Silva Junior, C. A.–Teodoro, P. E.–Shiratsuchi, L. S.: 2023. Maize Yield Prediction with Machine Learning, Spectral Variables and Irrigation Management. *Remote Sensing*, 15(1): 79. <https://doi.org/10.3390/rs15010079>
11. Bánszki, L.: 2012. Bioetanol előállítás céljából termesztett kukorica hibridek összehasonlító értékelése. *Agrártudományi Közlemények (Acta agraria Debreceniensis)*, 46: 11–14.
12. Basheer, I. A. – Hajmeer, M.: 2000. Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*. 43. (1): 3–31. [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
13. Bishop, C. M.: 1995. *Neural Networks for Pattern Recognition*. Oxford University Press.
14. Bojtor C. – Mousavi S. M. N. – Illés Á. – Széles A. – Nagy J. – Marton C. L.: 2021: Stability and adaptability of maize hybrids for precision crop production in a long-term field experiment in Hungary. *Agronomy*, 11.(11): 2167. doi: 10.3390/agronomy11112167.
15. Bojtor C. – Mousavi S. M. N. – Illés Á. – Goltzardi F. – Széles A. – Szabó A. – Nagy J. – Marton C. L.: 2022: Nutrient composition analysis of maize hybrids affected by different nitrogen fertilization systems. *Plants*, 11.(12): 1593. doi: 10.3390/plants11121593.
16. Szabó, A. – Mousavi, S. M. N. – Bojtor, C. – Ragán, P. – Nagy, J. – Vad, A. – Illés, Á.: 2022b. Analysis of Nutrient-Specific Response of Maize Hybrids in Relation to Leaf Area Index (LAI) and Remote Sensing. *Plants*, 11.(9): 1197.
17. Bramdeo, K., Rátónyi, T. *Acta Agraria Debreceniensis* 2020. Effect of tillage practices, fertilizer treatments and crop rotation on yield of maize (*Zea mays* L.) hybrids. (2): 43–48. <https://doi.org/10.34101/actaagrar/2/3626>
18. Broomhead, D. S. – Lowe, D.: 1988. Radial Basis Functions, Multi-Variable Functional Interpolation and Adaptive Networks. *Royal Signals and Radar Establishment*, Malvern, UK.
19. Brouwer, I. D. – McDermott, J. – Ruben, R.: 2020. Food systems everywhere: Improving relevance in practice. *Global Food Security*. 26: 100398. <https://doi.org/10.1016/j.gfs.2020.100398>

20. *Butts-Wilmsmeyer, C. J. – Seebauer, J. R. – Singleton, L. – Below, F. E.:* 2019. Weather during key growth stages explains grain quality and yield of maize. *Agronomy*. 9. (1): 16.
21. *Choubin, B. – Khalighi-Sigaroodi, S. – Malekian, A. – Kişi, Ö.:* 2016. Multiple linear regression, multi-layer perceptron network and adaptive neuro-fuzzy inference system for forecasting precipitation based on large-scale climate signals. *Hydrological Sciences Journal*. 61: 1001–1009. DOI: 10.1080/02626667.2014.966721
22. *Comas, L. H., Trout, T. J., DeJonge, K. C., Zhang, H., Gleason, S. M.* *Agricultural Water Management* 2019. Water productivity under strategic growth stage-based deficit irrigation in maize. 212: 433–440. DOI: 10.1016/j.agwat.2018.07.015
23. *Correndo, A. – Fernández, J. – Prasad, P. – Ciampitti, I.:* 2021. Do water and nitrogen management practices impact grain quality in maize? *Agronomy*. 11. (9): 1851. <https://doi.org/10.3390/agronomy11091851>
24. *Dahikar, S. S. – Rode, S. V.:* 2014. Agricultural crop yield prediction using artificial neural network approach. *International Journal of Innovative Research in Electrical, Electronics, Instrumentation and Control Engineering*. 2. (1): 683–686.
25. *Dahmani, K. – Dizene, R. – Notton, G. – Paoli, C. – Voyant, C. – Nivet, M. L.:* 2014. Estimation of 5-min time-step data of tilted solar global irradiation using ANN (Artificial Neural Network) model. *Energy*. 70: 374–381.
26. *Drobitko, A., Качанова, Т., Markova, N., Malkina, V.* *Ukrainian Black Sea Region Agrarian Science* 2024. Modern cultivation technologies in improvement of corn quality. 28(1): 19–28. <https://doi.org/10.56407/bs.agrarian/1.2024.19>
27. *Elbeltagi, A. – Zhang, L. – Deng, J. – Juma, A. – Wang, K.:* 2020. Modeling monthly crop coefficients of maize based on limited meteorological data: A case study in Nile Delta, Egypt. *Computers and Electronics in Agriculture*. 173: 105368. DOI: 10.1016/j.compag.2020.105368
28. *Emamgholizadeh, S. – Parsaeian, M. – Baradaran, M.:* 2015. Seed yield prediction of sesame using artificial neural network. *European Journal of Agronomy*. 68: 89–96. DOI: 10.1016/j.eja.2015.04.010

29. Erenstein, O. – Chamberlin, J. – Sonder, K.: 2021. Estimating the global number and distribution of maize and wheat farms. *Global Food Security*. 30: 100558. <https://doi.org/10.1016/j.gfs.2021.100558>
30. Erenstein, O. – Jaleta, M. – Sonder, K. – Mottaleb, K. – Prasanna, B. M.: 2022. Global maize production, consumption and trade: trends and R&D implications. *Food Security*. 14. (5): 1295–1319. DOI: 10.1007/s12571-022-01288-7
31. Erenstein, O.: 2010. The evolving maize sector in Asia: Challenges and opportunities. *Journal of New Seeds*. 11: 1–15. <https://doi.org/10.1080/15228860903517770>
32. Fanzo, J. – Haddad, L. – Schneider, K. R. – Béné, C. – Covic, N. M. – Guarin, A. – Herforth, A. W. – Herrero, M. – Sumaila, U. R. – Aburto, N. J. – Amuyunzu-Nyamongo, M. – Barquera, S. – Battersby, J. – Beal, T. – Bizzotto Molina, P. – Brusset, E. – Cafiero, C. – Campeau, C. – Caron, P. ... Rosero Moncayo, J.: 2021. Viewpoint: Rigorous monitoring is necessary to guide food system transformation in the countdown to the 2030 global goals. *Food Policy*. 104: 102163. <https://doi.org/10.1016/j.foodpol.2021.102163>
33. FAO. 2024. FAOSTAT, Agricultural production statistics <https://www.fao.org/statistics/highlights-archive/highlights-detail/agricultural-production-statistics-2010-2023/en>
34. FAO. 2024. *World Food and Agriculture – Statistical Yearbook 2024*. <https://doi.org/10.4060/cd2971en>
35. Ferencsik, S., Rátonyi, T. *Acta Agraria Debreceniensis* 2014. Evaluation of striptillage and conventional tillage in maize production. (59): 37–40. <https://doi.org/10.34101/actaagrar/59/1999>
36. Ferencsik, S., Rátonyi, T., Fejér, P., Harsányi, E. *Acta Agraria Debreceniensis* 2014. Comparative examination of the tillage systems of maize on meadow chernozem soil. (60): 21–24. <https://doi.org/10.34101/actaagrar/60/2017>
37. *Food and Agriculture Organization (FAO) (2022):* <https://www.fao.org/4/t0395e/T0395E03.htm>
38. Fox, G. P. – O’Hare, T. J.: 2017. Analysing maize grain quality. In: Watson, R. R. – Preedy, V. R. (eds.) *Achieving sustainable cultivation of maize: Volume 1*. Burleigh Dodds Science Publishing. 237-260. DOI: 10.19103/AS.2016.0001.14

