

DOKTORI (PhD) ÉRTEKEZÉS

ZSEBŐ SÁNDOR

MOSONMAGYARÓVÁR

2025

SZÉCHENYI ISTVÁN EGYETEM

ALBERT KÁZMÉR MOSONMAGYARÓVÁRI KAR

BIOLÓGIAI RENDSZEREK ÉS PRECÍZIÓS TECHNOLÓGIAI TANSZÉK

**WITTMANN ANTAL NÖVÉNY-, ÁLLAT- ÉS ÉLELMISZER-TUDOMÁNYI
MULTIDISZCIPLINÁRIS**

DOKTORI ISKOLA

HABERLANDT GOTTLIEB NÖVÉNYTUDOMÁNYI DOKTORI PROGRAM

DOKTORI ISKOLAVEZETŐ:

PROF. DR. VARGA LÁSZLÓ PhD

EGYETEMI TANÁR

PROGRAMVEZETŐ:

PROF. DR. PINKE GYULA PhD

EGYETEMI TANÁR

TÉMAVEZETŐ:

PROF. DR. KOVÁCS ATILA JÓZSEF, EGYETEMI TANÁR

PROF. DR. MILICS GÁBOR, EGYETEMI TANÁR

**Távérzékelési adatok alkalmazása tág térállású kultúrák precíziós
növénytermesztése során**

KÉSZÍTETTE:

ZSEBŐ SÁNDOR

MOSONMAGYARÓVÁR

2025

Távérzékelési adatok alkalmazása tág térállású kultúrák precíziós
növénytermesztése során

Írta:
ZSEBŐ SÁNDOR

**Készült a Széchenyi István Egyetem Albert Kázmér Mosonmagyaróvári Kar
Wittmann Antal Növény-, Állat- és Élelmiszer- tudományi Multidiszciplináris
Doktori Iskola**

Haberlandt Gottlieb Növénytudományi Doktori Programja keretében

**Témavezető: Prof. Dr. habil. Kovács Attila József, Prof. Dr. habil. Milics
Gábor**

Elfogadásra javaslom (igen / nem)

(aláírás)

A jelölt a doktori szigorlaton.....%-ot ért el,

Mosonmagyaróvár,

.....

a Szigorlati Bizottság Elnöke

Az értekezést bírálóként elfogadásra javaslom (igen/nem)

Első bíráló (Dr.) igen/nem

(aláírás)

Második bíráló (Dr.) igen/nem

(aláírás)

Esetleg harmadik bíráló (Dr.) igen/nem

(aláírás)

A jelölt az értekezés nyilvános vitáján%-ot ért el.

Mosonmagyaróvár,

A Bírálóbizottság elnöke

Doktori (PhD) oklevél minősítése.....

Az EDT elnöke

Tartalom

| | |
|--|----|
| Kivonat..... | 4 |
| Abstrakt..... | 6 |
| 1. Bevezetés..... | 8 |
| 2. Irodalmi áttekintés..... | 10 |
| 2.1. A búza termesztése – a távérzékeléssel vizsgált növény..... | 10 |
| 2.1.1. Az őszi búza világgazdaságban betöltött szerepe..... | 10 |
| 2.1.2. Őszi búza rendszertani besorolása és származása..... | 10 |
| 2.1.3. Őszi búza éghajlati igénye..... | 11 |
| 2.1.4. Gabonanövények fejlődésének szakaszai..... | 12 |
| 2.1.5. Búzatermesztés a zöld forradalomtól napjainkig..... | 16 |
| 2.2. Távérzékelési eszközökkel történő adatgyűjtés..... | 18 |
| 2.2.1. Műholdak alkalmazása mezőgazdasági célokra..... | 18 |
| 2.2.2. Pilóta nélküli légi járművekkel megvalósuló adatgyűjtés..... | 25 |
| 2.3. Földközeli szenzorok használata az agráriumban..... | 30 |
| 2.4. Vegetációs indexek alkalmazása a mezőgazdaságban..... | 31 |
| 2.4.1. Normalizált Vegetációs Index..... | 33 |
| 2.5. Különböző kultúrákban végzett hozambecslések..... | 36 |
| 2.5.1. Hozambecslés multispektrális UAV-felvételek alapján..... | 38 |
| 2.5.2. Hozambecslés a GreenSeeker adatai alapján..... | 42 |
| 2.5.3. Hozambecslés az NDVI értékek és a környezeti paraméterek figyelembevételével..... | 43 |
| 3. Anyag és módszer..... | 46 |
| 3.1. Kísérleti területek földrajzi elhelyezkedése..... | 46 |
| 3.1.1. Kutatási terület éghajlata..... | 47 |
| 3.1.2. A kutatási területek éves meteorológiai adatai..... | 48 |
| 3.2. Kísérleti helyszínek..... | 51 |
| 3.2.1. Fenyőmajori kísérlet..... | 52 |
| 3.2.2. Genezises kísérlet..... | 58 |
| 3.3. Adatgyűjtő eszközök bemutatása..... | 62 |
| 3.3.1. Sentinel-2 műhold..... | 63 |
| 3.3.2. MicaSense RedEdge-MX Dual kamerarendszer..... | 63 |

| | |
|---|-----|
| 3.3.3. Phantom 4 multispektrális kamera..... | 66 |
| 3.3.4. GreenSeeker HCS-250..... | 68 |
| 3.4. Adatgyűjtés módszere..... | 70 |
| 3.4.1. Genezises kísérlet | 70 |
| 3.4.2. Fenyőmajori kísérlet | 73 |
| 3.5. Adatfeldolgozás módszertana | 75 |
| 3.5.1. Képfeldolgozás folyamata az Agisoft Metashapeben..... | 75 |
| 3.5.2. Adatfeldolgozás módszertana a QGIS-ben..... | 78 |
| 3.5.3. Meteorológiai adatok elemzésének módszertana | 81 |
| 3.6. Alkalmazott statisztikai módszerek bemutatása..... | 81 |
| 3.6.1. Genezises kísérlet | 81 |
| 3.6.2. Fenyőmajori kísérlet | 84 |
| 4. Eredmények és értékelésük | 87 |
| 4.1. Genezises kísérlet..... | 87 |
| 4.1.1. Kutatáshoz kapcsolódó meteorológiai adatok | 87 |
| 4.1.2. Szűkített talajvizsgálati eredmények | 88 |
| 4.1.3. NDVI értékek összehasonlítása a különböző kezeléseknél | 89 |
| 4.1.4. Különböző kezelések kapcsolata a hozammal..... | 90 |
| 4.1.5. Korreláció az NDVI értékek és az őszi búza hozama között..... | 91 |
| 4.1.6. Őszi búza hozambecslése NDVI értékek alapján | 96 |
| 4.1.7. Hozambecslési egyenlet kiegészítése a VUN és a KNFHŐ értékekkel..... | 101 |
| 4.1.8. Modell validáció | 109 |
| 4.2. Fenyőmajori kísérlet | 111 |
| 4.2.1. GreenSeeker, Phantom 4 és MicaSense kamera adataiból kalkulált NDVI értékek összehasonlítása | 111 |
| 4.2.2. Négy szenzor adataiból kalkulált NDVI értékek összehasonlítása | 112 |
| 4.2.3. GreenSeeker és Sentinel-2 műhold adataiból számított NDVI értékek összehasonlítása | 115 |
| 5. Következtetések és javaslatok | 118 |
| 5.1. A GreenSeeker és a MicaSense NDVI értékek összehasonlítása ... | 118 |
| 5.2. Hozampredikció az NDVI értékek alapján | 119 |

| | |
|---|-----|
| 5.3. Hozampredikációs egyenletek alkalmazása..... | 120 |
| 5.4. Időjárási körülmények kapcsolata a hozammal | 122 |
| 5.5. Szenzorok összehasonlítása a hozampredikációs-modellben | 124 |
| 5.6. Négy szenzor NDVI értékének összehasonlítása | 125 |
| 5.7. GreenSeeker és Sentinel-2 műhold adataiból kalkulált NDVI értékek összehasonlítása | 127 |
| 6. Új tudományos eredmények..... | 129 |
| 7. Összefoglalás..... | 131 |
| 8. Publikációs jegyzék..... | 134 |
| 8.1. Az értekezés témakörében megjelent publikációk..... | 134 |
| 8.1.1. Tudományos közlemény, magyar nyelvű, lektorált folyóiratban: | 134 |
| 8.1.2. Tudományos közlemény, idegen nyelvű, lektorált folyóiratban: | 134 |
| 8.1.3. Proceedings, idegen nyelven: | 134 |
| 8.2. Egyéb témakörben megjelent publikációk: | 135 |
| 8.2.1. Impakt faktoros:..... | 135 |
| 8.2.2. Proceedings, idegen nyelven: | 135 |
| 8.2.3. Ismeretterjesztő közlemények: | 136 |
| 9. Irodalomjegyzék..... | 137 |
| 9.1. Internetes források..... | 167 |
| 10. Mellékletek..... | 168 |
| 11. A disszertációban szereplő rövidített vegetációs indexek feloldása..... | 171 |
| 12. Köszönetnyilvánítás | 172 |

KIVONAT

Különböző szenzorok adataiból kalkulált NDVI értékek összehasonlítása és kapcsolatuk az őszi búza hozamával

A disszertáció a precíziós gazdálkodás két fontos tématerületével, az őszi búza várható hozambecslésével és a különböző szenzorok adataiból kinyert NDVI (Normalized Difference Vegetation Index) értékek összehasonlításával foglalkozik.

Az egyre szélsőségesebbé váló időjárás körülmények miatt fokozódó kihívásokkal kell szembenézniük a várható hozammennyiségek meghatározása terén a gazdálkodóknak.

A szerző a hozamelőrejelzéssel kapcsolatos hazai és nemzetközi szakirodalom tanulmányozását követően megállapította, hogy különböző kultúrákban végeztek hozampredikációs eljárásokat a környezeti paraméterek bevonásával, azonban sok esetben ellentétes eredményeikről számoltak be a tanulmányokban. Az eltérő szakirodalmi eredmények arra utaltak, hogy a hozampredikáció területén további vizsgálatokra van szükség. Ezért jelen disszertáció fókuszában az őszi búza vizsgálata állt, míg az adatok gyűjtése egy kézi GreenSeeker optikai érzékelő és egy MicaSense RedEdge-MX dual kamerarendszer segítségével valósult meg.

A kapott eredmények kiértékelése különböző statisztikai (Student-féle t-próba, egy- és kéttényezős varianciaanalízis, regresszióanalízis, Levene-teszt, Tukey-féle post hoc-teszt, Pearson-féle korrelációs elemzés, determinációs együtthatók meghatározása) és modellezési módszerek (lineáris, exponenciális, kvadratikus) alapján történt.

A kutatási eredmények alapján megállapítható, hogy a GreenSeeker kézi szenzor méréseivel pontosabban és több időpontban határozható meg az őszi búza várható hozama, mint a MicaSense kamera adataiból kalkulált NDVI értékekből.

A modellszámítási eredmények pedig bebizonyították, hogy a lineáris modellel és a kumulált napi fejlődési hőmérsékleti összeg bevonásával sikerült a hozampredikációs-modellen javítani.

A több szenzor adataiból kinyert NDVI értékek egyidőben történő összehasonlítása képezi a dolgozat másik részét. Az NDVI az egyik leggyakrabban használt vegetációs index, ezért számos területen alkalmazzák a mezőgazdaságban. Azonban a hazai és nemzetközi szakirodalom áttanulmányozását követően kevés információ található földi, földközeli és műholdas szenzorok egyidőben történő idősoros összehasonlításáról.

Az őszi búzában gyűjtött adatok kiértékelése a már korábban is említett összetett statisztikai eljárásokkal történtek. A vizsgálat eredményei alapján fontos szempont, hogy az őszi búza különböző fejlődési szakaszaiban melyik eszköz NDVI értékeit vesszük figyelembe, ugyanis a vizsgált időpontok döntő többségében szignifikáns ($p \leq 0,05$) különbségek figyelhetők meg a szenzorok adataiból kalkulált NDVI értékei között.

Végül lineáris kevert modellt építettem, ahol a GreenSeeker és a Sentinel-2 műhold adataiból kalkulált NDVI értékek összehasonlíthatóságát vizsgáltam. Eredményeim alapján nagyon szoros összefüggés figyelhető meg a két szenzor NDVI értékei között.

ABSTRAKT

Comparison of NDVI values calculated from different sensor data and their relationship with winter wheat yield

The dissertation addresses two critical topics in precision agriculture: predicting winter wheat yield and comparing NDVI (Normalized Difference Vegetation Index) values derived from various sensor data. Due to increasingly extreme weather conditions, farmers face growing challenges in accurately estimating expected yields.

Following a review of national and international literature on yield forecasting, the author identified that yield prediction methods have been applied to various crops using environmental parameters. However, studies often reported conflicting results, indicating a need for further investigation in yield prediction. Therefore, this dissertation focuses on yield prediction of winter wheat, with data collected using a handheld GreenSeeker optical sensor and a MicaSense RedEdge-MX dual-camera system.

The collected data were analyzed using various statistical (Student's t-test, one- and two-factor analysis of variance, regression analysis, Levene's test, Tukey's post hoc test, Pearson correlation analysis, and determination coefficients) and modelling methods (linear, exponential, quadratic).

The research findings indicate that the GreenSeeker handheld sensor provides more accurate yield predictions for winter wheat and can measure at more time points than NDVI values derived from the MicaSense camera data. Additionally, the modelling results

demonstrated that incorporating a linear model and the cumulative growing degree days significantly improved the yield prediction model. The other part of the dissertation focuses on the comparison of NDVI values derived from multiple sensors. NDVI is one of the most widely used vegetation indices, and it is applied extensively in agriculture. However, national and international literature review revealed limited information on the simultaneous time-series comparison of NDVI values derived from ground-based, proximal, and satellite sensors.

The data collected for winter wheat was evaluated using the complex statistical procedures mentioned above. Results highlight that the selection of sensor NDVI values during different vegetation stages of winter wheat is crucial, as significant differences ($p \leq 0.05$) were observed in the NDVI values calculated from the sensors during most of the examined time points.

Finally, a linear mixed-effects model was developed to examine the comparability of NDVI values derived from the GreenSeeker sensor and Sentinel-2 satellite data. The results revealed a strong correlation between the NDVI values obtained from these two sensors.

1. BEVEZETÉS

Az elmúlt évszázadban a mezőgazdasági termelés óriási átalakuláson ment keresztül. Az ipari forradalom után a technológiai fejlődés gyors ütemben folytatódott, a gépesítés, a vegyipar és az információs technológia terén bekövetkező innovációk alapjaiban változtatták meg az élelmiszertermelést.

A világ legtöbb országában, mint Magyarországon is az őszi búza (*Triticum aestivum* L.), az egyik legfontosabb és legnagyobb területen termesztett kultúrnövény (Curtis, 2022). Azonban a globális felmelegedés és az egyre szélsőségesebbé váló időjárási körülmények miatt egyre kevesebb szántóterület áll a gazdálkodók rendelkezésére. Ugyanakkor a Föld növekvő lakosságának élelmiszerigénye folyamatosan emelkedő tendenciát mutat.

Magyarország mezőgazdasága sok más országhoz hasonlóan fokozatosan sebezhetőbbé válik a globális felmelegedés miatt. Az eddig megszokott gazdálkodási gyakorlatokon változtatni kell, mivel komoly aggályok merülnek fel talajok vagy talaj- és felszíni vizek védelmével és megőrzésével kapcsolatban (Sun et al., 2017; Zhang et al., 2020). A precíziós gazdálkodás éppen ezen erőforrások megőrzésében nyújthat segítséget, emellett alkalmazásával növelhetők a terméshozamok és csökkenthetők a vetésterületek változatosságát, valamint a kijutatott inputanyagok mennyisége (Yost et al., 2017).

A távérzékelési és földközeli szenzorok fontos szerepet játszanak a növényállományok egészségének és fejlődésének a monitorozásában. Azonban az elérhető információk alapján továbbra is kihívást jelent pontosan meghatározni, hogy mely szenzorból – és mikor –

kalkulálhatók ki a legjobb NDVI értékek az őszi búza várható hozamának meghatározásához.

Kutatómunkám célkitűzései a következők:

- GreenSeeker és MicaSense RedEdge-MX multispektrális adataiból kalkulált NDVI értékek összehasonlítása különböző tápanyaggal ellátott kezelések esetében a hozampredikációs modellbe való integrálás érdekében.
- Különböző kezelések és a hozam közötti kapcsolat feltárása az NDVI értékek alapján.
- Őszi búza hozambecslése a MicaSense kamera és a GreenSeeker adataiból kalkulált NDVI értékek alapján.
- Hozambecslési modell kidolgozása az NDVI értékek, a vetés utáni napok és a kumulált napi fejlődési hőmérsékleti összeg bevonásával.
- Sentinel-2, MicaSense és Phantom 4 multispektrális kamera és a GreenSeeker adataiból számított NDVI értékek egy időben történő összehasonlítása a hozampredikációs-modellbe bevont szenzorok jövőbeli kibővítésének céljából.
- Optimális mintavételezési szám meghatározása a GreenSeeker és a Sentinel-2 műhold által gyűjtött adatok összehasonlíthatósága érdekében.