39. Galli, G.–Lyra, D. H.–Granato, I.–Pérez-Rodríguez, P.–Fritsche-Neto, R.–de Los Campos, G.: 2022. Automated Machine Learning: A Case Study of Genomic “Image-Based” Prediction in Maize Hybrids. *Frontiers in Plant Science*, 13: 845524. <https://doi.org/10.3389/fpls.2022.845524>.
40. Gandhi, N. – Petkar, O. – Armstrong, L. J.: 2016. Rice crop yield prediction using artificial neural networks. In: *2016 IEEE Technological Innovations in ICT for Agriculture and Rural Development (TIAR)*. IEEE. 105–110. DOI: 10.1109/TIAR.2016.7801222
41. Gerland, P. – Raftery, A. E. – Ševčíková, H. – Li, N. – Gu, D. – Spoorenberg, T. – Alkema, L. – Fosdick, B. K. – Chunn, J. L. – Lalic, N. – Bay, G. – Buettner, T. – Heilig, G. K. – Wilmoth, J.: 2014. World population stabilization unlikely this century. *Science*. 346. (6206): 234-237. DOI: 10.1126/science.1257469
42. Gombos, B. – Nagy, J.: 2019. Az időjárás értékelése kukorica (*Zea mays* L.) tartamkísérletek eredményei alapján. *Növénytermelés*. 68. (2): 5–23.
43. Gombos-B – Nagy-Z – Hajdu-A – Nagy-J: 2023: Climate change in the Debrecen area in the last 50 years and its impact on maize production. *Időjárás* 127.4, 485–504: <https://doi.org/10.28974/idojaras.2023.4.5>
44. Goodfellow, I. – Bengio, Y. – Courville, A.: 2016. *Deep Learning*. MIT Press.
45. Grote, U. – Fasse, A. – Nguyen, T. T. – Erenstein, O.: 2021. Food Security and the Dynamics of Wheat and Maize Value Chains in Africa and Asia. *Frontiers in Sustainable Food Systems*. 4: 617009. <https://doi.org/10.3389/fsufs.2020.617009>
46. Guo, J., Qu, L., Wang, L., Lu, W., Lu, D. *Journal of the Science of Food and Agriculture* 2023. Effects of post-silking drought stress degree on grain yield and quality of waxy maize. *103*(3): 1530–1540. DOI: 10.1002/jsfa.12250
47. Hara, P. – Piekutowska, M. – Niedbala, G.: 2021. Selection of independent variables for crop yield prediction using artificial neural network models with remote sensing data. *Land*. 10. (6): 609. DOI: 10.3390/land10060609
48. Harsányi, E. – Bashir, B. – Almhamad, G. – Hijazi, O. – Maze, M. – Elbeltagi, A. – Szabó, S.: 2021a. GHGs emission from the agricultural sector within EU-28: A multivariate analysis approach. *Energies*. 14. (20): 6495. <https://doi.org/10.3390/en14206495>

49. Harsányi, E. – Bashir, B. – Alsilibe, F. – Alsafadi, K. – Alsalman, A. – Széles, A. – Mohammed, S.: 2021b. Impact of agricultural drought on sunflower production across Hungary. *Atmosphere*. 12. (10): 1339. <https://doi.org/10.3390/atmos12101339>
50. Harsányi, E. – Bashir, B. – Alsilibe, F. – Moazzam, M. F. U. – Ratonyi, T. – Alsalman, A. – Széles, A. – Nyéki, A. – Takács, I. – Mohammed, S.: 2022. Predicting Modified Fournier Index by Using Artificial Neural Network in Central Europe. *International Journal of Environmental Research and Public Health*. 19. (17): 10653.
51. Harsányi, E. – Bashir, B. – Arshad, S. – Ocwa, A. – Vad, A. – Alsalman, A. – Bácskai, I. – Ráttonyi, T. – Hijazi, O. – Széles, A. – Mohammed, S.: 2023. Data Mining and Machine Learning Algorithms for Optimizing Maize Yield Forecasting in Central Europe. *Agronomy*. 13. (5): 1297
52. Hateffard, F. – Mohammed, S. – Alsafadi, K. – Enaruvbe, G. O. – Heidari, A. – Abdo, H. G. – Rodrigo-Comino, J.: 2021. CMIP5 climate projections and RUSLE-based soil erosion assessment in the central part of Iran. *Scientific Reports*. 11. (1): 1–17. DOI: 10.1038/s41598-021-86618-z
53. Hornik, K. – Stinchcombe, M. – White, H.: 1989. Multilayer Feedforward Networks are Universal Approximators. *Neural Networks*. 2. (5): 359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
54. Horváth, É. – Gombos, B. – Széles, A.: 2021a. Evaluation phenology, yield and quality of maize genotypes in drought stress and non-stress environments. *Agronomy Research*. 19. (2): 408–422. <https://doi.org/10.15159/AR.21.073>
55. Horváth-É – András-T – Fejér-P – Széles-A: 2021b: Effect of different N doses on maize yield and quality. *Acta Agraria Debreceniensis* 2021.1, 97–101: <https://doi.org/10.34101/ACTAAGRAR/1/8493>
56. Hosseini-Moghari, S. M. – Araghinejad, S.: 2015. Monthly and seasonal drought forecasting using statistical neural networks. *Environmental Earth Sciences*. 74: 397–412. DOI:10.1007/s12665-015-4047-x
57. Huang, Y. – Chen, Z. – Yu, T. – Huang, X. – Gu, X.: 2018. Agricultural remote sensing big data: Management and applications. *Journal of Integrative Agriculture*. 17(9): 1915–1931. [https://doi.org/10.1016/S2095-3119\(17\)61859-8](https://doi.org/10.1016/S2095-3119(17)61859-8)
58. Huzsvai, L. – Balogh, P.: 2015. *Lineáris modellek az R-ben*. Debreceni Egyetemi Kiadó.

59. Huzsvai, L., Rátonyi, T., Nagy, J., Megyes, A. *Acta Agraria Debreceniensis* 2003. Effects of tillage systems on physical status and organic matter turnover of the soil. (12): 42–45. <https://doi.org/10.34101/actaagrar/12/3429>
60. Ibrahim, S.A. – Kandil, H.: 2007: Growth, yield and chemical constituents of corn (*Zea mays* L.) as affected by nitrogen and phosphorus fertilization under different irrigation intervals. *Journal of Applied Sciences Research* 3.10, 1112–1120.
61. Illés Á. – Mousavi S. M. N. – Bojtor C. – Nagy J.: 2020: The plant nutrition impact on the quality and quantity parameters of maize hybrids grain yield based on different statistical methods. *Cereal Research Communications*, 48.(4): 565–573. doi: 10.1007/s42976-020-00074-5.
62. Jiang, C. – Liang, Y. – Wang, Y. – You, G. – Guo, J. – Lu, D. – Li, G.: 2024. Effects of sulfur application on the quality of fresh waxy maize. *Plants*. 13. (19): 2677. <https://doi.org/10.3390/plants13192677>
63. Jiang, H.–Lu, J.: 2018. Using an optimal CC-PLSR-RBFNN model and NIR spectroscopy for the starch content determination in corn. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 196: 131–140. <https://doi.org/10.1016/j.saa.2018.02.017>
64. Jolliffe, I. T., - Cadima, J. (2016). Principal component analysis: a review and recent developments. *Philosophical transactions of the royal society A: Mathematical, Physical and Engineering Sciences*, 374(2065), 20150202.
65. Jones, A. D. – Yosef, S.: 2015. The implications of a changing climate on global nutrition security. In: Sahn, D. E. (ed.) *The Fight Against Hunger and Malnutrition*. Oxford University Press. 432–466.
66. Juhász, Cs. – Gálya, B. – Kovács, E. – Nagy, A. – Tamás, J. – Huzsvai, L.: 2020. Seasonal predictability of weather and crop yield in regions of Central European continental climate. *Computers and Electronics in Agriculture*. 173.: 105400. <https://doi.org/10.1016/j.compag.2020.105400>
67. Kamilaris-A – Kartakoullis-A – Prenafeta-Boldú-F-X: 2017: A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture* 143, 23–37: <https://doi.org/10.1016/j.compag.2017.09.037>

68. Kaplan-M – Karaman-K – Yilmaz-Y – Cakir-B: 2019: Phytic acid content and starch properties of maize (*Zea mays* L.): Effects of irrigation process and nitrogen fertilizer. *Food Chemistry* 283, 689–695: DOI:10.1016/j.foodchem.2019.01.029
69. Khallouf – A. – Talukdar – S. – Harsányi – E. – Abdo – H. G. – Mohammed – S.: 2021. Risk assessment of soil erosion by using CORINE model in the western part of Syrian Arab Republic. *Agriculture & Food Security*. 10. (1): 1–15. DOI: 10.1186/s40066-021-00295-9
70. Khan, A.: 2016. Maize (*Zea mays* L.) genotypes differ in phenology, seed weight and quality (protein and oil contents) when applied with variable rates and source of nitrogen. *Journal of Plant Biochemistry & Physiology*. 4. (1).
71. Kiss, Cs. G.: 2013. Kukorica hibridek keményítő tartalmának vizsgálata közeli infravörös spektroszkópiai (NIT) technikával. *Agrártudományi Közlemények*. 51.: 119–125.
72. Központi Statisztikai Hivatal (KSH): 2024 A fontosabb növények vetésterülete <https://www.ksh.hu/s/kiadvanyok/a-fontosabb-novenyek-vetesterulete-2024-junius-1/index.html>
73. Központi Statisztikai Hivatal (KSH): 2025 Debrecen időjárási adatai https://www.ksh.hu/stadat_files/kor/en/kor0071.html
74. Kross, A. – Znoj, E. – Callegari, D. – Kaur, G. – Sunohara, M. – Lapen, D. R. – McNairn, H.: 2020. Using artificial neural networks and remotely sensed data to evaluate the relative importance of variables for prediction of within-field corn and soybean yields. *Remote Sensing*. 12. (14): 2230. DOI: 10.3390/rs12142230
75. Kujawa, S. – Niedbala, G.: 2021. Artificial Neural Networks in Agriculture. *Agriculture*. 11: 497. <https://doi.org/10.3390/agriculture11060497>
76. Kumar – S.: 2024. Neural greenery: advancement in plant leaf diseases recognition using deep learning. *International Journal of Scientific Research in Engineering and Management*. 08. (03): 1–11. <https://doi.org/10.55041/ijsrem29167>
77. Laghari, A. – Buriro, M. – Laghari, G. – Talpur, K.: 2024. Impact of different NPK levels and sowing methods on maize growth, yield, and quality characteristics. *Pakistan Journal of Biotechnology*. 21. (1): 61–66. <https://doi.org/10.34016/pjbt.2024.21.01.824>

78. LeCun – Y. – Bengio – Y. – Hinton – G.: 2015. Deep learning. *Nature*. 521. (7553): 436–444. DOI: 10.1038/nature14539
79. Lipton Z. C.: 2016: The Mythos of Model Interpretability. *arXiv preprint*, arXiv:1606.03490. <https://doi.org/10.48550/arXiv.1606.03490>
80. Liu, C.–Huang, W.–Yang, G.–Wang, Q.–Li, J.–Chen, L.–et al.: 2020. Determination of starch content in single kernel using near-infrared hyperspectral images from two sides of corn seeds. *Infrared Physics & Technology*, 110: 103462. <https://doi.org/10.1016/j.infrared.2020.103462>
81. Long, W.–Wang, T.–Tang, Y.–Huang, X.–Zhang, M.: 2025. Detection of starch content in maize kernel based on Raman hyperspectral imaging technique. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 336: 126025. DOI: 10.1016/j.saa.2025.126025
82. Lynch, J. – Cain, M. – Frame, D. – Pierrehumbert, R.: 2021. Agriculture's Contribution to Climate Change and Role in Mitigation Is Distinct From Predominantly Fossil CO₂-Emitting Sectors. *Frontiers in Sustainable Food Systems*.
83. Maseko, S.–van der Laan, M.–Tesfamariam, E. H.–Delpont, M.–Otterman, H.: 2024. Evaluating machine learning models and identifying key factors influencing spatial maize yield predictions in data intensive farm management. *European Journal of Agronomy*. 157: 127193. <https://doi.org/10.1016/j.eja.2024.127193>
84. Matsuoka, Y. – Vigouroux, Y. – Goodman, M. M. – Sanchez G., J. – Buckler, E. – Doebley, J.: 2002. A single domestication for maize shown by multilocus microsatellite genotyping. *Proceedings of the National Academy of Sciences*. 99. (9): 6080-6084. DOI: 10.1073/pnas.052125199
85. McCleary, B. V. – Charmier, L. M. – McKie, V. A.: 2019. Measurement of starch: critical evaluation of current methodology. *Starch-Stärke*. 71. (1–2): 1800146.
86. McCulloch, W. S. – Pitts, W.: 1943. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*. 5: 115–133.
87. Megyes, A., Rátonyi, T., Nagy, J., Kovács, M. *Acta Agraria Debreceniensis* 2001. Evaluation of reduced tillage technologies in corn production based on soil and crop analyses. (2): 47–54. <https://doi.org/10.34101/actaagrar/2/3599>