2. IRODALMI ÁTTEKINTÉS

2.1. A búza termesztése – a távérzékeléssel vizsgált növény

2.1.1. Az őszi búza világgazdaságban betöltött szerepe

A világ népességének az egyik legfontosabb kultúrnövénye az őszi búza (*Triticum aestivum* L.), amely már 8000 éve az emberiség alapvető élelmiszerének számít (Curtis, 2022). Napjainkban az emberek által elfogyasztott kalória- és fehérjemennyiség 20 %-át teszi ki (Curtis et al., 2014). A globális élelmiszerbiztonság megőrzése szempontjából is kulcsfontosságú szerepet hárul az őszi búza termesztésére (Shiferaw et al., 2013), ezért a termésbiztonság megőrzéséért elengedhetetlen az állományok folyamatos nyomon követése. Továbbá az őszi búza teljes vegetáció alatti megfigyelése nagyban hozzájárul az okszerű, precíz gazdálkodáshoz és a különböző nemesítési programok sikeréhez (Tester et al., 2010; Magney et al., 2016).

2.1.2. Őszi búza rendszertani besorolása és származása

A búza a zárvatermők (Angiospermae) törzsébe, az egyszikűek (Monocotyledoneae) osztályába, a pelyvások (Glumiflorae) alosztályába, a pászitfűvek (Poales) rendjébe, a pászitfűfélék (Poaceae) családjába, a perjefélék (Pooideae) alcsaládjába, a Triticeae törzsébe, a Triticinae altörzsébe és a búzanemzetségbe (*Triticum*) tartozik (Radics, 2010). A legelterjedtebb búzafaj a *Triticum aestivum* L. Valószínűleg a tetraploid csoportba tartozó fajok és egy vad pászitfű (*Aegilops cylindrica* L.) kereszteződése révén, Délnyugat-Ázsiában alakult ki,

majd onnan terjedt el még a történelem előtti korban Európa-szerte (Láng, 1976).

A korábban Európában, Nyugat-Ázsiában és Afrikában élő civilizációk ősi búzát termesztettek, amelyet ma alakornak vagy egyszemű búzának (*Triticum monococcum* L.), tönkebúzának vagy kétszemű búzának (*Triticum dicoccon* Schrank), kamutnak vagy khorasan búzának (*Triticum turanicum* Jakubz.) és tönkölynek (*Triticum spelta* L.) neveznek. Ezekből a vad vagy ősi búzákból nemesített fajták napjainkban ismét egyre nagyobb népszerűségnek örvendenek olyan emberek körében, akik a modern búzafajtákra allergiásak, viszont ezeknek a fajtáknak az elfogyasztását tolerálja a szervezetük (Molber et al., 2005; Bordoni et al., 2017).

2.1.3. Őszi búza éghajlati igénye

Rendkívül jó adaptációs képességének is köszönhető, hogy ugyan a búza egy mérsékelt éghajlati övben hatékonyan termeszthető növény, azonban rendkívül szélsőséges éghajlati feltételek mellett is, akár -20°C és 40°C közötti hőmérséklet-tartományban is képes termést hozni. A hótakaróval borított állomány könnyebben átvészeli a tartósan fagypon alatti időjárást, mint a hóval fedetlen. Azonban 90 napot követően már káros hatással lehet a hó jelenléte a növényállomány fejlődésére. A búza növekedésénél fontosabb az arányos csapadékeloszlás, mint a lehullott csapadékmennyiség. Minimálisan 300-350 mm-re, míg az optimális fejlődéshez 500-600 mm csapadékra van szüksége a vegetációs periódusa során (Antal et al., 2005).

Magda et al. (2000) kutatása alapján Magyarország teljes területe megfelelő éghajlati szempontból a búza termesztésére. Ezt támasztja

alá Láng (1976) korábbi kutatása is, azonban ő felhívta a figyelmet, hogy bár megfelelő, mégsem egyaránt kedvező, ugyanis a kiegyenlítettebb éghajlatú Dunántúlon kisebbek a terméshozadások, mint a szélsőségesebb éghajlatú Alföldön. Ágoston et al. (2005) megállapítása szerint a változékony, szélsőséges időjárási körülmények jelentik a legnagyobb kockázati tényezőt a búza termesztése során. Éppen a változó klimatikus környezeti tényezők miatt lényeges, hogy az időjárási szélsőségekkel szemben ellenálló fajták legyenek a köztermesztésbe vonva (Reynolds et al., 2015). Becslések szerint a szárazság és a hőség következtében 9-10 %-kal csökkennek világszerte az éves hozamok (Lesk et al., 2016).

2.1.4. Gabonanövények fejlődésének szakaszai


A gabonanövények fejlődési szakaszait először 1941-ben Willem Feekes (1. táblázat) kategorizálta be. Az osztályozás során 11 szakaszra bontotta a növények teljes fejlődési ciklusát (Feekes, 1941; Large et al., 1954).

1. táblázat: A kalászos gabonák fenológiai fázisai a Feekes- és a Zadoks-féle skálabeosztás alapján (Feekes, 1941; Zadoks et al., 1974).

| Fenológiai fázis | Feekes | Zadoks |
|--------------------|-----------------|--------|
| | Skálabeosztások | |
| Kelés | 1 | 10 |
| 1 levél | 1,1 | 11 |
| 2 levél | 1,2 | 12 |
| 3 levél | 1,3 | 13 |
| Bokrosodás kezdete | 2 | 21 |
| Bokrosodás | 3 | 22 |

| | | |
|------------------------|-------------|-------|
| Bokrosodás vége | 4 | 23 |
| Szárbaingulás | 5 | 30 |
| 1 nádusz | 6 | 31 |
| 2 nádusz | 7 | 32 |
| Zászlós levél | 8 | 37 |
| Nyelvecske | 9 | 45 |
| Levélhüvely felnyílása | 10 | 47 |
| Kalászhányás kezdete | 10,1 | 51 |
| Kalászhányás vége | 10,5 | 59 |
| Virágzás-érés | 10,51-11,51 | 61-95 |

Ezt követően Zadoks et al. (1974) továbbfejlesztették (1. ábra) és sokkal részletesebben kidolgozták a Feekes-féle skálát (1. táblázat), ahol 99 különböző fenológiai fázist különítettek el. Ennél a kategorizálásnál már sokkal kisebb léptékek figyelhetők meg az egyes fejlődési szakaszok között.



1. ábra: Gabonafélék fenológiai fázisai a Zadoks-féle skála alapján (Forrás: Zadoks et al., 1974).

Végül egy német-angol összefogásnak köszönhetően 1981-ben megalkották a BBCH (Biologische Bundesanstalt, Bundessortenamt und Chemische Industrie) kódrendszert, amely a növények fenológiai

fázisainak azonosítására szolgált. Alapját a Zadoks-skála (1. ábra) képezte. Ennél a skálázásnál is 0 és 99 közötti értékekkel látták el a különböző fejlődési szakaszokat (Tottman et al., 1979, Meier, 2001), azonban ez a kódrendszer a kutatóintézetek, mezőgazdasági vállalatok és állami szervezetek kooperációjából született meg. Az őszi búza fenológiai fázisainak számszerűsítése agronómiai szempontból is fontos lépésnek bizonyult, mivel sok növényvédő szer gyártó vállalat ezek alapján tesz növényvédelmi ajánlásokat (Radics, 2010).

A különböző szakemberek által kidolgozott kategorizálásoktól eltekintve, az őszi búza fejlődését hat fő szakaszra lehet bontani (Radics, 2003):

- kelés
- bokrosodás
- szárbaindulás
- kalászolás
- virágzás és megtermékenyülés
- érés.

A csírázás kezdeti szakaszától a kelés befejezéséig tartó időintervallumot tekinthetjük az őszi búza kelési időszakának. Optimális körülmények között a vetéstől számított 12-14 napig már lezajlik ez a folyamat (Antal et al., 2005).

A bokrosodás időszaka az első mellékhajtás megjelenésétől a szárbaindulásig tart. Antal et al., (2005) munkássága alapján ez az időszak optimális körülmények között 50-60 nap alatt lezajlik, azonban míg a bokrosodás ősszel kezdődik, addig a szervdifferenciálódás minden esetben tavasszal történik. Ezzel ellentétes következtetésre

jutott Radics (2010), aki szerint a bokrosodásnak nincs meghatározott ideje, időjárástól függően ősszel és tavasszal is történhet.

A szárbaindulás időszaka az első nádusz megjelenésétől a kalászolás kezdetéig tart. Ebben a fejlődési szakaszban dől el a kalászkánkénti virágszám. Továbbá fontos a vernalizációs és a fényszakasz is, mivel csak akkor indul szárba a növény, ha a fajtára jellemző vernalizációs igényük teljesül. A szárbaindulás időszakának második felében a fényhatásnak van nagyobb szerepe, ugyanis a hosszabb megvilágítás gyorsítja a növények fejlődését (Radics, 2010).

A kalászhányás időszaka az első kalász megjelenésétől a teljes kalászolásig tart, ekkor dől el a termékenyülő virágok száma. Hazánkban általában május végére esik ez az időszak és rövid ideig (4-9 nap) tart (Antal et al., 2005).

A virágzás időszaka az első portokok megjelenésétől az összes kalászka elvirágzásáig tart. A virágzás előtti folyamatok a szemszámot, míg a virágzás utániak az átlagos szemtömeget határozzák meg (Antal et al., 2005).

Végül az érés az utolsó fő fejlődési szakasz, amelyet további négy részre lehet bontani:

- Tejesérés (BBCH 70-79): megkezdődik a szemtermés fejlődése.
- Viaszérés (BBCH 80-85): a szem méretben kifejlődött, de kezdetben még lágy (BBCH 83), majd a viaszérés végére (BBCH 85) a szemek megkeményednek.
- Teljes érés (BBCH 89): a szemek már betakarítható válnak.
- Holtérés (BBCH 93-99): a növényt nem takarítják be optimális időben, emiatt a szemek kiperegnek és romlanak a beltartalmi értékek (Zadoks et al., 1974; Antal et al., 2005).

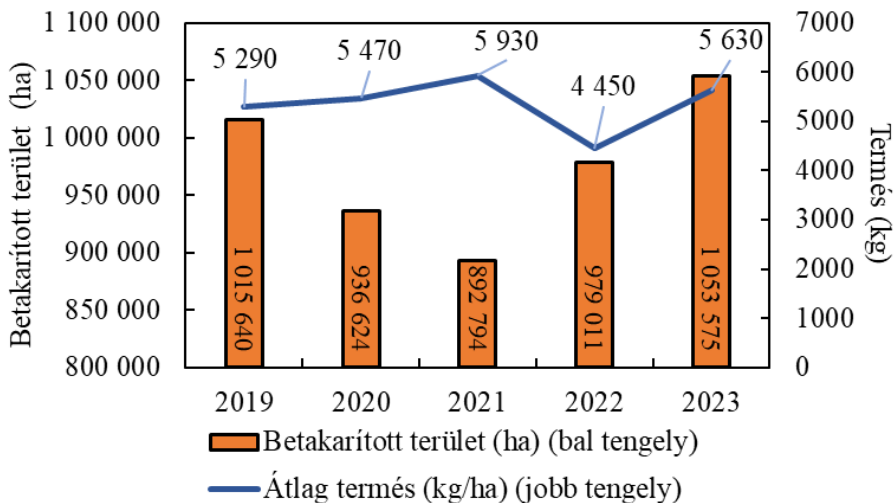
2.1.5. Búza termesztés a zöld forradalomtól napjainkig

Az 1950-es években bekövetkezett „zöld forradalom” óta az intenzív búza termesztés, illetve a hozamok növekedésének fenntartása érdekében jelentősen megnőtt a műtrágyák – azon belül is a nitrogénműtrágyák (N) – használata (Borlaug, 1958; Han et al., 2015; Ali et al., 2018). Az őszi búza hozamának növelése céljából a gazdálkodók gyakran – de tévesen – az általános ajánlásnál nagyobb mennyiségben juttatnak ki nitrogénműtrágyát (Heffer et al., 2017).

A hagyományos gazdálkodási gyakorlatoknál az elmúlt évek során betakarított hozamok átlagai alapján határozzák meg a kijuttatandó N műtrágya mennyiségét (Stanford, 1973). Azonban egy adott év hozama biztosan eltér az elmúlt évek átlagától (Dahnke et al., 1984), így a termés tér-időbeli változékonysága irreális N műtrágya-kijuttatáshoz és alacsony hasznosuláshoz vezethet. A növények fejlődéséhez, illetve szükségletéhez igazított műtrágya-kijuttatás nagymértékben javíthatja a műtrágyák hasznosulását (Tucker, 1979).

Az őszi búza nem csak a világon, hanem Magyarország is a legfontosabb szántóföldi kultúra a kukorica mellett. Hosszú évszázadok óta jelentős szerepet tölt be az ország mezőgazdaságában és élelmiszer-ellátásában (Huzsvai et al., 2024). A 2. ábra alapján a 2019-től 2021-ig tartó időszakban ellentétes folyamat játszódott le az őszi búza termésátlaga és a betakarított terület (2. ábra) között. Az egy hektárra vetített termésátlagok folyamatosan növekedtek (5,29 t; 5,47 t, 5,93 t), míg ugyanezekben az években a betakarított területek nagysága csökkenő tendenciát (1 015 640 ha; 936 624 ha; 892 794 ha) mutattak (URL¹).

Ezt követően egy fordulat következett be. 2022-ben a búza betakarított területe 979 011 hektárra (9,7 %-kal) növekedett az előző évihez képest, azonban a betakarított hektáronként termésátlagok 5,93 tonnáról 4,45 tonnára csökkentek, ami 25 %-os visszaesést jelentett. 2023-ban a búza betakarított területe 74 564 hektárral 1 053 575 hektárra növekedett a 2022-es esztendőhöz képest. A hektáronkénti termésátlag pedig 5,63 tonna lett, ami 27 %-os emelkedést mutat az előző esztendőhöz képest, azonban 5 %-kal maradt el a 2021-es átlag terméseredménytől (URL¹).



2. ábra: Őszi búza betakarított területe és a hektáronkénti átlag terméshozamok a 2019 és 2023 közötti időszakban Magyarországon (Forrás: URL¹).

2.2. Távérzékelési eszközökkel történő adatgyűjtés

2.2.1. Műholdak alkalmazása mezőgazdasági célokra

Az első polgári célokra felbocsájtott műholdnak a Landsat 1-et lehet tekinteni, amelyet 1972-ben állítottak földkörüli pályára. Az azt követő években a technológia fejlődésének köszönhetően tovább folytatódtak a műholdak fellövése, amely hozományaként egyre pontosabbak lettek a szolgáltatott adatok (Kowalik et al., 1974; Mulla, 2013; Sozzi et al., 2021).


Napjainkban már számos műhold vagy műholdcsalád kering földkörüli pályán (2. táblázat), mint például a MODIS, a Landsat, a SPOT5 vagy a Sentinel, amelyek különböző hullámhossztartományokban szolgáltatnak adatokat a tengerekről, óceánokról, a földfelszínről, illetve a szántóföldön termesztett növényekben bekövetkezett fiziológiai, biokémiai változásokról (Wardlow et al., 2008; Zheng et al., 2016; Lulla et al., 2021; Shen et al., 2022).

2. táblázat: Különböző műholdak felvételezési sávjainak száma, hullámhossztartományuk, térbeli felbontásuk és visszatérési idejük.

| Szenzor neve | Sávok száma | Hullámhossz (nm) | Térbeli felbontás (m) | Visszatérési idő (nadirban) | Forrás |
|--------------|-------------|-------------------------------------|-----------------------|-----------------------------|------------------------|
| Modis | 36 | 620-965 3660-14385(μm) | 250-1000 | 1-2 | Wardlow et al., 2008. |
| Sentinel-2 | 13 | 443-2190 | 10-60 | 5 | Shen et al., 2022. |
| Landsat-9 | 9 | 435-1384 | 15-30 | 16 | Lulla et al., 2021. |
| SPOT5 | 5 | 480-1750 | 2,5-20 | 2-3 | Zheng et al., 2016. |
| RapidEye | 5 | 440-850 | 5 | 5,5 | Magney et al., 2017. |
| PlanetScope | 8 | 443-865 | 3 | 1 | Sarkar et al., 2023. |
| WorldView-2 | 5 | 450-920 | 0,46-1,84 | 1 | C'ulibrk et al., 2011. |
| CartoSat-2 | 5 | 0,45-0,86 (μm) | 1 | 4 | Agarwal et al., 2022. |

Mezőgazdasági célokra a Föld-megfigyelő műholdak hullámhossztartományai közül leggyakrabban a 400 nm és 900 nm

közötti spektrumokat használják (3. ábra), mivel ezen hullámhosszokból megközelítőleg 100 különböző vegetációs index készíthető (Sozzi et al., 2021).



3. ábra: Látható fény és az infravörös hullámhossztartomány.

Azonban bizonyos esetekben a Sentinel, a Landsat vagy a Modis műholdjai túl alacsony térbeli felbontással (2. táblázat) rendelkeznek egyes kártételek kimutatásához. Az ilyen típusú kihívásokra jelentettek megoldást a kereskedelmi célú műholdak – WorldView-2 – amelyek nagyobb térbeli felbontást biztosítottak (C’ulibrk et al., 2011; Johansen et al., 2018; Navrozidis et al., 2018).

A Nemzeti Repülési és Űrhajózási Hivatal (National Aeronautics and Space Administration – NASA) és az Európai Űrügynökség (European Space Agency – ESA) egy közös megegyezés alapján elhatározták, hogy a Landsat (NASA) és Sentinel (ESA) műholdcsaládok segítségével, a korábbiakhoz képest nagyobb térbeli felbontású multispektrális műholdfelvételeket fognak készíteni a Föld felszínéről. Ennek megvalósítása érdekében a különböző műholdaknak

szinergikusan kell működniük, vagyis a felvételeknek hasonló jellemzőkkel (térbeli, spektrális, radiometriai stb.) kell rendelkezniük. Az együttműködés sikere a Landsat-7, Landsat-8, és Landsat-9, illetve a Sentinel-2A és Sentinel-2B műholdak pályára állításában nyilvánult meg. Valójában a Sentinel műholdakat a Landsat program támogatására tervezték, amelyekkel egyben a SPOT program folytonosságát is biztosítják a hasonló térbeli és spektrális jellemzők által (ESA_a).

A Sentinel-2 műholdak Föld körüli pályájának teljesítési idejét úgy határozták meg, hogy kombinálva maximalizálják a Landsat műholdakkal történő egymást követő megfigyeléseket (Li et al., 2017). A közepes térbeli felbontással rendelkező műholdak – mint a Landsat-8 és Landsat-9 vagy a Sentinel-2 műholdak – képesek idősoros adatokat szolgáltatni. Előbbieknek 16 nap, míg utóbbiaknak 5 nap a visszatérési idejük, vagyis az az időintervallum, amely alatt egy adott műhold egy meghatározott földrajzi pont felett ismét elhalad.

Hátrányuk azonban, hogy a műholdak nagyban korlátozottak adott magasságuk és pályájuk miatt, valamint nem minden esetben biztosítható a növényállomány fejlődésének monitorozásához szükséges térbeli, időbeli és spektrális felbontás (White et al., 2009; Ortiz et al., 2011). A műholdak általi megfigyelések adatminőségét nagyban korlátozzák az időjárási körülmények (felhős, esős és ködös időjárás), valamint a torzítások és zajok, amelyek szükségessé teszik a geometriai és radiometriai korrekciókat. Ezek különösen a nagyon párás, felhős és szmogos régiókban jelentenek nagy problémát. Előfordulhat, hogy a növények kulcsfontosságú növekedési szakaszainak számító egy-két hónapban egyetlen egy értékelhető műholdfelvétel sem készül (Ghafarian Malamiri et al., 2020; Chu et al.,

2021). Továbbá nem alkalmasak szántóföldön történő nemesítési vagy agronómiai kísérletek pontos, valós idejű monitorozására (Perry et al., 2014; Guo et al., 2016).

A műholdak alkalmazása mellett szól, hogy taposásmentesen lehet a növények egészségi állapotát optimális időjárási körülmények között a teljes vegetációs periódusuk során nyomon követni (Mahlein et al., 2010; Lu et al., 2015; Ramcharan et al., 2017). Használatukkal rengeteg időt lehet spórolni és olcsó megoldást jelentenek nagy területek vizsgálatánál. Az adatok könnyen elérhetőek és nem kell semmilyen kalibrációt vagy beállítást elvégezni a kalibrált adatok begyűjtéséhez (Li et al., 2022).

Az elmúlt években pedig egy új megközelítés tapasztalható a műholdas Föld-megfigyelés terén. A korábbi 2-5 műhold által gyűrűben, széles hullámhossztartományban történő megfigyelés helyett napjainkban már több száz nanoműholdat küldenek fel az űrbe, amelyek korlátozott hullámhossztartományban végeznek monitoring feladatokat (Houborg et al., 2016).

2.2.1.1. Sentinel -2

A Kopernikusz program (Európai Űrügynökség) keretein belül pályára állított Sentinel-2 műholdpárra (ESA_b) kutatói és gazdálkodói oldalról is egyre nagyobb figyelem hárul. A műholdpár napszinkron pályán kering, vagyis úgy határozták meg a pályahajlásukat és a pályamagasságukat, hogy egy adott hely felett mindig azonos helyi idő szerint repüljenek el.

A Sentinel-2A-t 2015-ben, a Sentinel-2B-t pedig 2017-ben állították működésbe (Li et al., 2017). Mindkét műhold multispektrális képalkotó

szenzorral (Multispectral Imaging Sensor – MSI) van felszerelve, amely 433 nm-től 2280 nm-ig képes képeket készíteni 13 különböző sávban (3. táblázat). Ezek a hullámhossztartományok alkalmasak a növényzet sűrűségének, a talajtakaró, fotoszintetikus aktivitás, aszályok, növényfiziológiai változások, felhőtakarók és a víztestek megfigyelésére (ESA, 2015).

3. táblázat: A Sentinel-2 műhold 13 sávjának hullámhossz közepe, sávszélessége és az egyes sávok felbontásának nagysága.

| Sávok | Hullámhossz közepe (nm) | Sávszélesség (nm) | Felbontás (m/px) |
|------------------------------------|-------------------------|-------------------|------------------|
| Sáv 1 (Aeroszol) | 443 | 20 | 60 |
| Sáv 2 (Kék) | 490 | 65 | 10 |
| Sáv 3 (Zöld) | 560 | 35 | 10 |
| Sáv 4 (Vörös) | 665 | 30 | 10 |
| Sáv 5 (Vörös él) | 705 | 15 | 20 |
| Sáv 6 (Vörös él) | 740 | 15 | 20 |
| Sáv 7 (Vörös él) | 783 | 20 | 20 |
| Sáv 8 (Közeli infravörös) | 842 | 115 | 10 |
| Sáv 8a (Keskeny közeli infravörös) | 865 | 20 | 20 |
| Sáv 9 (Vízpára) | 945 | 20 | 60 |
| Sáv 10 (Rövidhullámú infravörös) | 1375 | 30 | 60 |
| Sáv 11 (Rövidhullámú infravörös) | 1610 | 90 | 20 |
| Sáv 12 (Rövidhullámú infravörös) | 2190 | 180 | 20 |

A vörös (665 nm) és a közeli infravörös (842 nm) hullámhossztartományokat gyakran használják mezőgazdasági célokra. A két spektrum használatával lehetőség nyílik több vegetációs index készítésére is tíz méteres térbeli felbontásban (Domínguez et al., 2017; Sozzi et al., 2020).

Bollas et al. (2021) kutatásukban a Sentinel-2 műhold és egy Parrot Sequoia Plus multispektrális kamera által szolgáltatott NDVI értékek alapján hasonlították össze a két eszközt. Vizsgálatuk során egymáshoz hasonló trendeket figyeltek meg a két szenzor mérési eredményeinél, és erős korrelációt ($r = 83,5 - 98,26$) állapítottak meg.

Pellegrini et al. (2020) a fotoszintetikusan aktív sugárzás (Photosynthetically Active Radiation – PAR) elnyelődését vizsgálták őszi búzában a Sentinel-2 és a MODIS műhold, valamint egy kézi GreenSeeker adataiból kalkulált NDVI értékek által. A regressziós modellel végzett számítások erős összefüggésekre mutattak rá a Sentinel-2 műhold ($r^2 = 0,89$) és a GreenSeeker ($r^2 = 0,88$) adataiból számított NDVI és PAR értékek között. Amikor a Sentinel-2 térbeli felbontását 10 méterről 250 méterre (a MODIS felbontására) csökkentették, akkor az nem volt hatással a PAR és az NDVI közötti kapcsolatra ($p > 0,05$), azonban a determinációs együttható 0,89-ről 0,92-re emelkedett. Ezt támasztja alá Dela Nave et al. (2022) silócirokban végzett kutatómunkája is, ahol a Sentinel-2 műholdfelvételekből és a GreenSeeker optikai érzékelő adataiból számított NDVI értékek és az PAR kapcsolatát elemezték. Eredményeik rámutattak, hogy az NDVI szezonális dinamikája pontosan ($r^2 = 0,92$) reprezentálta az PAR értékeket.

Norvégiában növényi stresszt vizsgáltak különböző RGB indexek, valamint a Sentinel-2 és a GreenSeeker adataiból kinyerhető NDVI értékek által (Ritz et al., 2020). Kutatómunkájuk rávilágított, hogy az RGB indexekkel jól reprezentálható a növényi stressz és erősen korrelálnak az NDVI értékekkel ($r = 0,75$, $p < 0,001$).

Swoish et al. (2022) az USA-ban változatos fajösszetételű takarónövények biomasszáját becsülték meg nyolc vegetációs index, köztük az NDVI bevonásával a Landsat-8 (30 m felbontás), a Sentinel-2 (20 m) és a Plantscope (3 m) műholdképek alapján. Kutatásukban a térbeli felbontás és a műholdak visszatérési idejének hatását vizsgálták a biomassza becslésének pontosítása céljából. Tanulmányukból tudjuk, hogy a PlanetScope volt az egyetlen műhold, amely minden helyszínhez értékelhető felvételt biztosított a nagyobb visszatérési idejének köszönhetően. Azonban a nagyobb térbeli felbontás összességében nem eredményezett nagyobb pontosságot a többi műhold adataihoz képest. Az NDVI értékek és a takarónövények biomasszájának (kg / ha) kapcsolatánál $p < 0,0001$ szignifikanciaszinten a Sentinel-2 műhold érte el a legjobb eredményeket ($r^2 = 0,71$; RMSE = 534 kg / ha). Utána a Landsat-8 ($r^2 = 0,66$; RMSE = 590 kg / ha) és a PlantScope ($r^2 = 0,58$; RMSE = 677 kg / ha) következett.

Egy másik tanulmányban (Farbo et al., 2024) mesterséges neurális háló (Artificial Neural Network – ANN) modellt alkalmaztak, ahol az NDVI-t, a Normalizált Differenciált Vízindexet (NDWI), hőmérséklet és csapadék adatokat használtak fel előrejelzési változóként. Céljuk a jövőbeli NDVI értékek rövid- és középtávú előrejelzése volt. Eredményeik azt mutatták, hogy a jövőbeli NDVI értékek előre jelzése meglehetősen pontos. Három előrejelzési időpontot figyelembe véve (5, 10 és 15 nap) az RMSE értékek rendre 0,028, 0,038 és 0,050 voltak. Vizsgálataik során megfigyelték, hogy az idő előrehaladtával az NDVI értékek becslése egyre pontatlanabb lesz. Azonban Borgogno-Mondino et al. (2016) kutatásukban felhívták a figyelmet, hogy a műholdas adatokból számított NDVI értékek 0,01 és 0,07 között változhatnak.

2.2.2. Pilóta nélküli légi járművekkel megvalósuló adatgyűjtés

A pilóta nélküli légi járműveket (Uncrewed Aerial Vehicle korábbi nevén Unmanned Aerial Vehicle – UAV) vagy másnéven a pilóta nélküli légi jármű rendszereket (Unmanned Aircraft System – UAS) a köznapis szóhasználatban csak „drónoknak” nevezzük. A pilóta nélküli légi járműveknél bekövetkezett, illetve jelenleg is tapasztalt robbanászerű fejlődés, egyre népszerűbbé teszi ezen eszközöket a kutatási és kereskedelmi szegmensekben (Colomina et al., 2014).

Az UAV-k számos szempont szerint csoportosíthatók. Mezőgazdasági alkalmazásukat tekintve két (monitoring és permetező drónok) osztályba sorolhatók. A monitoring és permetező drónokon belül már rengeteg további dróntípus közül lehet választani (Duan et al., 2017; Shahi et al., 2023). A hagyományos légi vagy műholdas platformokkal összevetve, az UAS-k számos előnnyel rendelkeznek. Egyike, hogy csekély ráfordítás mellett, alacsony magasságokból ultranagy térbeli felbontásban készíthetők a legkülönbözőbb területekről felvételek a felhasználók által kívánt időbeli léptékben (Ambrosia et al., 2003; Berni et al., 2009; Yuan et al., 2015; Dall’Asta et al., 2017). Ráadásul az UAV-kra különböző szenzorok (pl. digitális kamera vagy multispektrális, hiperspektrális, termál és LiDAR érzékelők) szerelhetők fel. Ennek köszönhetően széles körben alkalmazhatók mind a magán, mind az állami szektorban (Grenzdorffer et al., 2008; Toth et al., 2016; Aasen et al., 2018; Liu et al., 2018; Webster et al., 2018).

További előnye a drónoknak a műholdakkal szemben, hogy sokkal pontosabban nyomon követhető a különböző kultúrák, illetve kultúrnövények fejlődése, különös tekintettel a térbeli felbontás és

időbeli felhasználhatóság vonatkozásában. Elmondható, hogy a távérzékelés fogalomkörébe tartozó eszközök közül az UAV-eket emelhetjük ki, mint a legfontosabb távérzékelési technológiák a mezőgazdaság perspektívájából. Rugalmasságuknak és sokrétű felhasználásuknak köszönhetően egyaránt segítik a tudományos kutatások előrehaladását, valamint a gyakorlati, precíz gazdálkodást (De Rango et al., 2017; Khot et al., 2016; Rasmussen et al., 2016).

Napjainkban a növénymonitoring célú kutatásoknál kevesen használnak merevszárnyú drónokat. A merevszárnyú eszközökkel ellentétben a többrotoros UAV-k jóval stabilabbak és könnyebben irányíthatók, továbbá alacsony magasságban repülnek, valamint kevés probléma adódhat a fel- vagy leszállás során (Canicatti et al., 2024). Azonban hátrányaik közé sorolható az alacsony sebességük és teherbírásuk, korlátozott repülési idejük és hatótávolságuk, illetve széles időjárásnál kevésbé stabilak (Hafeez et al., 2023). Továbbá mivel bárki számára könnyen elérhető és megvásárolható ezen eszközök, repülésbiztonsági szempontból is kockázatosabb a drónokkal történő adatgyűjtés, mint a műholdak vagy földközeli szenzorok által (Gajdács et al., 2021).

Az UAV-k működtetése technikai tudást is igényel. A repülést végző személyeknek jártasnak kell lenniük a drónok irányításában (Rose et al., 2016), mivel a felhasználónak végre kell hajtaniuk minden egyes lépést a sikeres felvételezés érdekében. A lépések általában a repülési terv elkészítéséből, a repülés végrehajtásából, a képek begyűjtéséből, valamint az adatok későbbi tárolásából és feldolgozásából állnak (Li et al., 2022).

Az UAV-kal történő mezőgazdasági célú adatgyűjtéshez pedig általában RGB vagy multispektrális kamerákat alkalmaznak (Neale et al., 2003; Choudhary et al., 2021; Wilke et al., 2021; Walsh et al., 2023).

2.2.2.1. Multispektrális szenzorokkal történő vizsgálatok

Az UAV-kre szerelt multispektrális érzékelők mezőgazdaságban történő monitoring célú használata ugrásszerűen megnőtt az elmúlt évtizedben a kutatók és a gazdálkodók körében. Ezen eszközök nagy előnye, hogy mobilisak, rugalmasan lehet őket alkalmazni, valamint nagy térbeli és időbeli felbontás is garantálható a vegetáció vizsgálata során (Stagakis et al., 2012; Jin et al., 2017).

A multispektrális szenzorok által készített felvételek az RGB kamerákkal ellentétben, nem korlátozódnak csak a látható fénytartományra, hanem a közeli infravörös tartományban is gyűjtnek adatokat (Bi et al., 2019). Ennek folytán a multispektrális képekből gyorsan és nagy mennyiségben lehet, akár nagyobb területekről is különböző vegetációs indexek által információkat kinyerni. Ezt támasztja alá Qi et al. (2021) kutatása is, akik két fajta földimogyoró klorofill tartalmát vizsgálták nyolc vegetációs index (NDVI, GNDVI, DVI, LCI, MCARI, NDRE, RVI, SIPI2) elemzésével. A regressziós modell eredményei alapján az NDVI és a GNDVI (Green Normalized Difference Vegetation Index) értékek sokkal erősebb kapcsolatot ($r^2 = 0,89$ és $0,86$) mutattak a földimogyoró leveleinek klorofill tartalmával, mint a többi index ($r^2 = 0,80 - 0,12$) esetében.

Mezőgazdasági célú felvételek készítésénél rendkívül népszerűek a Parrot Sequoia, a MicaSense RedEdge-M és a DJI Phantom 4

multispektrális drónra szerelt kamerák. A RedEdge-M kamera egy jó választás azon kutatóknak, akik megbízható adatokat szeretnének gyűjteni a különböző növényi jellegzetességekről, amit már számos kutatás is bizonyított (Shafiee et al., 2021; Veverka et al., 2021; Zsebő et al., 2024).