88. *met.hu.*: 2025 Napi meteorológiai adatok – Debrecen. https://www.met.hu/eghajlat/magyarorszag_eghajlata/eghajlati_adatsorok/Debrecen/adatok/napi_adatok/index.php (letöltve 2025. 02. 15.)
89. Miao, L.–Zou, Y.–Cui, X.–Kattel, G. R.–Shang, Y.–Zhu, J.: 2024. Predicting China's Maize Yield Using Multi Source Datasets and Machine Learning Algorithms. *Remote Sensing*, 16(13): 2417. <https://doi.org/10.3390/rs16132417>
90. Mishra, A. K. – Desai, V. R.: 2006. Drought forecasting using feed-forward recursive neural network. *Ecological Modelling*. 198: 127–138. DOI: 10.1016/j.ecolmodel.2006.04.017
91. Mohammed, S. – Alsafadi, K. – Hennawi, S. – Mousavi, S. M. N. – Kamal-Eddin, F. – Harsányi, E.: 2021a. Effects of long-term agricultural activities on the availability of heavy metals in Syrian soil: A case study in southern Syria. *Journal of the Saudi Society of Agricultural Sciences*. 20. (5): 304–312. <https://doi.org/10.1016/j.jssas.2020.05.001>
92. Mohammed, S. – Gill, A. R., Alsafadi, K. – Hijazi, O. – Yadav, K. K. – Hasan, M. A. – Harsányi, E.: 2021b. An overview of greenhouse gases emissions in Hungary. *Journal of Cleaner Production*. 314.: 127865. <https://doi.org/10.1016/j.jclepro.2021.127865>
93. Mohammed, S. – Mirzaei, M. – Pappné Törő, Á. – Anari, M. G. – Moghiseh, E. – Asadi, H. – Harsányi, E.: 2021c. Soil carbon dioxide emissions from maize (*Zea mays* L.) fields as influenced by tillage management and climate. *Irrigation and Drainage*. 71. (1): 131–140. <https://doi.org/10.1002/ird.2601>
94. Mohammed, S. – Alsafadi, K. – Enaruvbe, G. O. – Bashir, B. – Elbeltagi, A. – Széles, A. – Harsányi, E.: 2022a. Assessing the impacts of agricultural drought (SPI/SPEI) on maize and wheat yields across Hungary. *Scientific Reports*. 12. (1): 8838.
95. Mohammed, S. – Elbeltagi, A. – Bashir, B. – Alsafadi, K. – Alsilibe, F. – Alsalman, A. – Zeraatpisheh, M. – Széles, A. – Harsányi, E.: 2022b. A comparative analysis of data mining techniques for agricultural and hydrological drought prediction in the eastern Mediterranean. *Computers and Electronics in Agriculture*. 197: 106925.
96. Mohammed, S.–Arshad, S.–Alsilibe, F.–Ul Moazzam, M. F.–Bashir, B.–Proadhan, F. A.–Alsalman, A.–Vad, A.–Rátonyi, T.–Harsányi, E.: 2024a. Utilizing machine learning and CMIP6 projections for short-term agricultural drought monitoring in Central Europe

- (1900–2100). *Journal of Hydrology*, 633: 130968.
<https://doi.org/10.1016/j.jhydrol.2024.130968>
97. Mohammed, S.–Arshad, S.–Bashir, B.–Vad, A.–Als Salman, A.–Harsányi, E.: 2024b. Machine learning driven forecasts of agricultural water quality from rainfall ionic characteristics in Central Europe. *Agricultural Water Management*, 293: 108690.
<https://doi.org/10.1016/j.agwat.2024.108690>
98. Mohanty, S. P. – Hughes, D. P. – Salathé, M.: 2016. Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*. 7: 1419.
<https://doi.org/10.3389/fpls.2016.01419>
99. Mousavi, S.–Kith, K.–Nagy, J.: 2019. Effect of interaction between traits of different genotype maize in six fertilizer level by GGE biplot analysis in Hungary. *Progress in Agricultural Engineering Sciences*, 15(1): 23–35.
<https://doi.org/10.1556/446.15.2019.1.2>
100. Nagy J. – Bojtor C. – Illés Á. – Széles A.: 2022: Long-term impacts of maize production technologies on yield stability in Eastern Europe. *Cereal Research Communications*, 50.(3): 345–356. doi: 10.1007/s42976-022-000xx.
101. Nagy J.: 2010: A kukoricatermesztés jelene és jövője. *Növénytermelés*, 59.(3): 85–111.
102. Nagy, J. – Nyéki, A. – Gombos, B.: 2020. A 2018–2019. évi időjárás elemzése szántóföldi tartamkísérletekben (Debrecen–Látókép). *Növénytermelés*. 69. (1): 21–31.
103. Nagy, J., Széles, A. *Acta Agraria Debreceniensis* 2018. The scientific background of competitive maize production. 33–46. <https://doi.org/10.34101/actaagrar/150/1700>
104. Nagy, Z. – Nagy, J.: 2020. Az agrometeorológiai tényezők értékelése kukorica (*Zea mays* L.) tartamkísérletekben – 2019/2020. *Növénytermelés*. 69. (4): 1–18.
105. Nash, J. E. – Sutcliffe, J. V.: 1970. River flow forecasting through conceptual models part I—A discussion of principles. *Journal of Hydrology*. 10. (3): 282–290.
106. Nuss, E. T. – Tanumihardjo, S. A.: 2010. Maize: a paramount staple crop in the context of global nutrition. *Comprehensive Reviews in Food Science and Food Safety*. 9: 417–436. DOI: 10.1111/j.1541-4337.2010.00117.x
107. Nyandi M. S. – Appiah E. A. – Pepó P.: 2025: Harnessing chlorophyll and canopy reflectance indices relationship for grain yield, protein and starch content in maize

- cultivars under different nitrogen treatments. *Plant, Soil and Environment*, 71. doi: 10.17221/633/2024-pse.
108. Nyéki, A. É.–Kerepesi, C.–Daróczy, B.–Benczúr, A. J.–Milics, G.–Harsányi, E.–Kovács, A. J.–Neményi, M.: 2021. Application of spatio-temporal data in site-specific maize yield prediction with machine learning methods. *Precision Agriculture*, 22(5): 1397–1415. <https://doi.org/10.1007/s11119-021-09833-8>
109. Oikeh, S.O. – Kling, J.G. – Okoruwa, A.E.: 1998: Nitrogen fertilizer management effects on maize grain quality in the West African moist savanna. *Crop Science* 38, 1056–1061: <https://doi.org/10.2135/cropsci1998.0011183x003800040029x>
110. Park, J. – Sandberg, I. W.: 1991. Universal Approximation Using Radial-Basis-Function Networks. *Neural Computation*. 3. (2): 246–257. <https://doi.org/10.1162/neco.1991.3.2.246>
111. Pearson, K.: 1896. VII. Mathematical contributions to the theory of evolution.—III. Regression, heredity, and panmixia. *Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character*. (187): 253–318.
112. Poole, N. – Donovan, J. – Erenstein, O.: 2021. Agri-nutrition research: Revisiting the contribution of maize and wheat to human nutrition and health. *Food Policy*. 100: 101976. <https://doi.org/10.1016/j.foodpol.2020.101976>
113. Qi, M.: 1996. Financial applications of Artificial Neural Networks. In: *Handbook of Statistics*. Elsevier. 14: 529–552. [https://doi.org/10.1016/S0169-7161\(96\)14020-7](https://doi.org/10.1016/S0169-7161(96)14020-7)
114. Ragán, P. – Rátónyi, T. – Széles, A. – Nagy, J. – Tamás, A.: 2024. Az agrotechnikai paraméterek és az évjárat hatásának vizsgálata a kukorica (*Zea mays* L.) termésére polifaktoriális tartamkísérleti adatok felhasználásával. *Növénytermelés*. 73. (2): 77–100.
115. Raj, M. – Gupta, S. – Chamola, V. – Elhence, A. – Garg, T. – Atiqzaman, M. – Niyato, D.: 2021. A survey on the role of Internet of Things for adopting and promoting Agriculture 4.0. *Journal of Network and Computer Applications*. 187: 103107.
116. Ramasamy – J. – Moorthy – P.: 2006. Managing food insecurity and poverty in India in the era of globalization. *International Journal of Multidisciplinary Research*. 2. (1): 1–10.