Jellemzően a szántóföldi megfigyeléseknél öt vagy hatszernás multispektrális kamerákat alkalmaznak. Több multispektrális kamerához – például az imént taglalt Parrot Sequoia, MicaSense RedEdge és RedEdge-M kamerákhoz is – fényérzékelő eszközök tartoznak, amelyek a fény visszaverődését és a beeső napsugárzást is képesek rögzíteni. Az így begyűjtött adatok pedig a képek kalibrálása során kerülnek felhasználásra, ugyanis a fényviszonyok változása befolyásolja a felvételek adattartalmát is (Assmann et al., 2018).

Számos tanulmány részletezte ezen szenzorok alkalmazásának előnyeit korai vízstressz (Zhang et al., 2019), nitrogénkoncentráció (Shendryk et al., 2020), növényi betegségek (Neupane et al., 2021) vagy várható hozamok meghatározásánál (Hassan et al., 2019).

Walsh et al. (2018) egy 5 sávú MicaSense RedEdge kamera használata során erős összefüggéseket ($r^2 = 0,77 - 0,86$) állapítottak meg a vörös él (vörös váll) alapú vegetációs indexek és a búza nitrogénkoncentrációja (RMSE = 0,06 - 0,13 %) között. Zabala (2017) a Sentinel-2 műhold látható (VIS) és közeli-infravörös (NIR) hullámhossztartományban begyűjtött adataiból különböző indexeket kalkulált ki és összehasonlította egy MicaSense RedEdge típusú multispektrális kamera adataiból számított indexekkel. Kutatásában rámutatott, hogy mindkét szenzor esetében jó korreláció ($r = 0,71 - 0,99$) figyelhető meg a kalkulált vegetációs indexek (NDVI, GCC, EVI) tekintetében. A

Pearson-féle korreláció alapján a márciusi időpontban érte el a legkimagaslóbb eredményeket ($r = 0,96 - 0,99$) $p < 0,001$ szignifikanciaszinten.

Dimiyati et al. (2023) négy különböző multispektrális kamerával vizsgálták eltérő fenológiai fázisokban a rizsföldeket. A begyűjtött adatokat az NDVI és öt másik vegetációs index (BNDVI, GNDVI, VARI, NDRE és MCARI) alapján hasonlították össze. Vizsgálataik során mindhárom fejlődési stádiumban a MicaSense kamera adataiból kalkulált NDVI értékek voltak a legmagasabbak. Több rizsföldön és búzában végzett kutatómunka (Duan et al., 2017; Naser et al., 2020; Nakano et al., 2023) erősítette meg, hogy a MicaSense kamera adataiból kalkulált NDVI értékek megközelítőleg 0,2-vel magasabb értéket mutatnak, mint a GreenSeekerrel mért NDVI értékek.

Azonban egy kamera hiperérzékenysége hátrányt jelenthet olyan esetekben, amikor egy növény túl nagy biomaszátömeeggel rendelkezik. Ugyanis a multispektrális kamera adataiból kalkulált NDVI értékek egy bizonyos idő elteltével már nem tudják lekövetni a biomaszátömeg változását, ezért telítetté válnak (Goffart et al., 2022). Deng et al. (2018) kisparcellás kutatásukban egy Mini-MCA6 és egy napszenzorral ellátott Sequoia típusú kamerát hasonlítottak össze kukoricában. A kísérletben különböző nitrogénszinteket állítottak be. A kamerákat hat különböző reflektancia panel (4,5 %, 20 %, 30 %, 40 %, 60 % és 65 %) spektrális visszaverődése és az NDVI alapján hasonlították össze. A keskenysávú Mini-MCA6 kamera pontosabb reflektanciaértékeket mutatott, mint a szélessávú Sequoia kamera. Azonban csak abban az esetben, ha a megfelelő kalibrációs módszert alkalmazták, különösen a látható fénytartományban. Viszont a

reNDVI-nál (rededgeNDVI) a Sequoia kamera ($r^2 = 0,91$) determinációs együtthatója jóval magasabb volt, mint a Mini-MCA6 ($r^2 = 0,48$) kameráé.

Más kutatók jelentősen javítani tudták hozampredikációs modelljüket a multispektrális kamerák adatai mellé bevont egyéb paraméterekkel. Liu et al. (2024) a búza magassági adataival egészítették ki a multispektrális felvételekből kinyert adatokat, míg Khodjaev et al. (2024) különböző vegetációs indexeket, napsugárzási és növény magassági adatokat integráltak a modellbe.

2.3. Földközeli szenzorok használata az agráriumban

A kutatók és gazdálkodók a műholdakra, illetve drónokra szerelt érzékelők mellett földi mérőeszközökkel is végeznek vizsgálatokat. A várható hozamok előrejelzésére, a növényállomány fejlődésének, zöldtömegének mérésére vagy a tápanyag-ellátottság megállapítására több kézi eszköz (Crop Circle, PlantPen, GreenSeeker) is a rendelkezésükre áll. Azonban az egyik leggyakrabban alkalmazott hordozható kézi optikai érzékelő a GreenSeeker, amellyel vizsgálható a növények nitrogén hasznosulása, indirekt módon meghatározható vele a differenciáltan kijuttatandó nitrogénműtrágya mennyisége, valamint megbecsülhető a várható terméseredmények (Ali et al., 2020). A korábbiakban bemutatott távérzékelési eszközökkel szemben a GreenSeeker egy viszonylag olcsóbb aktív érzékelő, amely a mérések során saját fényt bocsájt ki, így nem szükséges külső energiaforrásnak (Nap) világítania, hogy méréseket lehessen vele végrehajtani (Solari et al., 2008). A GreenSeeker a vörös (660 nm) és a NIR (780 nm)

hullámhossz reflektanciájából számítja ki az NDVI értéket (Saberioon et al., 2014).

Naser et al. (2020) arra a következtetésre jutottak, hogy talajközeli szenzorokkal – amelyek 2 méternél közelebb helyezkednek el a vizsgált célfelülethez (pl. talajhoz vagy levélzethez) (Viscarra Rossel et al., 2011) – a kisebb mezőgazdasági parcellákon jobb rendszeres monitoring feladatokat végezni különböző őszi búza fajták hozamának meghatározása céljából.

Több kísérletet végeztek GreenSeeker segítségével nitrogén műtrágya kijuttatásával kapcsolatban is, ahol erős korrelációt ($r \geq 0,75$) figyeltek meg a nitrogén és NDVI értékek között (Tubaña et al., 2008; Lie et al., 2009; Arnall et al., 2016; Franzen et al., 2016).


Azonban a kísérletekben bemutatott GreenSeeker hátrányai közé sorolható, hogy mind térben, mind időben korlátozott vele a mérés, valamint az adatgyűjtés során szubjektív mérési vagy az eszközt zavaró torzítás is felléphet (Schirrmann et al., 2016). Továbbá a lassú és munkaigényes adatgyűjtés miatt nem lehetséges közepes vagy nagy kiterjedésű növényállomány NDVI értékeinek a változását nyomon követni (Kumhálová et al., 2014).

2.4. Vegetációs indexek alkalmazása a mezőgazdaságban

Az elmúlt 30 évben a vegetációs indexeket széles körben használják a növényállomány lombzatának és növekedésének megfigyelésére. A vegetációs indexek ismerete alapvető fontosságú a mezőgazdasági ökoszisztémák megértéséhez, mivel jelzik az aktuálisan termesztett növények egészségi állapotát és kondícióját. Minden egyes index az

elektromágneses spektrumok más-más hullámhosszából kalkulálható ki, emiatt pedig eltérő információértékkel is bír (Wang et al., 2010).

A növényekről eltérő mértékben verődik vissza a kék, a zöld, a vörös és a közeli infravörös (NIR) hullámhossztartományokban (4. ábra) a fény. Egészséges növényállomány esetében a zöld és a NIR tartományban visszaverődik, míg a vörös és kék hullámhossztartományban elnyelődik a fény (Inman et al., 2005).



4. ábra: A különböző spektrumokban történő fényvisszaverődés az elhalt, stresszt elszenvedő és az egészséges levél esetében (URL²)

Duan et al. (2019) rengeteg információt gyűjtöttek a rizs fejlődéséről a vegetációs indexek és a spektrális jellemzők által. A vegetációs indexek

és a levélzet különböző tulajdonságai közötti korreláció is nagyban függ a vizsgált növény jellemzőitől.

Eltérő nitrogéndózisú kisparcellás kísérletekben vizsgálták a levélklorofil-tartalom indexet (Canopy Chlorophyll Content Index – CCCI) angolperjében (*Lolium perenne* L.). Eredményeik alapján a CCCI erősebb kapcsolatot mutatott a biomasszával ($r^2 = 0,37$), mint a levelek nitrogéntartalmával ($r^2 = 0,13$) (Patel et al., 2021). A különböző indexek kalkulálásakor azt is figyelembe kell venni, hogy a vegetációs indexek értékei változhatnak a napfény beesési szögének változásával (Valencia-Ortiz et al., 2021).

2.4.1. Normalizált Vegetációs Index

Az egyik legnépszerűbb kutatási és mezőgazdasági célokra alkalmazott index a Normalizált Vegetációs Index (Normalized Difference Vegetation Index – NDVI) (Raun et al., 2005; Dellinger et al., 2008; Holland et al., 2012), amely megalkotásáig 1973-ig kell visszamenni az időben (Rouse et al., 1973). Az NDVI egy dimenziómentes mérőszám, ami egy adott területen található növényzet vegetációs aktivitását fejezi ki a következő képlet (1) alapján (Rouse et al., 1973; Tucker, 1979):

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (1)$$

Az NDVI értékek a műholdak (Lopresti et al., 2015), a drónokra szerelt kamerák és a földközeli szenzorok adataiból is kiszámolható (Inman et al., 2008; Lopes et al., 2012). Az egyik legnagyobb előnye ennek az indexnek, hogy könnyen kinyerhető és értelmezhető, mivel a kapott

értéknek minden esetben -1 és 1 közé kell esnie. A -1 felé közeledő értékek a vizet jelölik, míg a -0,1 és 0,1 közötti értékek a kopár területeket, homokot vagy havat jelentik. A 0,1-nél magasabb és a 0,25-nél alacsonyabb értékek az elhalt növényi maradványokkal borított talajokat mutatja meg. Az alacsonyabb pozitív értékek (körülbelül a 0,2-0,4 közötti értékek) a füves, cserjés területeket, míg a magasabbak értékek a sűrűbb növényzetet ábrázolja. Végül az 1-hez közeli NDVI értékek a teljesen fejlett növényállományt vagy a trópusi esőerdőket jelöli (Heege et al., 2013; Domínguez et al., 2015).

Azonban nem csak a növények zöldtömegének mennyiségi változása követhető nyomon ezzel az indexel, ugyanis az NDVI értékek pozitív kapcsolatot mutattak a nitrogén ($r = 0,52$) $p \leq 0,01$ szignifikanciaszinten (Sumfleth et al., 2008), a pH ($r^2 = 0,63$) és a szerves szén ($r^2 = 0,86$) változásával is (Kumar et al., 2016a).

A világon először a Landsat műhold adatait felhasználva kísérelték meg a gabonák hozamát megbecsülni az NDVI értékek alapján (Tucker et al., 1980; Aase et al., 1981).

Az idősoros műholdas adatokból számított NDVI értékek nyomon követésével közel valós idejű információ nyerhető ki a növényállomány fejlődéséről (Zhou et al., 2018; Li et al., 2019; Yue et al., 2023), fenológiai állapotáról (Bouchet et al., 2016; Gim et al., 2020), valamint a várható terméshozamáról (Nagy et al., 2018; Maresma et al., 2020). Ezen tényeket erősítik Raun et al. (2001), Solie et al. (2012) és Miller et al. (2021) kutatásaikban.

Az NDVI értékekből következtetni lehet a növények klorofill tartalmára is (Kizilgeci et al., 2021). Az NDVI-ből származtatott levélterület indexet (Leaf Area Index – LAI) és a növények

biomasszatömegének változását (Rouse et al., 1974) széles körben használják a vegetáció növekedésének megfigyelésére. Ez az indexszám érzékeny a növényi zöldtömeg-változásra (Ma et al., 2001; Marti et al., 2007; Inman et al., 2008), illetve a búzában kialakuló foltos tüneteket okozó betegségek vizuális értékelését is helyettesíteni lehet vele (Kumar et al., 2016_b). Azonban Sellers (1985), Gitelson et al. (2002), Cao et al. (2016) és Goffart et al. (2022) kutatásaikban felhívták a figyelmet, hogy közepes és magas biomasszatömegnél az NDVI értékek könnyen telítetté válhatnak.

Az adatgyűjtésnél használt szenzorok térbeli felbontása általában eltérő. Ez pedig nagyban befolyásolhatja a kapott NDVI vagy a talaj reflektanciájából származó értékeket. Egy földközeli aktív optikai érzékelővel történő mérés során 0,5 m²-nél kisebb terület vizsgálható meg (Inman et al., 2005), míg egy műhold passzív érzékelője 1 és 60 méter közötti felbontásban készít felvételeket (Benincasa et al., 2018; Yu et al., 2021). A drónokra szerelt multispektrális kamerák felbontása a repülés magasságától és az adott kamera típusától függően változhat, például 1,29 és 11,00 cm / pixel nagyság között, ha 30 m, illetve 120 m magasságban történik a repülés (Miller et al., 2021).

Ugyanakkor Duan et al. (2017) tanulmányából tudjuk, hogy 30 és 50 méteres repülési magasság között a MicaSense RedEdge kamera adataiból számított NDVI értékek erősen korreláltak a GreenSeeker NDVI értékeivel a búza normál ($r^2 = 0,85$) és kései ($r^2 = 0,84$) vetésénél is. Amikor viszont magasabbra repültek a drónnal, már csökkent a korreláció erőssége. Ennek eredményeként a földi, földközeli NDVI mérések objektívebb adatokkal szolgálnak a növényi stressz

kimutatására (Lopes et al., 2012) vagy a növények fejlődése során fellépő nitrogénszükséglet meghatározásához (Raun et al., 2002).

Egyes kutatások szerint az NDVI értékekből következtetni lehet még a kultúrnövény nitrogéntartalmára és nitrogénhasznosítására (Erdle et al., 2011; Samborski et al., 2015; Foster et al., 2016).

A távérzékelési eszközök mezőgazdaságban történő szélesebb körű alkalmazását követően elkezdték a passzív multispektrális szenzorokat vizsgálni a változó dózisú nitrogén (Variable Rate Nitrogen – VRN) kijuttatásnál is (Benincasa et al., 2018; Walsh et al., 2018; Sozzi et al., 2021; Heinemann et al., 2022). A drónok és a műholdak adataiból kapott NDVI értékek pedig behelyettesíthetők a VRN modellekbe. Azonban kiemelt figyelmet kell fordítani, hogy a mért értékek folyamatosan változhatnak, mivel a passzív érzékelőknek napfényre van szükségük és a napsugarak beesési szögének változásával az NDVI értékek is egy adott időn belül kis mértékben eltérhetnek egymástól (Holland et al., 2012; Winterhalter et al., 2013).

Az imént felsorolt kutatásokból jól kivehető, hogy az NDVI szoros kapcsolatban van a növények fiziológiai tulajdonságaival és értékük sok egyéb tényezőt is megmagyarázhat pl. talajnedvesség, nitrogéntartalom vagy különböző fenológiai változások (Marti et al., 2007; Edwards et al., 2015; Foster et al., 2016). Következésképpen az NDVI használatakor a kutatóknak meg kell bizonyosodniuk arról, hogy a kísérletek során mely tényezőket szeretnék a leginkább reprezentálni.

2.5. Különböző kultúrákban végzett hozambecslések

A gazdálkodás hatékonyságának növelése érdekében és a napjainkban tapasztalt egyre szélsőségesebb időjárási körülmények miatt a

különböző kultúrák terméshozamának pontos meghatározása egyre fontosabbá válik. A legelterjedtebb termésbecslési módszer a szántóföldi becslés (Huddleston, 1978; Overton, 1979). Ennél a módszernél egy adott terület meghatározott pontjairól betakarított és lemért hozamok alapján következtetünk a teljes terület várható hozamára. Ebből adódóan a szántóföldi becslések megvalósítása rendkívül egyszerű, ugyanakkor sok időt vesznek igénybe és kevésbé hatékonyak (Reynolds et al., 2000). Éppen ezért egy gyors, hatékony és roncsolásmentes termésbecslés kialakítására van szükség.

Ezen kihívásokra jelenthetnek megoldást a különböző távérzékelési eszközre szerelt kamerák (Li et al., 2020; Yang et al., 2022). A távérzékelési eszközök kameráiból kinyert adatokat a környezeti paraméterekkel is ki lehet egészíteni (Meng et al., 2021; Zhou et al., 2022) vagy egy növényfejlődési szimulációs modellt (Li et al., 2009) kialakítani, amellyel nyomon követhető a növények fejlődése és a várható terméseredmények.