117. Rátonyi, T.–Nagy, J.–Harsányi, E.: 2012. Utilization of the field experiment results of University of Debrecen in the development of maize-based bio-ethanol production. *Acta Agraria Debreceniensis*, 49: 55–57. <https://doi.org/10.34101/actaagrar/49/2479>
118. Raza, H. – Bilal, H. – Raza, A. – Shoukat, M. B. – Tariq, R. – Rasheed, A. – Shahid, M. – Sharif, M. U. – Maqsood, M. – Ramzan, M.: 2021. Impact of Climate Change on Agriculture and Food Security: A Review. *Indian Journal of Pure and Applied Biosciences*. 9. (3): 110-118.
119. Rebe, S. – Cronje, N. – Redelinghuys, N. – Pretorius, W. – Du Toit, A.: 2024. Exploring the consumption of maize products, side dishes and snacks preferred by consumers at a public tertiary institution in South Africa. *Journal of Consumer Sciences*. 1: 23-42.
120. Roberts – L.: 2011. 9 Billion? *Science*. 333. (6042): 540–543. <https://doi.org/10.1126/science.333.6042.540>
121. Rodrigues, D. M. – Coradi, P. C. – Teodoro, L. P. R. – Teodoro, P. E. – Moraes, R. dos S. – Leal, M. M.: 2024. Monitoring and predicting corn grain quality on the transport and post-harvest operations in storage units using sensors and machine learning models. *Scientific Reports*, 14: 6232. <https://doi.org/10.1038/s41598-024-56879-5>
122. Rosenblatt, F.: 1958. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*. 65. (6): 386–408.
123. Rosenblatt, F.: 1961. *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Cornell Aeronautical Lab Inc., Buffalo, NY, USA.
124. Rouf Shah, T. – Prasad, K. – Kumar, P.: 2016. Maize—A potential source of human nutrition and health: A review. *Cogent Food & Agriculture*. 2: 1166995.
125. Rumelhart, D. E. – Hinton, G. E. – Williams, R. J.: 1986. Learning representations by back-propagating errors. *Nature*. 323. (6088): 533–536.
126. Safa, M. – Samarasinghe, S. – Nejat, M.: 2015. Prediction of wheat production using artificial neural networks and investigating indirect factors affecting it: case study in Canterbury province, New Zealand. *Journal of Agricultural Science and Technology*. 17. (4): 791–803.
127. Sánchez B. – Rasmussen A. – Porter J. R.: 2014: Temperatures and the growth and development of maize and rice: a review. *Global Change Biology*, 20.(2): 408–417. <https://doi.org/10.1111/gcb.12389>

- 128.Sandhu – K. S. – Paterson – A. H. – Cooper – M. – Messina – C. D. – Hammer – G. L. – Chapman – S. C.: 2021, Multitrait machine- and deep-learning models for genomic prediction of yield and protein content in wheat, *The Plant Genome*, 14(3): e20119, doi:10.1002/tpg2.20119.
- 129.Sedlák, G.: 2012. Evaluation of the interaction between environmental factors, cultivation and fertilisation. *Acta Agraria Debreceniensis*. (47): 103–108. <https://doi.org/10.34101/actaagrar/47/2435>
- 130.Shahhosseini – M. – Hu – G. – Huber – I. – Archontoulis – S. V.: 2021. Coupling machine learning and crop modeling improves crop yield prediction in the US Corn Belt. *Scientific Reports*. 11. (1): 1–15. DOI: 10.1038/s41598-020-80820-1
- 131.Shiferaw, B. – Prasanna, B. – Hellin, J. – Bänziger, M.: 2011. Crops that feed the world 6. Past successes and future challenges to the role played by maize in global food security. *Food Security*. 3: 307–327. <https://doi.org/10.1007/s12571-011-0140-5>
- 132.Simić, M. – Dragičević, V. – Mladenović-Drinić, S. – Vukadinović, J. – Kresović, B. – Tabaković, M. – Brankov, M.: 2020. The contribution of soil tillage and nitrogen rate to the quality of maize grain. *Agronomy*. 10. (7): 976. <https://doi.org/10.3390/agronomy10070976>
- 133.Singh, N., Kaur, A., Shevkani, K. In: Chaudhary, D. P., Kumar, S., Langyan, C., Singh, A. K. (eds.) *Maize: Nutrition Dynamics and Novel Uses* 2014. Maize: Grain structure, composition, milling, and starch characteristics. Springer. 65–76. https://doi.org/10.1007/978-81-322-1623-0_5
- 134.Smith, B. D.: 2001. Documenting plant domestication: the consilience of biological and archaeological approaches. *Proceedings of the National Academy of Sciences of the United States of America*. 98: 1324–1326.
- 135.Souza, P. V. D. – Rezende, L. P. – Duarte, A. P. D. – Miranda, G. V.: 2023. Maize Yield Prediction using Artificial Neural Networks based on a Trial Network Dataset. *Engineering, Technology & Applied Science Research*, 13(2): 10338–10346. <https://doi.org/10.48084/etasr.5664>
- 136.Szabó, A.–Széles, A.–Illés, Á.–Bojtor, C.–Mousavi, S.–Radócz, L.–Nagy, J.: 2022a. Effect of different nitrogen supply on maize emergence dynamics, evaluation of yield