A hozambecslésben rejlő lehetőséget bizonyítja, hogy már számos kutató és kutatás foglalkozott ezzel a témakörrel, mind szántóföldi, mind kertészeti körülmények között. Hozambecslési vizsgálatokat végeztek búzában (*Triticum aestivum* L.) (Liaqat et al., 2017; Segarra et al., 2020) árpában (*Hordeum vulgare* L.) (Johnson et al., 2016), kukoricában (*Zea mays* L.) (Zhang et al., 2020; Yang et al., 2021), rizsben (*Oryza sativa* L.) (Wan et al., 2020; Franch et al., 2021), burgonyában (*Solanum tuberosum* L.) (Fortin et al., 2011; Li et al., 2020), gyapotban (*Gossypium* L.) (Ashapure et al., 2020; Feng et al., 2020), káposztában (Ji et al., 2017) mangó ültetvényben (Gutiérrez et al., 2019) vagy cukornád ültetvényben (Sumesh et al., 2021).

Az említett kutatások döntő többségében távérzékelési eszközre (műhold vagy UAV) szerelt szenzorok adataira támaszkodtak a kutatók. Mivel a növények és a környezeti tényezők folyamatos változáson mennek keresztül, ezért a kultúrnövény fejlődésének nyomon követése érdekében idősoros méréseket kell végezni a vegetációs periódus végéig. Ez egyben a hozampredikció pontosságát is javítja. Hosszútávú idősoros felvételek készíthetők a műholdak (Atzberger et al., 2011; Rembold et al., 2013) vagy a pilóta nélküli légitársulatok által (Gonzalez-Dugo et al., 2015; Gabriel et al., 2017). Azonban Ogaya és Peñuelas (2003) tanulmányából tudjuk, hogy a vegetáció spektrális visszatükröződése függ a levelek sejtszerkezetétől és felszínétől, valamint a fotoszintetikus pigmentek és egyéb biokémiai összetevők koncentrációjától, illetve eloszlásától. Továbbá az UAV-k és a kézi érzékelők használatakor jelentkező hozamelőrejelzési különbségek a szenzorok hullámhosszainak (sávszélességeinek) eltéréseiből is adódhatnak.

2.5.1. Hozambecslés multispektrális UAV-felvételek alapján

Az UAV-alapú felvételezések remek lehetőséget kínálnak a gyors és pontos hozambecslésekhez (Shi et al., 2022; Feng et al., 2023; Kumar et al., 2023).

Shi et al. (2022) gyapotban egy DJI M300 drónra szerelt MicaSense Altum kamerával végeztek vizsgálatokat. Kísérletükben öt hozambecslési modellt – lineáris regressziót (Linear Regression – LR), támaszvektor regressziót (Support Vector Regression – SVR), osztályozási és regressziós fákat (Classification and Regression Trees – CART), véletlen erdőt (Random Forest – RF) és K-legközelebbi

Szomszéd eljárást (K-Nearest Neighbors – KNN) – alkalmaztak. Kutatómunkájuk során a hozambecslési eljárásnak az RF módszer bizonyult ($r^2 = 0,77$ és $RMSE = 7,5 \%$) a legjobbnak.

Kukoricában végeztek hasonló vizsgálatokat egy Parrot Sequoia multispektrális kamerával a vegetatív (V6) és a reprodukzív (R5) szakaszban. A kísérleti területek négyféle agronómiai kezelést kaptak. A begyűjtött adatokból 26 vegetációs indexet készítettek és öt különböző gépi tanulós modell (LR, KNN, RF, SVR és mély neurális hálózat (Deep Neural Network – DNN)) felhasználásával becsülték meg a várható hozamot. A 26 indexből a CARI (Chlorophyll Absorption Reflectance Index) és CVI (Chlorophyll Vegetation Index) indexek érték el a legerősebb korrelációt ($r = -0,87$ és $-0,69$) a hozammal (Kumar et al., 2023). Az USA-ban szintén kukoricában Oglesby et al. (2022), négy szenzor (atLEAF SPAD szenzor, GreenSeeker, Crop Circle, MicaSense-RedEdge) használatával becsülték meg a hozamot. Kutatásukban megállapították, hogy a MicaSense kamerával lehetett a legjobban megbecsülni a várható hozamot a címerhányás és az azt követő időszakban ($r^2 = 0,78-0,83$). A Crop Circle és SPAD ($r^2 = 0,57$ és $0,49$), valamint GreenSeeker ($r^2 = 0,52$) jóval alacsonyabb determinációs együtthatókat mutatott. Mind a négy elemzés $p \leq 0,001$ szignifikanciaszinten lett vizsgálva.

Zhou et al. (2017) drónra szerelt Mini-MCA6 típusú multispektrális kamerával idősoros adatgyűjtés végeztek, majd számos vegetációs indexek használatával becsülték meg a rizs hozamát. A legmagasabb korrelációs koefficiens ($r = 0,76$) a multilineáris regresszióval volt az NDVI értékek 800 nm és 720 nm-es hullámhosszával számolva. Miller et al. (2021) Parrot Sequoia multispektrális kamerát használtak három

éven keresztül a különböző tőszámú őszi búzák vizsgálatánál. Eredményeik alapján az őszi búza BBCH 21-45 közötti szakaszban $r = 0,54-0,59$ között korreláltak a kalkulált NDVI értékek a hozammal $p \leq 0,0001$ szignifikanciaszinten.

Kínában őszi búzáról készített multispektrális képek alapján gépi tanulós algoritmusok - (véletlen erdő (RF), K-Legközelebbi szomszédok (KNN), Bagging and Gradient Boosting Regression (GBR)) és egy mélytanulási algoritmus (1D konvolúciós neurális hálózat (1D-CNN)) - alkalmazásával vizsgálták a hozambecslés pontosságát. A felvételezéshez egy DJI M210 típusú drónra szerelt MicaSense kamerát használtak és három időpontban (kalászhányás, virágzás, szemképződés) készítettek felvételeket. A begyűjtött képekből pedig 16 vegetációs indexet készítettek. A gépi tanulós algoritmusok közül a konvolúciós neurális hálózati modell bizonyult a legpontosabbnak, amely $-0,1$ t/ha és $0,1$ t/ha között volt képes prediktálni a várható hozamot (Li et al., 2023).

Shafiee et al. (2021) tavaszi búzában végeztek hozambecslést egy Micasense-RedEdge-M kamerával Norvégiában. A felvételeket három időpontban készítették és két gépi tanulós módszert, illetve három vegetációs indexet (NDVI, EVI, MTCI) használtak fel kutatómunkájukban. Vizsgálataik során megállapították, hogy három időpontban (június 26., július 2., július 19.) az NDVI értékekkel lehetett a legjobban előre jelezni a várható hozamot ($r = 0,87; 0,88; 0,93$).

Hasonló kutatást végeztek Veverka et al. (2021), akik szintén tavaszi búza hozamát és fehérjetartalmát becsülték meg Észak-Dakotában két éves kutatómunkájuk során egy MicaSense kamera és egy kézi RapidScan CS-45 adataiból kalkulált r_{NDVI} ($_{\text{red}}\text{NDVI}$) és $_{\text{re}}\text{NDVI}$

($r_{\text{rededgeNDVI}}$) alapján. A két szenzor értékeinek összehasonlításánál a lineáris regresszió szignifikáns kapcsolatot mutatott ($p \leq 0,05$) az r_{NDVI} ($r^2 = 0,69$) és a r_{reNDVI} ($r^2 = 0,55$) esetében is. Azonban csak a második évben lehetett az r_{reNDVI} alkalmazásával mindkét szenzorról megbecsülni a várható hozamot (RapidScan $r^2 = 0,51$; MicaSense $r^2 = 0,63$), ugyanis az első évben valószínűleg a kedvezőtlen időjárási és környezeti tényezők miatt az r_{reNDVI} és a hozam közötti kapcsolat mindhárom mérési időpontban nagyon gyenge ($r^2 \leq 0,35$) volt. Valamint kizárólag az UAV passzív érzékelőjéből kalkulált r_{reNDVI} értékekkel tudták előre jelezni a fehérjetartalmat ($r^2 = 0,60$, RMSE = 14,8, $p \leq 0,02$).

Az NDVI értékek telítettsége búzában (Naser et al., 2020) jelentős kihívást okozhat az olyan kritikus periódusokban, mint a kalász kezdeti fejlődésének (BBCH-40) időszaka. E megfigyelések alapján a különböző vegetációs periódusokban történő egységes hozambecslés nem megvalósítható, ezért kiemelten fontos, hogy mindig a lehető legoptimálisabb időpontban becsüljük meg a várható hozamot. Korábbi tanulmányok pozitív korrelációt találtak a búza hozama és az NDVI értékek között a virágzás (BBCH 60-69) és a szemképződés (BBCH 70-79) időszakában (Pavuluri et al., 2014; Goodwin et al., 2018; Guan et al., 2019).

Az utóbbi időben egyre nagyobb érdeklődés tapasztalható a multimodális adatok gyűjtése iránt is, mivel ezen adatok hozampredikációs modellekbe történő integrálása kiegészítheti az egyes módszerek hiányosságait, amely következményeként nagymértékben javulhat a termésbecslés pontossága (Maimaitijiang et al., 2020; Fei et al., 2022; Sun et al., 2022).

2.5.2. Hozambecslés a GreenSeeker adatai alapján

Számos kutatásban és kultúrában vizsgálták a GreenSeeker aktív érzékelő NDVI értékei és a hozam közötti kapcsolatot. Ali et al. (2020) vizsgálataik során megfigyelték, hogy a GreenSeeker jobb információt szolgáltat a búza nitrogénfelvételéről ($r^2 = 0,65$) és a várható hozamáról ($r^2 = 0,59$) a szárbaindulás (BBCH 30) időszakában, mint az atLeaf kontakt szenzor (nitrogénfelvétel: $r^2 = 0,52$; hozam: $r^2 = 0,49$), amely a levelekre helyezve, csak egy pontról szolgáltat adatokat.

Duan et al. (2017) kutatásukban a búza hozama és az NDVI értékek közötti legerősebb kapcsolatot a virágzás körüli időszakban mérték. A vizsgálat során használt két érzékelő közül a GreenSeeker ($r^2 = 0,87$) NDVI értékei jobban illeszkedtek a terméseredményekhez, mint a MicaSense RedEdge kamera ($r^2 = 0,82$) adataiból kalkulált értékek. Továbbá azt is megállapították, hogy a repülési magasság növelése negatívan befolyásolja a hozamelőrejelzés pontosságát.

Más kutatók egy GreenSeeker és egy Parrot Sequoia kamera adataiból számított NDVI értékek alapján határozták meg a rizs hozamát. A két szenzor mérési eredményeinek összehasonlításakor erős kapcsolatot ($r = 0,79-0,96$) állapítottak meg $p \leq 0,001$ szignifikanciaszinten. A Pearson-féle korrelációs koefficiens alapján különböző nitrogéndózisok mellett a kalászhányás kezdete előtti három hétben a GreenSeekerrel ($r \geq 0,80$) hatékonyabban prediktálható $p \leq 0,001$ szignifikanciaszinten a várható hozam, mint a Sequoia kamera ($r = 0,25-0,75$) adataiból számított NDVI értékek alapján $p \leq 0,05$ szignifikanciaszinten (Nakano et al., 2023).

Ji et al. (2017) kísérletükben GreenSeekerrel két káposztafajtát, négy eltérő nitrogéndózissal, két évig vizsgáltak. A Pearson-féle korrelációs koefficiens tekintetében az ültetéstől számított 110. napon lehetett fajtától és évtől független a legjobban előre jelezni a várható hozamot ($r = 0,87 - 94$) $p \leq 0,01$ szignifikanciaszinten.

Nemcsak káposztában, hanem burgonyában is végeztek GreenSeekerrel hozambecslést Kenyában. A randomizált blokk elrendezésű kísérletben négy nitrogénszintet állítottak be és két éven keresztül vizsgálták a kultúrát. Kutatásukban rámutattak, hogy a gumónövekedési ($r = 0,33$) periódust leszámítva az NDVI értékek szignifikáns korrelációt mutattak a hozammal a vegetáció végén ($r = 0,81$) $p \leq 0,001$ szignifikanciaszinten, az érés ($r = 0,54$) és a gumóképződés ($r = 0,43$) időszakában $p \leq 0,05$ szignifikanciaszinten (Satognon et al., 2021).

Bu et al. (2017) kétéves kutatási eredményeik alapján a GreenSeekerrel sikeresen megbecsülték a cukorrépa ($r^2 = 0,65 - 67$), a tavaszi búza ($r^2 = 0,96$), a kukorica ($r^2 = 0,84$) és a napraforgó ($r^2 = 0,31$) hozamát $p < 0,001$ szignifikanciaszinten. A mérések alapját az NDVI értékek és vetéstől számított napi fejlődési hőmérsékleti összeg adatok képezték.

2.5.3. Hozambecslés az NDVI értékek és a környezeti paraméterek figyelembevételével

A különböző vegetációs indexek – pl. NDVI – kiszámítása lehetővé teszi a termés hozamok predikcióját (Raun et al., 2001; Harrel et al., 2011), azonban a kumulált napi fejlődési hőmérsékleti összeg (KNFHÖ) vagy a vetés utáni napok (VUN) figyelembevételével még pontosabb hozambecslés valósítható meg. Ennek oka, hogy az aktuális

termesztési szezon várható hozama kisebb-nagyobb mértékben eltérhet a végleges terméseredményektől a becslés időpontja és a betakarítás időszaka között kialakuló változó időjárási körülmények miatt (Raun et al., 2002).

Raun et al. (2001) kilenc kísérlet kétéves adatai alapján végeztek az NDVI érték alapján hozambecslést. A várható hozampredikációs modellbe a napi fejlődési hőmérsékleti összeget (NFHÖ) is beépítették. Az összes helyszín és a két éves adatok egyesítését követően a determinációs együttható 0,5 lett a becsült és a mért hozam között $p \geq 0,0001$ szignifikanciaszinten. Azonban amikor csak hat helyszínen alapján végeztek hozampredikációt, akkor az $r^2 = 0,83$ -ra emelkedett. Ezt a nagyobb differenciát azzal magyarázták, hogy három helyszínen a késő nyári esők miatt nem tudták optimális időben elvégezni a betakarítást, ezért megdőlt az állomány, sok mag kipergett a kalászból, ami magasabb hozamvesztést okozott. Hasonló eredményeket értek el kukoricában (Tagarakis et al., 2017_a), káposztában (Ji et al., 2017) és cukornádban (Lofton et al., 2012), amikor az NDVI értékeket KNFHÖ értékekkel korrigálták.

Azonban Teal et al. (2006) éppen ellentétes megállapításokról számoltak be az előbb említett vizsgálatokhoz képest, ugyanis sem növekedést, sem csökkenést nem tapasztaltak, amikor a VUN vagy a NFHÖ adatokkal korrigálták az NDVI-alapú modelljüket. Hasonló eredményekről számoltak be Ali et al. (2014) és Tagarakis et al. (2017_b) kutatásaikban, ugyanis sem a rizs, sem a cirok hozampredikációját nem sikerült a KNFHÖ értékek alkalmazásával fejleszteni.

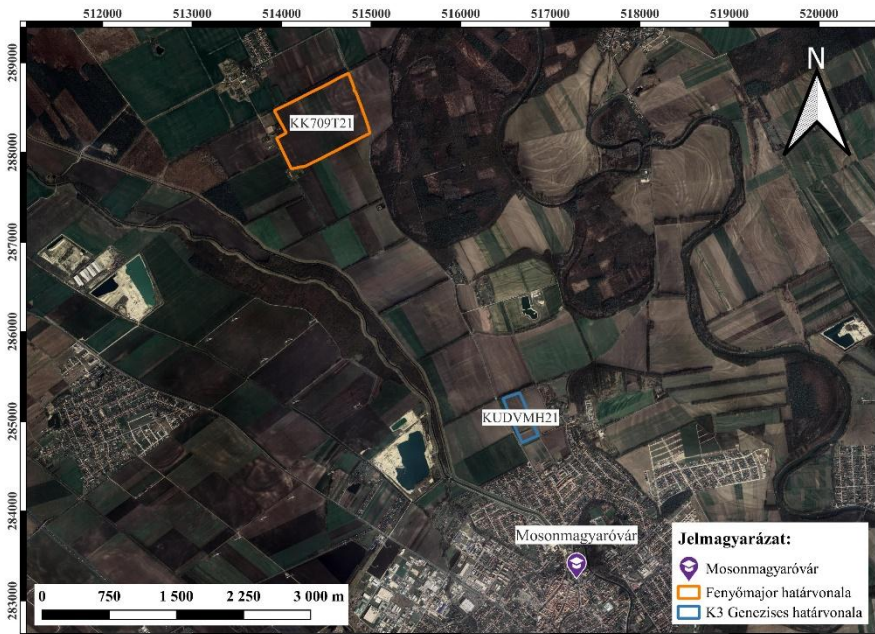
A VUN-kal korrigált NDVI értékek esetében kukoricánál (Tagarakis et al., 2017_a) 0,65-ről 0,75-re, a ciroknál (Tagarakis et al., 2017_b) 0,44-ről

0,67-re sikerült az r^2 -et megnövelni. Káposztánál (Ji et al., 2017) azonban nem sikerült a hozampredikációs eredményeken javítani a VUN bevonásával.

3. ANYAG ÉS MÓDSZER

3.1. Kísérleti területek földrajzi elhelyezkedése

A kutatási területek a Dunántúl északnyugati részén, a Kisalföld legmélyebb középtáján, a Győri medence északi sarkában, a Moson-sík kistájon elhelyezkedő, Győr-Moson-Sopron vármegyében található Mosonmagyaróvár település északi határában helyezkedik el (5. ábra). A kistáj területe 468 km² és teljes egészében magasártéri hordalékkúpsíkság. Az északnyugati részen 125-131 m, míg délkeleten 113-115 m között változik a tengerszint feletti magasság (Dövényi, 2010).



5. ábra: A kísérletekre kijelölt területek földrajzi elhelyezkedése és azok MePAR kódjai

3.1.1. Kutatási terület éghajlata

A Mosoni-sík mérsékelt hűvös, de száraz éghajlatú vidék. A 2001-2010 közötti periódusban az átlaghőmérséklet 10,8 °C, a napsütéses órák száma átlagosan 2051, a lehullott csapadékmennyiség pedig 583 mm volt. Ezzel szemben a 2011-2020 közötti időszakban már jóval magasabb (11,5 °C) átlaghőmérsékletet mértek a vizsgált időszakban, míg a napsütéses órák száma (1989) és a csapadékösszes (571 mm) is alacsonyabb értékeket mutatott az azt megelőző tíz évhez képest (Varga, 2021).

A térségben a mosonmagyaróvári (korábban óvári) meteorológiai állomásról származnak a leghosszabban folyamatos mért meteorológiai adatsorok. A meteorológiai adatokat Masch Antal kezdeményezésére kezdték el gyűjteni az 1840-es évektől, így számos mért paraméter már hosszú ideje a meteorológusok rendelkezésre áll (Tenk, 2017).

A kutatás helyszínéül kijelölt Fenyőmajori terület 4365 méter, míg a Genezises kísérlet 500 méter távolságra található légvonalban a mosonmagyaróvári mérőállomástól. Ez egyben az Országos Meteorológiai Szolgálat (OMSZ) állomását (6. ábra) képezi. A kutatásom során felhasznált meteorológiai adatok is erről a mérőállomásról származnak.




6. ábra: A mosonmagyaróvári Országos Meteorológiai Szolgálat (OMSZ) időjárás mérőállomása.

3.1.2. A kutatási területek éves meteorológiai adatai

Az OMSZ mérései alapján a 2019-2023 közötti (7. ábra) öt év átlaghőmérséklete $11,7^{\circ}\text{C}$, míg az átlag csapadékmennyiség $592,4\text{ mm}$ volt. Azonban a 7. ábra évenkénti átlaghőmérsékletének alaposabb tanulmányozása során negatívan kiugró érték figyelhető meg a 2021-es esztendő átlaghőmérsékletében ($10,9^{\circ}\text{C}$), amely egyben a vizsgált öt év leghidegebb esztendejét is jelentette. Ezt követően egy magasabb hőmérséklet-változás figyelhető meg a 2022-es (12°C) és 2023-as ($11,8^{\circ}\text{C}$) évben, amelyek között csak $0,2^{\circ}\text{C}$ -os éves átlaghőmérsékleti különbség állapítható meg.

Mint már korábban is említésre került, a 2019 és 2023 közötti periódus átlag csapadékmennyisége $592,4\text{ mm}$, amely meghaladja a Dövényi (2010) által meghatározott 560 mm körüli mennyiséget. Ennek ellenére


rendkívül szélsőséges csapadékeloszlás volt megfigyelhető (7. ábra) a kutatás ideje alatt, ugyanis öt év tekintetében a 2021-es volt a második legszárazabb (550 mm), míg a 2022-es a legszárazabb (513 mm) év. Ezzel szemben a 2023-as esztendőben 168 mm-rel több csapadék hullott (752 mm), mint a második legcsapadékosabb 2020-as évben (584 mm).



7. ábra: Évenkénti átlaghőmérséklet és csapadékmennyiség a 2019-2023 közötti időszakban.

A 8. ábra a vegetációs periódus átlaghőmérsékletét és csapadékmennyiségét ábrázolja a 2018 és 2023 közötti időszakban. Az év átlaghőmérséklete 8,9°C. A kutatásban vizsgált időszak, azonban a 2022-es és 2023-as vegetációs periódusra fókuszál, így azt elemezve megállapítható, hogy a 2022-es (8,9°C) és a 2023-as (9,0°C) fejlődési időszakok minimális mértékben tértek el egymástól az átlaghőmérséklet tekintetében.

Azonban a csapadékmennyiség terén már jóval alacsonyabb értékek állapíthatók meg a 2021-22-es (349 mm) termelési ciklusban. Ellenben a rá következő 2022-23-as időszakban már 428 mm csapadék hullott. Antal et al., (1992) vízigénnyel kapcsolatos megállapítása alapján tehát a 2022-23-as időszak sokkal optimálisabb volt őszi búza termesztésére, mint a 2021-22-es periódus. Ezt támasztja alá Xia et al. (2005) kutatása is, melyben megállapítja, hogy október közepétől június közepéig az őszi búza evapotranszpirációja a 400-500 mm-t is elérheti. Azonban Farkas et al. (2020) eredményei alapján a különböző magyar őszi búza fajták vízhasznosításának hatékonysága is eltér egymástól.

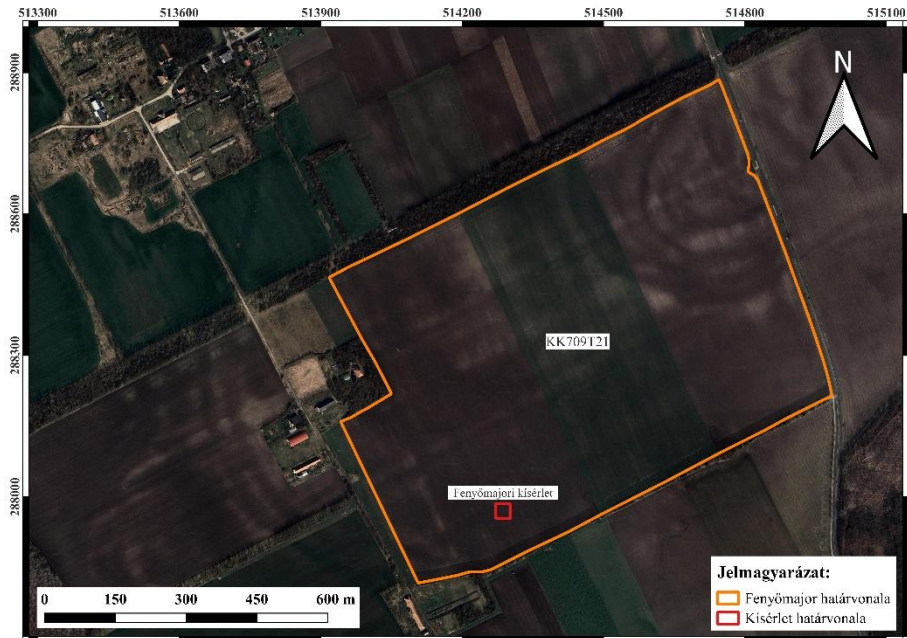


8. ábra: Vegetációs időszakok (október - június) átlaghőmérséklete és csapadékmennyisége a 2018-2023 közötti időszakban.

3.2. Kísérleti helyszínek

A vizsgálatok helyszínéül a Széchenyi István Egyetemhez tartozó Uni-Agro-Food Kft. kezelésében lévő Fenyőmajor (MePAR kód: KK709T21) és K3 Genezises (MePAR kód: KUDVMH21) nevű táblák (9-10. ábra) szolgáltak, amelyből az előbbi a 0403/2-es, míg utóbbi a 0451 helyrajzi számon található.

A Fenyőmajori tábla (9. ábra) 69,11 hektár nagyságú, míg a K3 Genezises (10. ábra) 10,61 hektár, azonban a kísérletek egy jóval kisebb területen (9-10. ábra) lettek kialakítva.



9. ábra: A Fenyőmajori tábla elhelyezkedése, pirossal jelölve rajta a kísérleti terület.



10. ábra: A K3 Genézises tábla elhelyezkedése, pirossal jelölve rajta a kísérleti terület.

3.2.1. Fenyőmajori kísérlet

A Fenyőmajori tábla összterülete 69,11 hektár, azonban egy jóval kisebb, 30 × 30 méteres rész lett kijelölve a Sentinel-2 műhold haladási irányának és pixelméreteinek megfelelően. Ezen a táblán csak a 2023-as évben végeztem méréseket, amikor a termesztett kultúra őszi búza (*Triticum aestivum* L.) volt. Az őszi búza előveteménye szintén őszi búza volt.

3.2.1.1. Fenyőmajori kísérlet helyének kiválasztása, kijelölése, kimérése

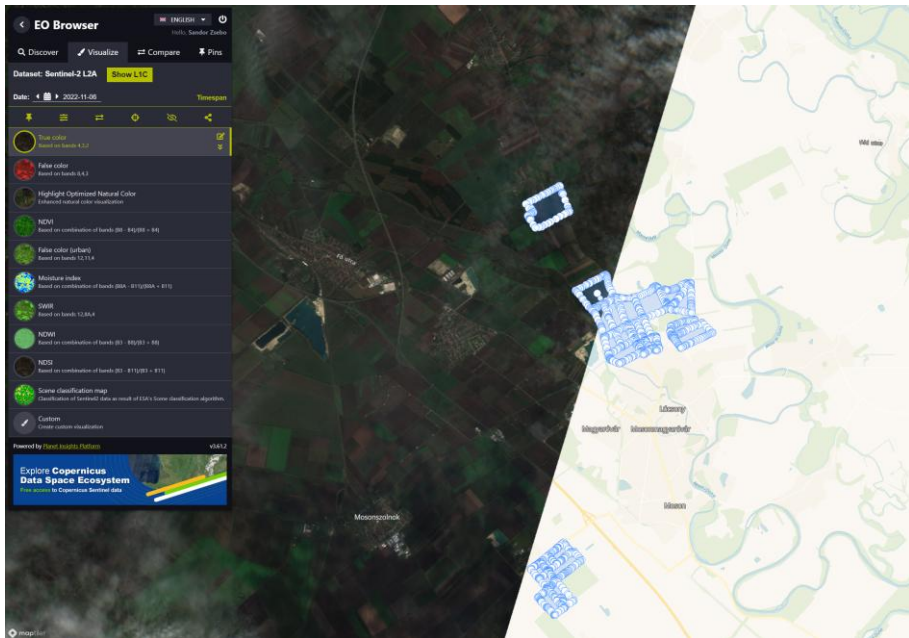
A Fenyőmajori tábla kiválasztása előtt az a cél fogalmazódott meg a Sentinel-2 műhold pályájának a tanulmányozását követően, hogy egy

olyan területet kell kijelölni a kísérlet helyszínéül, ahol kettő, illetve három nap a műholdak visszatérési ideje és egyben az Uni-Agro-Food Kft. kezelése alá tartozik.

Rövid kutatás után a Mosonmagyaróvártól legmesszebb elhelyezkedő Fenyőmajori táblára esett a választás, mivel egyedülként ez felelt meg az előző bekezdésben megfogalmazott kritériumoknak. Ezt a 2022. november 8-i (11. ábra) és november 6-i (12. ábra) Sentinel-2 műhold által készített felvételek is bizonyítanak, aminek köszönhetően kettő, illetve három naponta gyűjthetők műholdfelvételek a kísérleti területről.




11. ábra: 2022. november 8-ai Sentinel-2 által készített műholdfelvétel, ahol a fehér körök jelölik a földterületek határát. (Forrás: ESA)



12. ábra: 2022. november 6-ai Sentinel-2 által készített műholdfelvétel, ahol a fehér körök jelölik a földterületek határát. (Forrás: ESA)

Ezt követően a Fenyőmajori táblán belül a kísérlet pontos helyét tűztem ki. A feladatot a QGIS térinformatikai szoftverben a Google műholdkép segítségével valósítottam meg.

A vizsgált terület lehatárolását követően egy Sentinel-2 műholdfelvételt olvastam be a QGIS szoftverbe, majd a pixelirányoknak megfelelően kijelöltem a 3×3 pixelméretű kutatási területet (13. ábra).



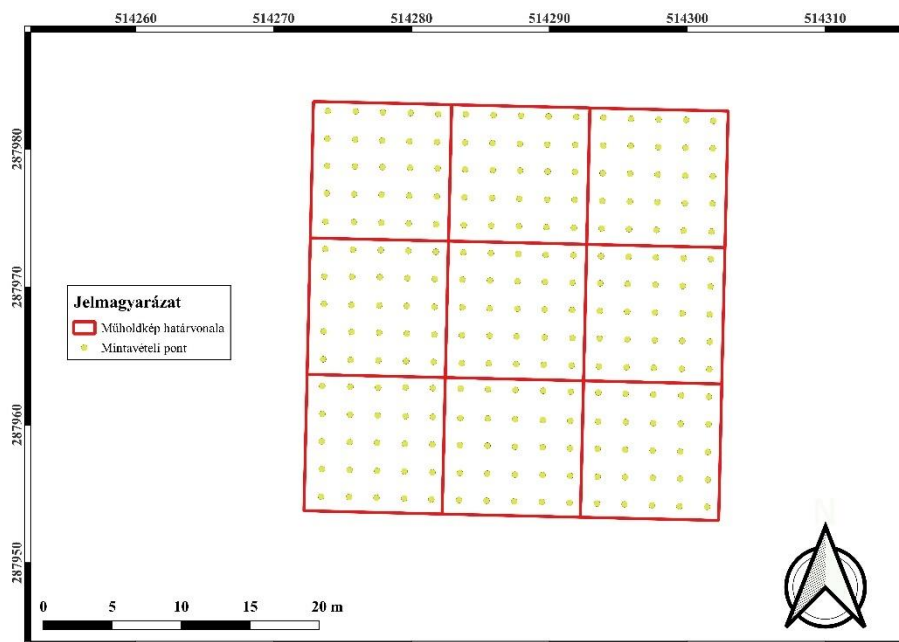
13. ábra: A Sentinel-2 műhold 10×10 méteres pixeleihez igazított határvonalak a Fenyőmajori kísérletnél.

A 3×3 -as kísérleti terület négy sarokpontjának koordinátáit kiexportáltam, majd betöltöttem egy South S660N GPS RTK (South Surveying & Mapping Instrument Co., Ltd., Peking, Kína) típusú GPS-be. Az eszköz RTK korrekcióval rendelkezett, így két centiméter pontossággal mérhettem ki a kutatási helyszín sarokpontjait (14. ábra).



14. ábra: 225 mintavételezési pont kitűzése

Mindegyik négyszögben 25 egymástól egyenlő távolságra elhelyezkedő jelölőkaró lett kitűzve, így összesen 225 mintavételi pontot (15. ábra) foglalt magába a 30×30 méteres terület. A kísérlet négy sarkába földi kontroll pontok (Ground Control Point – GCP) lettek kihelyezve. A GCP pontok közepei is be lettek mérve, amely adatok az ortomozaik képek georeferálásánál kerültek felhasználásra.



15. ábra: A kijelölt és GPS-szel bemért 225 mintavételi pont.

3.2.1.1. Szántóföldi kezelések a Fenyőmajori kísérletnél

A 2022-23-as vegetációs időszakban a következő munkafolyamatok és kezelések történtek (39. ábra) a kísérleti területen:

2022. október 16. (magágykészítés) *Erőgép:* New Holland T7.315 AC + Bednar Swifter SO 6000 F magágy-előkészítő kompaktor

2022. október 18. (vetés) *Erőgép:* New Holland T6.145 AC + Horsch Pronto 4 DC vetőgép, *Fajta:* Capo, *Mennyiség:* 200 kg/ha

2022. november 19. (növényvédelem) *Erőgép:* New Holland T6.145 + Hardi Ranger 2500 vontatott permetező, *Növényvédő szer:* Tebucor, *Dózis:* 1 l/ha

2023. február 10. (műtrágyázás) *Erőgép:* New Holland 110-90 + Amazone ZA-M Max Tronic, *Műtrágya típusa:* MAS 27 %, *Mennyiség:* 105 kg/ha

2023. március 23. (hengerezés) *Erőgép:* New Holland T6.145 AC + LEKO 5 m gyűrűshenger

2023. május 4. (lombtrágyázás) *Erőgép:* New Holland T6.145 + Hardi Ranger 2500 vontatott permetező, *Növénykondicionáló:* Naturamin-WSP, *Dózis:* 0,3 kg/ha

2023. május 4. (növényvédelem) *Erőgép:* New Holland T6.145 + Hardi Ranger 2500 vontatott permetező, *Növényvédő szer:* U46 M Plus 750SL, *Dózis:* 1 l/ha

2023. május 10. (lombtrágyázás) *Erőgép:* New Holland T6.145 + Hardi Ranger 2500 vontatott permetező, *Növénykondicionáló:* Naturamin-WSP, *Dózis:* 0,3 kg/ha

2023. május 24. (növényvédelem) *Erőgép:* New Holland T6.145 + Hardi Ranger 2500 vontatott permetező, *Növényvédő szer:* Klartan 24 EW, *Dózis:* 0,2/ha

2023. július 20. (betakarítás) Claas Medion 340 + C510 vágóasztal (5,1 méteres)

3.2.2. Genezises kísérlet

A Genezises kísérlet összességében négy kultúrát (őszi búza (*Triticum aestivum* L.), őszi káposztarepce (*Brassica napus* L.), kukorica (*Zea mays* L.) és tavaszi árpa (*Hordeum vulgare* L.)) foglal magába, amelyben a különböző növények a vetésforgót betartva folyamatosan egymást követik. Kutatásom során a vizsgált kultúrnövény az őszi búza volt a 2021-22-es és a 2022-23-as termesztési ciklusban. Az őszi búza

előveteménye mindkét évben őszi káposztarepce volt. A vizsgált terület talajtípusa Dunai öntéstalaj.