- parameters of different hybrids in long-term field experiments. *Agronomy*, 12(2): 284.
<https://doi.org/10.3390/agronomy12020284>
- 137.Széles A. – Ragán P. – Huzsvai L. – Nagy J.: 2023a: Climate change impacts and adaptation strategies in maize production in Central Europe. *Sustainability*, 15.(5): 4022.
 doi: 10.3390/su15054022.
- 138.Széles A.–Horváth É.–Simon K.–Zagy P.–Huzsvai L.: 2023b Maize Production under Drought Stress: Nutrient Supply, Yield Prediction. *Plants* 12.(18):3301. DOI: 10.3390/plants12183301.
- 139.Széles, A. – Nagy, J. – Rátónyi, T. – Harsányi, E.: 2019. Effect of differential fertilisation treatments on maize hybrid quality and performance under environmental stress condition in Hungary. *Maydica*. 62: 11–14.
- 140.Széles, A.–Huzsvai, L.–Mohammed, S.–Nyéki, A.–Zagy, P.–Horváth, É.–Simon, K.–Arshad, S.–Tamás, A.: 2024. Precision agricultural technology for advanced monitoring of maize yield under different fertilization and irrigation regimes: A case study in Eastern Hungary (Debrecen). *Journal of Agriculture and Food Research*, 15: 100967.
<https://doi.org/10.1016/j.jafr.2024.100967>
- 141.Takács, I. – Amiri, M. – Károly, K. – Mohammed, S.: 2021. Assessing soil quality changes after 10 years of agricultural activities in eastern Hungary. *Irrigation and Drainage*. 70. (1): 68–76. DOI: 10.1002/ird.2623
- 142.Tanumihardjo, S. A. – McCulley, L. – Roh, R. – Gunaratna, N. S. – Lopez-Ridaura, S. – Palacios-Rojas, N. – Mattei, F. – Pixley, K. V.: 2019. Maize agro-food systems to ensure food and nutrition security in reference to the Sustainable Development Goals. *Global Food Security*. 23: 22-30. DOI: 10.1016/j.gfs.2019.100327
- 143.Taylor, K. E.: 2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*. 106. (D7): 7183–7192.
- 144.TechVidvan.: 2024. Artificial Neural Network – Applications, Algorithms and Examples. <https://techvidvan.com/tutorials/artificial-neural-network/> (letöltve: 2024.09.20.)
- 145.Thakur – A. – Aggarwal – P. – Dubey – A. – Abdelgawad – A. – Rocha – Á.: 2022. Design of decision model for sensitive crop irrigation system. *Expert Systems*. 40. (1):
<https://doi.org/10.1111/exsy.13119>

146. Toishimanov, M. – Suleimenova, Z. – Myrzabayeva, N. – Dossimova, Z. – Shokan, A. – Kenenbayev, S. – Serikbayeva, A.: 2023. Effects of organic fertilizers on the quality, yield, and fatty acids of maize and soybean in southeast Kazakhstan. *Sustainability*. 16. (1): 162. <https://doi.org/10.3390/su16010162>
147. Virág, I., Vad, A., Kutasy, E. *Acta Agraria Debreceniensis* 2020. The effect of irrigation on the yield and quality of maize (*Zea mays* L.) hybrids. (1): 143–147. <https://doi.org/10.34101/actaagrar/1/3778>
148. Viswakumar-A – Mullen-R-W – Sundermeier-A – Dygert-C-E: 2008: Tillage and nitrogen application methodology impacts on corn grain yield. *Journal of Plant Nutrition* 31.11, 1963–1974: <https://doi.org/10.1080/01904160802403102>
149. Wang, J. – Lu, D.: 2022. Starch physicochemical properties of normal maize under different fertilization modes. *Polymers*. 15. (1): 83. <https://doi.org/10.3390/polym15010083>
150. Wang, W. – Van Gelder, P. H. A. J. M. – Vrijling, J. K. – Ma, J.: 2006. Forecasting daily streamflow using hybrid ANN models. *Journal of Hydrology*. 324. (1–4): 383–399. <https://doi.org/10.1016/j.jhydrol.2005.09.032>
151. Wasaya, A. – Tahir, M. – Yasir, T. – Akram, M. – Farooq, O. – Sarwar, N.: 2018. Soil physical properties, nitrogen uptake and grain quality of maize (*Zea mays* L.) as affected by tillage systems and nitrogen application. *Italian Journal of Agronomy*. 13. (4): 1197. <https://doi.org/10.4081/ija.2018.1197>
152. Willett, W. – Rockström, J. – Loken, B. – Springmann, M. – Lang, T. – Vermeulen, S. – Garnett, T. – Tilman, D. – DeClerck, F. – Wood, A. – Jonell, M. – Clark, M. – Gordon, L. J. – Fanzo, J. – Hawkes, C. – Zurayk, R. – Rivera, J. A. – De Vries, W. – Majele Sibanda, L. ... Murray, C. J. L.: 2019. Food in the Anthropocene: The EAT–Lancet Commission on healthy diets from sustainable food systems. *The Lancet*. 393: 447–492. [https://doi.org/10.1016/S0140-6736\(18\)31788-4](https://doi.org/10.1016/S0140-6736(18)31788-4)
153. Xu, H. – Xie, H. – Wu, S. – Wang, Z. – He, K.: 2019. Effects of elevated CO₂ and increased N fertilization on plant secondary metabolites and chewing insect fitness. *Frontiers in Plant Science*. 10: 739. <https://doi.org/10.3389/fpls.2019.00739>
154. Xue, H.–Xu, X.–Meng, X.: 2024. Estimation Model for Maize Multi-Components Based on Hyperspectral Data. *Sensors*, 24(18): 6111. <https://doi.org/10.3390/s24186111>

155. Yu, B.-G. – Chen, X.-X. – Zhou, C.-X. – Ding, T.-B. – Wang, Z.-H. – Zou, C.-Q.: 2022. Nutritional composition of maize grain associated with phosphorus and zinc fertilization. *Journal of Food Composition and Analysis*. 114: 104775. DOI: 10.1016/j.jfca.2022.104775
156. Yuan, C. – Wang, S. – Lu, D.: 2021. Fertilization time of slow-release fertilizer affects the physicochemical properties of starch from spring-sown waxy maize. *Journal of the Science of Food and Agriculture*. 102. (3): 1012–1020. DOI: 10.1002/jsfa.11436
157. Yue, B – Liu, M – Liu, Y – Zhao, R – Liu, L – Li, X – Zhang, W – Li, F – Guo, W: 2022: Nitrogen supply affects yield and grain filling of maize by regulating starch metabolizing enzyme activities and endogenous hormone contents. *Frontiers in Plant Science* 12, 798119: <https://doi.org/10.3389/fpls.2021.798119>
158. Zell, A. – Mache, N. – Huebner, R. – Mamier, G. – Vogt, M. – Schmalzl, M. – Herrmann, K. U.: 1994. SNNS (Stuttgart Neural Network Simulator). In: *Neural Network Simulation Environments*. Springer, Boston, MA, USA. pp. 165–186. DOI: 10.1007/978-1-4615-2736-7_9
159. Zhang, J. – Ding, W.: 2017. Prediction of Air Pollutants Concentration Based on an Extreme Learning Machine: The Case of Hong Kong. *International Journal of Environmental Research and Public Health*. 14. (2): 114. <https://doi.org/10.3390/ijerph14020114>
160. Zhang, Q. – Li, G. – Lu, W. – Lu, D.: 2022. Interactive effects of nitrogen and potassium on grain yield and quality of waxy maize. *Plants*. 11. (19): 2528. <https://doi.org/10.3390/plants11192528>
161. Zhu, Y. – Deng, K. – Wu, P. – Feng, K. – Zhao, S. – Li, L.: 2023. Effects of slow-release fertilizer on lotus rhizome yield and starch quality under different fertilization periods. *Plants*. 12. (6): 1311. <https://doi.org/10.3390/plants12061311>
162. Zsembeli, J., Kovács, G., Czeller, K., Tuba, G. *Acta Agraria Debreceniensis* 2018. Long-term effect of soil management on the carbon-dioxide emission of the soil. 515–527. <https://doi.org/10.34101/actaagrar/150/10724>

12. PUBLIKÁCIÓK AZ ÉRTEKEZÉS TÉMAKÖRÉBEN



**DEBRECENI
EGYETEM**

**DEBRECENI EGYETEM
EGYETEMI ÉS NEMZETI KÖNYVTÁR**

H-4002 Debrecen, Egyetem tér 1, Pf.: 400
Tel.: 52/410-443, e-mail: publikaciok@lib.unideb.hu

Nyilvántartási szám: DEENK/146/2025.PL
Tárgy: PhD Publikációs Lista

Jelölt: Fejér Péter
Doktori Iskola: Kerpely Kálmán Doktori Iskola
MTMT azonosító: 10084000

A PhD értekezés alapjául szolgáló közlemények

Magyar nyelvű tudományos közlemények hazai folyóiratban (1)

1. Ferencsik, S., Rátonyi, T., **Fejér, P.**, Harsányi, E.: A kukorica talajművelési rendszereinek összehasonlító elemzése réti csernozjom talajon.
Agrártud. közl. 60, 21-24, 2014. ISSN: 1587-1282.