A kísérlet randomizált blokk elrendezésű (16. ábra) négy blokkal és négy ismétléssel. Minden blokkban eltérő mennyiségű műtrágya lett kijuttatva. Egy parcella mérete $4,2 \times 22$ méter. A GK Csillag fajta vetésére mindkét évben október 25-én 12 centiméteres sortávban került sor. A kivetett hektáronkénti magmennyiség 4 500 000 szem volt.



16. ábra: Randomizált blokk elrendezésű Genezises kísérlet négy kezeléssel (kontroll (C), környezetkímélő (A), mérleg (B), genezis (D)) és négy ismétlésben.

Mindkét esztendőben a kísérleti területre történő műtrágya-kijuttatás (4. táblázat) két menetben történt. Az első rögtön alaptrágyaként a vetéssel egy menetben (2021. és 2022. október 25-én), majd 2022-ben és 2023-

ban is március 1-én került sor a fejtrágyázásra. A következő makroelem hatóanyagmennyiségek kerültek kijuttatásra a kezeléseknél:

- Nitrogén (környezetkímélő – 135,3 kg/ha, mérleg – 135,1 kg/ha, genezis – 135 kg/ha)
- Foszfor (környezetkímélő – 77,5 kg/ha, mérleg – 91 kg/ha, genezis – 75 kg/ha)
- Kálium (genezis – 45 kg/ha)

A kísérletek betakarítása egy Sampo SR2010 (Sampo Rosenlew Kft., Finnország) típusú parcellakombájnnal valósult meg.

4. táblázat: A négy kezelés (kontroll (C), környezetkímélő (A), mérleg (B), genezis (D)) a kijuttatott hatóanyag-mennyiségekkel és a kijuttatás időpontjaival.

| Kezelés | Hatóanyag (kg/ha) | | | Kijuttatott műtrágya kg/ha (őszi) 2021. és 2022. 10. 25. | | Kijuttatott műtrágya kg/ha (tavasz) 2022. és 2023. 03. 01. | |
|---------------------|-------------------|-------------------------------|------------------|--|------------|--|-----------|
| | N | P ₂ O ₅ | K ₂ O | Típus | Mennyiség | Típus | Mennyiség |
| Kontroll (C) | - | - | - | - | - | - | - |
| Környezetkímélő (A) | 135,3 | 77,50 | - | NP 15-25 | 310 | N 27% | 329 |
| Mérleg (B) | 135,1 | 91 | - | NP 15-25 | 364 | N 27% | 298 |
| Genezis (D) | 135 | 75 | 45 | NPK 5-18-18 NP 15-25 | 250 120 | N 27% | 387 |

3.2.2.1. Szántóföldi kezelések a Genezises kísérletnél

A 2021-22-es és a 2022-23-as vegetációs periódusban a következő munkafolyamatok és kezelések történtek (39. ábra) a kísérleti területen:

2021. október 24. (műtrágyázás): manuálisan, kezelésként a 4. táblázat alapján

2021. október 24. (magágyelőkészítés) *Erőgép:* Goldoni 45 RS + Sicma ZLL 140 talajmaró

2021. október 25. (vetés) *Erőgép:* New Holland 110-90 + SULKY Tramline GC 4 m vetőgép, *Fajta:* GK csillag, *Mennyiség:* 4,5 millió csíra/ha

2021. november 19. (növényvédelem) *Erőgép:* Goldoni 45 RS + Biardzki 300/10 függesztett permetező, *Növényvédő szer:* Tebucor, *Dózis:* 1/ha

2022. március 1. (műtrágyázás) manuálisan, kezelésként a 4. táblázat alapján

2022. április 14. (növényvédelem) *Erőgép:* Goldoni 45 RS + Biardzki 300/10 függesztett permetező, *Növényvédő szer:* Granstar 50SX és Fury 10 EW, *Dózis:* 50 g/ha és 0,075 l/ha

2022. május 10. (növényvédelem) *Erőgép:* Goldoni 45 RS + Biardzki 300/10 függesztett permetező, *Növényvédő szer:* Trebusha 25 EW, *Dózis:* 1/ha

2022. május 27. (növényvédelem) *Erőgép:* Goldoni 45 RS + Biardzki 300/10 függesztett permetező, *Növényvédő szer:* Fury 10 EW és Cello, *Dózis:* 0,075 l/ha és 1 l/ha

2022. július 5. (betakarítás) Sampo SR2010 parcellakombájn 1,5 m széles gabona-vágóasztallal

2022. augusztus 15. (tarlóhántás) *Erőgép:* New Holland T7.315 AC + Pöttinger TerraDisc 6001 T típusú félig függesztett rövidtárca

2022. október 24. (műtrágyázás) manuálisan, kezelésként az 4. táblázat alapján

2022. október 24. (magágyelőkészítés) *Erőgép:* Goldoni 45 RS + Sicma ZLL 140 talajmaró

2022. október 25. (vetés) *Erőgép:* New Holland 110-90 + SULKY Tramlane GC 4 m vetőgép, *Fajta:* GK csillag, *Mennyiség:* 4,5 millió csíra/ha

2022. november 28. (növényvédelem) *Erőgép:* Goldoni 45 RS + Biardzki 300/10 függesztett permetező, *Növényvédő szer:* Tebucor, *Dózis:* 1/ha

2023. március 1. (műtrágyázás) manuálisan, kezelésként a 4. táblázat alapján

2023. április 3. (növényvédelem) *Erőgép:* Goldoni 45 RS + Biardzki 300/10 függesztett permetező, *Növényvédő szer:* Granstar 50SX és Fury 10 EW, *Dózis:* 50 g/ha és 0,075 l/ha

2023. május 5. (növényvédelem) *Erőgép:* Goldoni 45 RS + Biardzki 300/10 függesztett permetező, *Növényvédő szer:* Trebusha 25 EW, *Dózis:* 1/ha

2023. május 19. (növényvédelem) *Erőgép:* Goldoni 45 RS + Biardzki 300/10 függesztett permetező, *Növényvédő szer:* Fury 10 EW és Cello, *Dózis:* 0,075 l/ha és 1 l/ha

2023. július 3. (betakarítás) Sampo SR2010 parcellakombájn 1,5 m széles gabona-vágóasztallal

3.3. Adatgyűjtő eszközök bemutatása

Jelen kutatásban három különböző távérzékelési eszközt, valamint egy földközeli kézi szenzort használtam az adatok gyűjtéséhez. A vizsgálatok során a Sentinel-2 műhold, egy DJI Matrice 210 V2 (Da-Jing Innovation, Nanshan, Shenzhen, Kína) típusú drónra szerelt MicaSense RedEdge-MX Dual (MicaSense Inc., Seattle, Washington,

USA) kamerarendszer, egy Phantom 4 multispektrális kamera (Da-Jing Innovation, Nanshan, Shenzhen, Kína) és egy kézi GreenSeeker (NTech Industries, Trimble, Sunnyvale, Kalifornia, USA) adatait vettem alá további elemzéseknek.

3.3.1. Sentinel-2 műhold

Sentinel-2 műhold által a kísérleti területről készült felvételek letöltése a Sentinel Hub EO Browser keresőrendszeren keresztül valósult meg.

3.3.2. MicaSense RedEdge-MX Dual kamerarendszer

Mindkét kísérleti területen idősoros méréseket végeztem a MicaSense RedEdge-MX Dual kamerarendszerrel. Ez egy különálló adatgyűjtő szenzor, amelyet egy érzékelővel kompatibilis drónra kellett felszereni. A megoldást a négy rotoros DJI Matrice 210 V2 típusú drón (17. ábra) jelentette, amely számos ipari felhasználásra is alkalmas, köszönhetően a robusztusos felépítésének és az egyszerű konfigurálhatóságának. A Matrice 210 második szériája már fejlettebb intelligens irányítórendszerrel, jobb teljesítménnyel és megerősített biztonsággal rendelkezik mind a repülés, mind az adatátvitel terén az elődjéhez képest.



17. ábra: DJI Matrice 210 V2 típusú drón felvételkedés közben.

A MicaSense RedEdge-MX Dual kamerarendszer (18. ábra) egy nagyteljesítményű professzionális multispektrális érzékelő. A kamerák összekötésének köszönhetően egyszerre tíz spektrális sávot (5. táblázat) képes rögzíteni a felvételezések során.

5. táblázat: A MicaSense kamera tíz sávja, hullámhossz közepe és a sávok szélessége.

| Sávok | Hullámhossz közepe (nm) | Sáv szélesség (nm) |
|---------------------|--------------------------------|---------------------------|
| Sáv 1 (Világos kék) | 444 | 28 |
| Sáv 2 (Kék) | 475 | 32 |
| Sáv 3 (Zöld) | 531 | 14 |
| Sáv 4 (Zöld) | 560 | 27 |
| Sáv 5 (Vörös) | 650 | 16 |

| | | |
|----------------------------|-----|----|
| Sáv 6 (Vörös) | 668 | 14 |
| Sáv 7 (Vörös él) | 705 | 10 |
| Sáv 8 (Vörös él) | 717 | 12 |
| Sáv 9 (Vörös él) | 740 | 18 |
| Sáv 10 (Közeli infravörös) | 842 | 57 |



18. ábra: A MicaSense RedEdge-Mx dual kamerarendszer és annak tíz lencséje.

A szenzor részletes specifikációja a 6. táblázatban látható. A kamerához egy drónra szerelhető fényérzékelő és egy kalibrációs panel is tartozik, amelyek a változó fényviszonyok okozta torzító hatásokra nyújtanak megoldást. A MicaSense kamera esetében a 10-es sáv (közeli infravörös) és a 6-os sáv (vörös) spektrumi lettek felhasználva az NDVI értékek kikalkulálásához.

6. táblázat: A MicaSense-RedEdge-MX dual kamerarendszer specifikációja.

| Specifikáció | |
|-------------------|---|
| Súly | 508,8 g (két szenzor, tartórendszer, fényérzékelő és kábel) |
| Méret | 8,7 x 12,3 x 7,6 cm |
| Tápegység | 4,2 V DC – 15,8 V DC |
| Spektrum | kék, zöld, vörös, vörös váll, közeli infravörös |
| RGB kimenet | 3,6 MP (Globális zár, sávokkal szinkronizálva) |
| Pixel felbontás | 8 cm pixel (spektrumonként) 120 m magasságból |
| Képssebesség | 1 képkocka másodpercenként (minden spektrum) 12-bit RAW |
| Kapcsolat | Serial, 10/100/1000 ethernet, kikapcsolható WiFi, külső trigger, GPS, SDHC kártya |
| Látómező | 47,2° HFOV |
| Üzemi hőmérséklet | 0 – 40°C (nincs légáramlat), 0 – 50°C levegőáram mellett > 0,5 m/s |
| Spektrumtartomány | 400 nm – 900 nm |

3.3.3. Phantom 4 multispektrális kamera

A Phantom 4 multispektrális kamerával történő mérésekre a Fenyőmajori táblán került sor. A négyrotoros drónra szerelt 2 megapixeles szenzorrendszer specifikációja a 7. táblázatban látható. A kamera egy RGB-kamerából és öt kamerás multispektrális kamerarendszerből áll, amelyek hullámhosszai a 8. táblázatban található.

7. táblázat: Phantom 4 multispektrális kamerája specifikációja

| Specifikációk | |
|-----------------------|--|
| Súly (drónnal) | 1487 g |
| Érzékelők | 6 1 / 2,9 "CMOS, egy RGB-érzékelővel színes képekhez és öt monokróm érzékelővel a multispektrális képekhez. Minden érzékelő: 2,08 MP |
| Pixel felbontás | (H/18,9) cm/pixel, H= drón magassága (mértékegysége: m) |
| ISO tartomány | 200 – 800 |
| Képméret | 1600 x 1300 (4:3.25) |
| Képfarmátum | JPEF (RGB képek) + TIFF (MSP képek) |
| Támogatott SD-kártyák | microSD legalább 15 MB / s sebességgel. Maximális kapacitás: 128 GB |
| Üzemi hőmérséklet | 0 – 40°C |
| Spektrumtartomány | 400 nm – 900 nm |

A szenzoron kívül egy képstabilizátor és az eszköz tetején egy integrált spektrális napfényérzékelő is be van építve a drónba. Nagy előnye a DJI Matrice 210 V2 típusú drónnal szemben, hogy az RTK modul közvetlenül a légi járműbe lett integrálva, ezáltal 2 centiméter pontosságú pozícionált koordináták kerülnek a begyűjtött képek metaadataiba.

A Phantom 4 multispektrális kamera (19. ábra) esetében a 6-os sáv (közeli infravörös) és a 4-es sáv (vörös) spektrumai lettek felhasználva az NDVI értékek kikalkulálásához.

8. táblázat: A Phantom 4 multispektrális kamera hat sávja, hullámhossz közepe és a sávok szélessége.

| Sávok | Hullámhossz közepe (nm) | Sáv szélesség (nm) |
|---------------------------|--------------------------------|---------------------------|
| Sáv 1 (Látható fény, RGB) | - | - |
| Sáv 2 (Kék) | 450 | 16 |
| Sáv 3 (Zöld) | 560 | 16 |
| Sáv 4 (Vörös) | 650 | 16 |
| Sáv 5 (Vörös él) | 730 | 16 |
| Sáv 6 (Közeli infravörös) | 840 | 26 |



19. ábra: DJI Phantom 4 multispektrális kamerával felszerelt drón.

3.3.4. GreenSeeker HCS-250

A GreenSeeker HCS-250 (NTech Industries, Trimble, Sunnyvale, Kalifornia, USA) típusú kézi szenzorral (20. ábra) a Fenyőmajori és a Genezises kísérletnél is méréseket végeztem. Míg a korábbiakban bemutatott távérzékelési eszközök passzív szenzorok voltak, addig a GreenSeeker az aktív érzékelők csoportjába tartozik, mivel saját fényt bocsájt ki a mérések során.



20. ábra: GreenSeeker HCS-250 típusú NDVI mérő szenzor adatgyűjtés közben.

Az érzékelő működési elve, hogy a vörös és infravörös (9. táblázat) hullámhossztartományokban fényimpulzusokat bocsájt ki, miközben méri a két spektrum növényállományról történő visszaverődését. A kapott értékekből pedig a képlet alapján egy NDVI értéket számol ki.

9. táblázat: A GreenSeeker két sávja, hullámhossz közepe és a sávok szélessége.

| Sávok | Hullámhossz közepe (nm) | Sáv szélesség (nm) |
|---------------------------|-------------------------|--------------------|
| Sáv 1 (Vörös) | 660 | 10 |
| Sáv 2 (Közeli infravörös) | 780 | 15 |

3.4. Adatgyűjtés módszere

Az adatgyűjtési módszer és a felvételezési időpontok közel azonosak voltak mind a két kísérleti területen. A Genezises kísérletnél a MicaSense kamerával és a GreenSeekerrel két vegetációs perióduson keresztül végeztem az adatok gyűjtését az őszi búza szárbaindulásától (BBCH 30) a teljes érésig (BBCH 80). A Fenyőmajori kísérletnél a MicaSense és a GreenSeeker érzékelők mellett a Phantom 4 multispektrális kamerával és a Sentinel-2 műhold adataival is bővítettem a vizsgálatomat, amely egy vegetációs időszakot ölelt fel szintén a szárbaindulástól (BBCH 30) az érésig (BBCH 80).

3.4.1. Genezises kísérlet

A kísérleti területről történő adatgyűjtés 2022-ben és 2023-ban is áprilistól június végéig, hat eltérő időpontban valósult meg (10. táblázat).

10. táblázat: A Genezises kísérlet felvételezési időpontjai 2022-ben és 2023-ban, valamint az aktuális időpontokhoz kapcsolódó fejlődési szakaszok.