Idegen nyelvű tudományos közlemények hazai folyóiratban (6)

2. Zagyó, P., Tamás, A., Rácz, D., **Fejér, P.**, Radócz, L., Horváth, É.: Correlation analysis of relative chlorophyll content and yield of maize hybrids of different genotypes.
Agrártud. Közl. 1, 211-214, 2022. ISSN: 1587-1282.
DOI: <http://dx.doi.org/10.34101/actaagrar/1/10393>
3. Huzsvai, L., **Fejér, P.**, Illés, Á., Bojtó, C., Bojtó, C., Horváth, É., Demeter, C.: Analysis of sweet corn nutritional values using multivariate statistical methods.
Agrártud. Közl. 1, 103-108, 2021. ISSN: 1587-1282.
DOI: <http://dx.doi.org/10.34101/ACTAAGRAR/1/8587>
4. Horváth, É., Tamás, A., **Fejér, P.**, Széles, A.: Effect of different N doses on maize yield and quality.
Agrártud. Közl. 1, 97-101, 2021. ISSN: 1587-1282.
DOI: <https://doi.org/10.34101/actaagrar/1/8493>
5. Horváth, É., **Fejér, P.**, Széles, A.: Examination of drought stress of two genotype maize hybrids with different fertilization.
Agrártud. Közl. 1, 53-57, 2020. ISSN: 1587-1282.
DOI: <http://dx.doi.org/10.34101/actaagrar/1/3757>
6. Horváth, É., **Fejér, P.**, Széles, A.: The impact of climatic factors on the relative chlorophyll content and yield of a maize hybrid in a long-term experiment.
Agrártud. Közl. 1, 71-77, 2019. ISSN: 1587-1282.
DOI: <http://dx.doi.org/10.34101/actaagrar/1/2374>





7. Rátonyi, T., **Fejér, P.**, Veres, S., Harsányi, E.: Influences of soil tillage and fertilization on leaf photosynthetic characteristics of maize (Zeal mays L.) in a long term experiment.
Növénytermelés. 64 (Suppl.2), 173-181, 2015. ISSN: 0546-8191.
DOI: <http://dx.doi.org/10.12666/Novenyterm.64.2015.Suppl2>

Idegen nyelvű tudományos közlemények külföldi folyóiratban (2)

8. **Fejér, P.**, Széles, A., Horváth, É., Rátonyi, T., Ragán, P.: Effects of some agronomic practices on the quality of starch content of maize grains.
Agron. Res. 20 (1), 124-133, 2022. ISSN: 1406-894X.
DOI: <http://dx.doi.org/10.15159/AR.22.006>
9. Széles, A., **Fejér, P.**, Harsányi, E., Huzsvai, L.: Evaluation of Changes Caused by Genotypes and Weather on the Protein and Oil Content of Maize Grains in the Continental Climate of Central European Hungary.
J. Agric. Food Dev. 5 (1), 22-32, 2019. EISSN: 2415-0142.
DOI: <http://dx.doi.org/10.30635/2415-0142.2019.05.3>

Idegen nyelvű konferencia közlemények (1)

10. Rátonyi, T., Nagy, O., Bakó, K. I., **Fejér, P.**, Harsányi, E.: Effects of fertilization on grain quality and bio-ethanol production of maize.
Növénytermelés. 63 (Suppl.), 31-34, 2014. ISSN: 0546-8191.
DOI: <http://dx.doi.org/10.12666/Novenyterm.63.2014.Suppl>

Idegen nyelvű absztrakt kiadványok (9)

11. Rátonyi, T., Tamás, A., **Fejér, P.**, Horváth, É., Széles, A., Ragán, P., Bojtor, C., Illés, Á., Juhász, C., Somogyi, E., Harsányi, E.: Evaluation of soil moisture dynamics in a long-term field experiment set up on chernozem soil.
In: 2nd International Congress on Sustainable Development in the Human Environment - Current and Future Challenges : Proceedings book. Eds.: Atilgan Atilgan, Iksad Institute, Antalya, 27-28, 2024. ISBN: 9786258254600
12. Illés, Á., Széles, A., Rátonyi, T., **Fejér, P.**, Harsányi, E., Ragán, P., Nagy, J., Bojtor, C.: Examination of the ATSAVI index in the case of different nutrient supply and tillage systems in a small plot long-term field experiment with a multispectral UAV.
In: 100 years of soil science - past achievements and future challenges : Centennial Celebration and Congress of the International Union of Soil Sciences : Abstract book / Sara Marinari, Giuseppe Corti, Edoardo A.C. Costantini, Italian Society of Soil Science, Florence, 1419, 2024.





13. Rátónyi, T., **Fejér, P.**, Horváth, É., Széles, A., Ragán, P., Bojtor, C., Illés, Á., Harsányi, E.: The impact of conventional and precision cultivation technology on the moisture content of the chernozem soil.
In: 100 years of soil science - past achievements and future challenges : Centennial Celebration and Congress of the International Union of Soil Sciences : Abstract book / Sara Marinari, Giuseppe Corti, Edoardo A.C. Costantini, Italian Society of Soil Science, Florence, 91 (ID ABS WEB: 137209), 2024.
14. Harsányi, E., **Fejér, P.**, Tamás, A., Széles, A., Ragán, P., Bojtor, C., Illés, Á., Rátónyi, T.: The impact of conventional and precision farming technology on maize yields.
In: 100 years of soil science - past achievements and future challenges : Centennial Celebration and Congress of the International Union of Soil Sciences : Abstract book / Sara Marinari, Giuseppe Corti, Edoardo A.C. Costantini, Italian Society of Soil Science, Florence, 101 (ID ABS WEB: 137239), 2024.
15. Simon, K., Horváth, É., Zagyai, P., **Fejér, P.**, Széles, A.: Effect of abiotic stress factors on quality parameters of sweet corn (*Zea mays* L. convar. *saccharata* Koern.).
In: International Congress on Sustainable Development in the Human Environment- Current & Future Challenges ICSDEC 2022 : Proceedings book. Eds.: Anna Krakowiak-Bal, Atılgan Atılgan, Roman Rolbiecki, Hakan Aktas, Infrastructure and Ecology of Rural Areas Association, Krakow, 52-59, 2022. ISBN: 9788396606211
16. Horváth, É., **Fejér, P.**, Széles, A.: Examination of the nutrient content of various genotype maize hybrids at different N supply levels.
In: Abstract book of the 19th Alps-Adria Scientific Workshop. Ed.: by Zoltán Kende, Szent István Egyetemi Kiadó Nonprofit Kft., Gödöllő, 23, 2020. ISBN: 9789632698960
17. Horváth, É., **Fejér, P.**, Széles, A.: Effect of the production year and artificial fertilization on the yield and protein content of Renfor (FAO 320) maize hybrid.
In: Abstract book of the 18th Alps-Adria Scientific Workshop. Ed.: Zoltán Kende, Csaba Bálint, Viola Kunos, Szent István Egyetemi Kiadó Nonprofit Kft., Gödöllő, 54-55, 2019.
18. Rátónyi, T., Sulyok, D., Duzs, L., Törő, Á., **Fejér, P.**, Nagy, J., Harsányi, E., Ragán, P.: Evaluation of the crop year, soil tillage and fertilisation effect on maize yield using a novel statistical method.
In: Prega Science 2019 : Mezőgazdasági Technika, Agroinform Média Kft, Budapest, 1-2, 2019.
19. Rátónyi, T., Ragán, P., Duzs, L., Nagy, J., Sulyok, D., Vántus, A., Törő, Á., **Fejér, P.**, Vasvári, G., Harsányi, E.: The Effect of Conventional and Conservation Tillage Systems on Maize Yield.
In: XV European Society for Agronomy Congress; ESA2018. Ed.: Christoph Carjen, MDPI AG, Geneva, 128, 2018.





További közlemények

Magyar nyelvű tudományos közlemények hazai folyóiratban (1)

20. Harsányi, E., **Fejér, P.**, Kutasiné Nagy, I., Rátonyi, T.: A vidékiség értelmezése és a földhasználat helyzete Magyarországon.
Agrártud. Közl. 61, 79-85, 2014. ISSN: 1587-1282.
DOI: <http://dx.doi.org/10.34101/actaagrar/61/2044>

Idegen nyelvű konferencia közlemények (2)

21. Ragán, P., Rátonyi, T., Széles, A., **Fejér, P.**, Bácskai, I., Harsányi, E.: A cheap alternative to data management and creating of yield maps of small-plot field experiments.
In: Proceedings of the 1st African Conference on Precision Agriculture, African Plant Nutrition Institute, Benguéir, 105-111, 2020.
22. Rátonyi, T., Ragán, P., Széles, A., **Fejér, P.**, Bácskai, I., Harsányi, E.: Preparation of a precision ripping plan using manual vertical penetrometer measurements.
In: Proceedings of the 1st African Conference on Precision Agriculture, African Plant Nutrition Institute, Benguéir, 103-106, 2020.

Idegen nyelvű absztrakt kiadványok (2)

23. Bojtor, C., Széles, A., Rátonyi, T., **Fejér, P.**, Harsányi, E., Nagy, J., Illés, Á.: Phosphorus as a key factor in soil nutrient ecosystems - a case study based on longterm field trial data.
In: 100 years of soil science - past achievements and future challenges : Centennial Celebration and Congress of the International Union of Soil Sciences : Abstract book / Sara Marinari, Giuseppe Corti, Edoardo A.C. Costantini, Italian Society of Soil Science, Florence, 877 (ID ABS WEB: 137196), 2024.
24. Duzs, L., Ragán, P., **Fejér, P.**, Vántus, A., Rátonyi, T.: The effects of the soil tillage and the fertilization on the relative chlorophyll content (SPAD-values) of the maize (*Zea Mays L.*) leaves.
In: Abstract book of the 18th Alps-Adria Scientific Workshop. Ed.: Zoltán Kende, Csaba Bálint, Viola Kunos, Szent István Egyetemi Kiadó Nonprofit Kft., Gödöllő, 50-51, 2019. ISBN: 9789632698182



A DEENK a Jelölt által a Tudóstérbe feltöltött adatok bibliográfiai és tudánymetriai ellenőrzését a tudományos adatbázisok és a Journal Citation Reports Impact Factor lista alapján elvégezte.

Debrecen, 2025.04.11.

13. KÖSZÖNETNYILVÁNÍTÁS

2000 óta kisebb megszakításokkal a Debreceni Egyetem Böszörményi úti campusához köt az életem. Gazdasági agrármérnök hallgatóként itt végeztem 2006-ban, majd 2008-tól kezdve folyamatosan itt dolgoztam. Az elmúlt évtizedek alatt rendkívül sok támogatást és segítséget kaptam kollégáktól, oktatóktól, vezetőktől; ezért őszinte hálával tartozom.

Külön köszönetemet szeretném kifejezni Prof. Dr. Nagy Jánosnak és Prof. Dr. Kakuszi-Széles Adrienn Intézetvezető Asszonynak a folyamatos iránymutatásukért. Kutatásom megalapozásában és megvalósításában kulcsszerepük volt, hiszen a kísérlet elindításával, fenntartásával és az adatok biztosításával elengedhetetlen támogatást nyújtottak.

Ezúton mondok köszönetet Dr. Rátonyi Tamásnak, témavezetőmnek, akinek köszönöm a türelmét és minden segítségét az évek során.

Köszönetet mondok továbbá Prof. Dr. Harsányi Endrének is, aki 2008 óta töretlenül támogatta szakmai munkámat, és akinek biztatása és támogatása az évek során sokat jelentett számomra.

Hálás vagyok Dr. Safwan Mohammed kollégámnak az innovatív gondolatokért és inspiráló iránymutatásáért, melyek új nézőpontokat és megoldásokat hoztak a kutatásomba.

Ugyancsak köszönet illeti Dr. Ragán Pétert, aki a kutatás minden szakaszában megbízható szakmai és gyakorlati segítséget nyújtott.

Köszönöm még Prof. Dr. Juhász Csabának, hogy konstruktív észrevételeivel folyamatosan ösztönözte a munkámat.

Köszönöm Elek Erzsébetnek, Dorogi Zsuzsannának és Baginé Dr. Hunyadi Ágnesnek az adminisztratív folyamatok során nyújtott precíz és készséges segítséget.


Köszönöm kollégáimnak, hogy szakmai utamat segítették és támogattak.

Végül pedig köszönöm családomnak a türelmet és támogatást a tézis elkészítése során.

14. NYILATKOZATOK

Ezen értekezést a Debreceni Egyetem Kerpely Kálmán Növénytermesztési és Kertészeti Tudományok Doktori Iskola keretében készítettem el a Debreceni Egyetem (PhD) fokozatának elnyerése céljából.

Debrecen, 2025. augusztus 29.



.....
jelölt aláírása

Tanúsítom, hogy **Fejér Péter István** doktorjelölt 2024 és 2025 között a fent megnevezett Doktori Iskola keretében irányításommal végezte munkáját. Az értekezésében foglalt eredményekhez a jelölt önálló alkotó tevékenységével meghatározóan hozzájárult, az értekezés a jelölt önálló munkája. Az értekezés elfogadását javaslom.

Debrecen, 2025. augusztus 29.



.....
témavezető aláírása