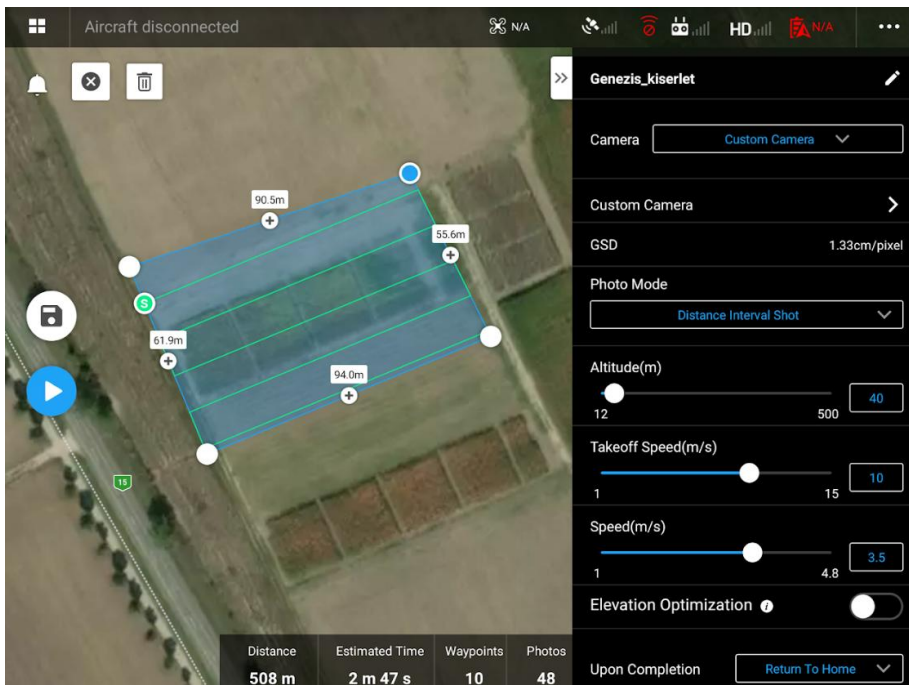
| Felvételezés időpontja (2022, 2023) | Vetés utáni nap (VUN) | BBCH- Skála | Fejlődési szakasz |
|--|--------------------------|----------------|--------------------------------|
| Április 12. | 170 | 30-35 | Szárbaindulás |
| Április 28. | 186 | 37-40 | Zászlóslevél megjelenése |
| Május 12. ±2 | 200 | 40-45 | Kalászkedzdemény fejlődése |
| Május 24. ±2 | 212 | 58-63 | Kalászhányás vége, virágzás |
| Június 07. ±2 | 226 | 70-75 | Szemképződés |
| Június 21. ±2 | 240 | 80-85 | Érés |

A földi méréseket a GreenSeekerrel végeztem. Wang et al. (2019) szintén ezt a szenzort használták kisparcellás kutatómunkájuk során, melyben megállapították, hogy parcellánként háromszor érdemes mintavételezni. Ezen eredmények alapján a parcellánkénti három kijelölt pont koordinátái az 1. mellékletben található. A vizsgálatoknál tíz mérési eredmény átlagából kaptam meg az adott ponthoz tartozó egy átlag NDVI értéket.

A felvételezés során Zhitao et al. (2014) mintájára megközelítőleg 60 cm távolságra tartottam a Greenseekert a növényállománytól. A mért átlag NDVI értékek a szenzor kijelzőjén jelentek meg.

A 2022-es esztendőben a felvételezésekre április 12-én, április 28-án, május 12-én, május 24-én, június 7-én és június 21-én került sor (10. táblázat). A 2023-as évben is ugyanazokon a napokon kezdődött az adatgyűjtés, azonban a harmadik mérési alkalomtól kezdődően ±2 nap eltérések voltak a kedvezőtlen időjárási körülmények okozta torzító hatások kiküszöbölése érdekében.

A repülések becsült időtartama 2 perc 47 másodperc volt. Zhitao et al. (2015) munkássága alapján a felvételek készítése minden alkalommal 11:30 és 12:00 között zajlott le. A repülési terv kialakítása a DJI Pilot (2.5.1.10 verzió) szoftverben (Da-Jing Innovation, Nanshan, Shenzhen, Kína) valósult meg (21. ábra). A repülési magasság 40 méterre lett állítva Duan et al., (2017) kutatómunkája alapján, ami 1,33 cm/pixel felbontást eredményezett.



21. ábra: Repülési terv készítése és a repülési adatok beállítása a DJI Pilot szoftverben.

A repülési útvonal megtervezése során 70 %-os hosszirányú és keresztirányú átfedést állítottam be. A terület felvételezése során 48 ponton készült 10 sávban felvétel, vagyis 480 multispektrális kép készült egy repülés alkalmával. A MicaSense kamerához tartozó

kalibrációs panelt a repülések megkezdése előtt és a repülések befejezése után is lefotóztam annak érdekében, hogy kiküszöbölhessem a felvételezések során fellépő változó fényviszonyok okozta torzító hatásokat (An et al., 2016). A repülések teljes egészében automatán történtek az előre megtervezett útvonal alapján.

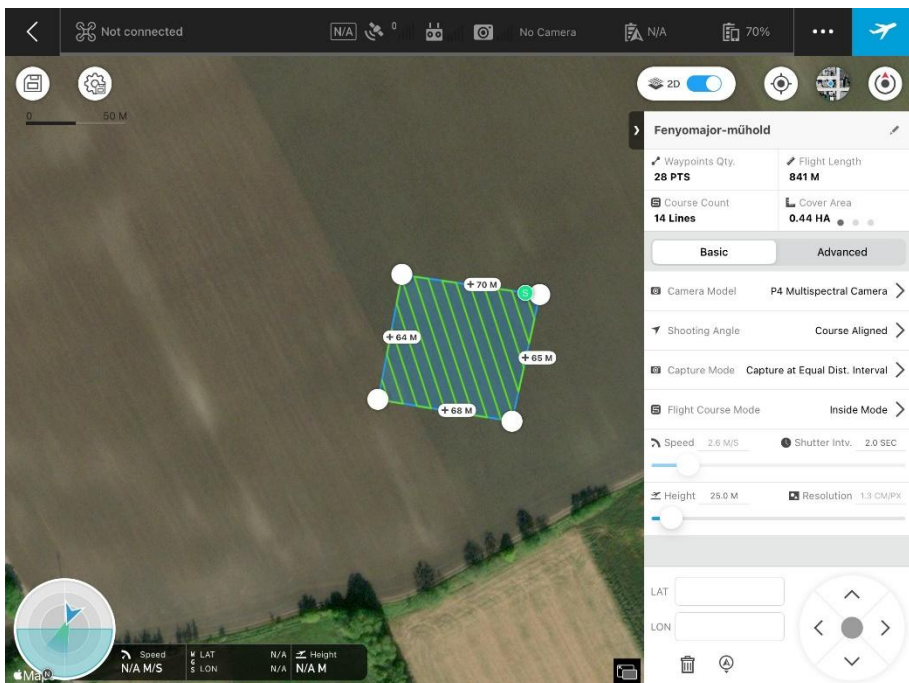
3.4.2. Fenyőmajori kísérlet

A Fenyőmajori kísérletnél egy időben négy különböző szenzor (Sentinel-2 műhold, MicaSense és Phantom 4 multispektrális kamera, GreenSeeker) adataiból kalkulált NDVI értékeket hasonlítottam össze. A felvételezés időpontja minden alkalommal a Sentinel-2 műhold kísérleti területen történő áthaladásához (9:50 és 10:10 között) volt igazítva. A kutatási helyszínről végül négy alkalommal (2023. április 12-én, május 5-én, május 22-én és június 16-án) gyűjtöttem adatokat a négy szenzor által. A felvételezés időpontjai az őszi búza BBCH 30-80-ig tartó növekedési szakasza közötti időintervallumot foglalta magába. A műhold 9:50 és 10:10 között haladt el a Fenyőmajori tábla felett, így 10:00-tól kezdtem el a drónos felvételek készítését, amelyek maximum 15 percet vettek igénybe. A növényállomány drónfelvételezés előtti letaposását megelőzve a GreenSeekeres földi mérésekkel zárult az adatgyűjtés. A földi méréseket minden alkalommal 30 és 40 perc között sikerült abszolválni.

A Fenyőmajori kísérletnél a MicaSense kamerával történő repüléseknél ugyanazok a beállítások szerepeltek, amelyeket az előző 3.4.1. „Genezises kísérlet” fejezetben részletesen kifejtettem. Egyedüli változás a kamera által készített képek mennyiségében történt, ugyanis

a mostani kísérletnél 50 pontról készült felvétel, ami 500 multispektrális képet eredményezett.

A Phantom 4 multispektrális kamerához fejlesztett DJI GSPro (2.0.18. verzió) szoftverben (Da-Jing Innovation, Nanshan, Shenzhen, Kína) a repülési magasság 25 méterre lett állítva (22. ábra) a MicaSense kamera felbontásának (1,3 cm/pixel) megtartása érdekében. A kijelölt terület nagysága 0,44 hektár, a becsült repülési idő pedig 7 perc 35 másodperc volt. A repülési útvonal megtervezése során ennél a kísérletnél és szenzornál is 70 %-os hosszirányú és keresztirányú átfedést állítottam be. A repülés során 160 pontban készült kép a területről, ami összesen 960 képet eredményezett.



22. ábra: Repülési terv elkészítése és a repülési adatok beállítása a DJI DJI GSPro szoftverben.

A GreenSeeker adatgyűjtés a 3.4.1. „Genezises kísérlet” című fejezetben bemutatott módszer alapján zajlott.

3.5. Adatfeldolgozás módszertana

Az adatok feldolgozása két szinten valósult meg. A Phantom 4 és a MicaSense kamera által készített képek összeillesztése az Agisoft Metashape Professional (2.0.1. verzió) (Agisoft LLC, Szentpétervár, Oroszország) fotogrammetriai feldolgozó szoftverben valósult meg. A képösszeillesztés folyamata a 23. ábrán látható. Az elkészült ortomozai képeket ezt követően lehetett tovább elemezni a QGIS (3.22. verzió) térinformatikai szoftverben.

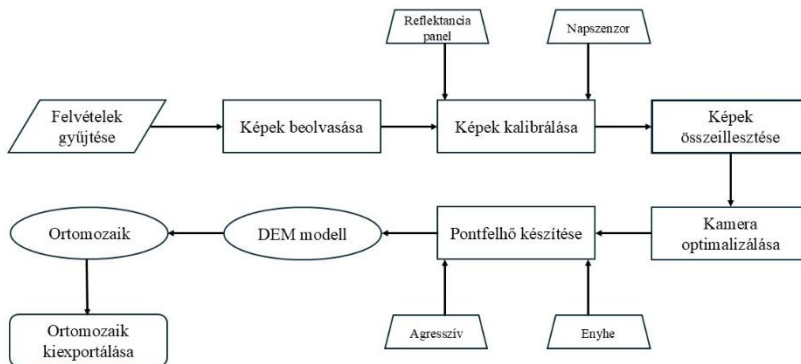
A Sentinel-2 műhold által készített nyers képek ingyenesen hozzáférhetőek és letölthetőek a Sentinel Hub EO Browseren (<https://apps.sentinel-hub.com/eo-browser>), így a műholdképek feldolgozása rögtön a QGIS szoftverben folytatódhatott.

A GreenSeeker kézi optikai szenzor a méréseket követően rögtön kiírta az adott területre vonatkozó NDVI értékeket, így ennek az eszköznek az adatával további adatfeldolgozást nem kellett végezni.

3.5.1. Képfeldolgozás folyamata az Agisoft Metashapeben

Az Agisoft Metashape fotogrammetriai feldolgozó szoftver, amellyel képek összeillesztését, 3D modelleket készítését, illetve különböző számításokat lehet végezni. A MicaSense és a Phantom 4 multispektrális kamera által készített nyers képek összeillesztése ezzel a szoftverrel valósult meg. A képösszeillesztés minden egyes lépését (23. ábra) manuálisan végeztem el, így biztosítva, hogy mindegyik

folyamat a megfelelő beállításokat tartalmazza. A Fenyőmajori és a Genezises kísérlet képösszeillesztési módszere között minimális eltérések (23. ábra) voltak.



23. ábra: Az ortomozaik kép összerakásának folyamatábrája az Agisoft Metashape szoftverben.

A nyers felvételeket multispektrális módban olvastam be az Agisoft Metashape-be szoftverbe, mivel az elemzések során különböző sávokkal kell dolgozni.

A feldolgozás következő lépcsőfokát a képek kalibrálása (23. ábra) jelentette. A MicaSense kamerához tartozó kalibrációs panel használata mellett a drónon elhelyezett napszenzor adatai is beolvasásra kerültek (23. ábra). A Phantom 4 multispektrális kamera nem rendelkezik saját kalibrációs pannellel, ezért ott csak a napszenzor értékeivel kalibráltam a képeket.

A kalibrálás után a képek feldolgozása következett. Az összeillesztés a képfeldolgozás egyik legfontosabb folyamata, mivel ennél a lépésnél

ismeri fel a szoftver a képek közös jellemzőit, illetve meghatározza a képek relatív pozícióját és orientációját. Beállítottam a kulcspontok és az illesztési pontok számát. A Phantom 4 multispektrális kameránál a képösszeillesztés során a „Generic preselection” helyett a „Reference preselection” opciót állítottam be, mivel ott rendelkezésre állnak a képpárok kiválasztása során a képekhez társított RTK pontos GPS-adatok.

Az összeillesztést a pontfelhő készítése követte, azonban ezt a folyamatot még a kamerák optimalizálása előzte meg (23. ábra). Ez egy „finomító” funkció, amely optimalizálja a kamerák pozícióját és paramétereit, hogy pontosabb modellt kaphassunk, ezáltal az egyes képek még jobban illeszkednek egymáshoz.

A kamera optimalizálás után az adatok pontfelhővé alakítása (23. ábra) következett. A program az egymást átfedő képekből háromdimenziós pontokat számol ki, amelyekből a terület térbeli alakja rajzolódik ki. A mélységssűrűs erősre (aggressive) lett állítva a MicaSense kameránál. Ennek eredményeként sok pont törölhető ki, azonban hasznos a zajos, nehezen feldolgozható képsorozatoknál. A Phantom 4 multispektrális kameránál pedig enyhére (mild) lett állítva, mivel RTK korrekcióval történt a repülés.

A pontfelhő elkészítését a digitális domborzatmodell (Digital Elevation Model – DEM) kialakítása követte. A modell a kísérleti terület domborzatának magassági adatait ábrázolja Egységes Országos Vetületi rendszerben (HD72 / EOVS (EPSG: 23700)).

Az adatfeldolgozás utolsó lépését az ortomozai kép kialakítása, majd kiexportálása (23. ábra) jelentette. Az ortomozai kép elkészítésénél egyesülnek az egymást átfedő fotók, korrigálva a perspektivikus

torzításokat és a vizsgált terület magasságváltozásait. Az ortomozaik képet a DEM modellből alakítottam ki és két centiméteres pixelnagyságot állítottam be.

3.5.2. Adatfeldolgozás módszertana a QGIS-ben

Az Agisoft Metashapeben összeillesztett és kiexportált ortomozaik képekkel a QGIS szoftverben dolgoztam tovább. A Fenyőmajori és a Genezises kísérletnél is ugyanaz az adatfeldolgozási és kiértékelési folyamat zajlott le, mindkét helyen a GreenSeeker mérések nagysága jelentette az etalont. Emiatt a QGIS-ben történő adatfeldolgozási folyamatot csak a Fenyőmajori táblán mutatom be részletesen, de ugyanazokat a lépéseket történtek a Genezises kísérletnél is.

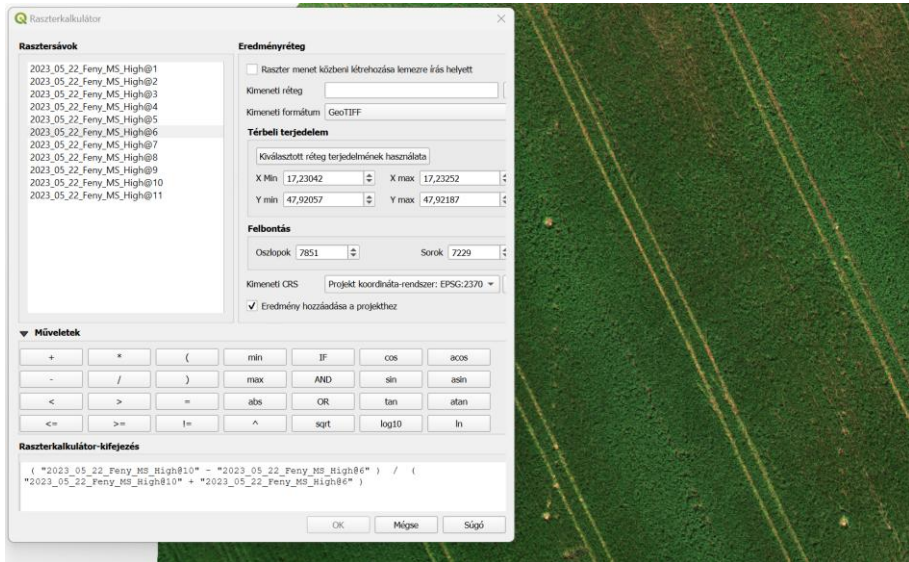
A drónképek beolvasását követően a nyers képekből NDVI térképet készítettem a raszterkalkulátor (24. ábra) segítségével a következő képlet (1) alapján:

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (1)$$

ahol:

NIR = közeli infravörös – Sentinel-2 (842 nm), MicaSense kamera (842 nm), Phantom 4 (840 nm).


Red = vörös – Sentinel-2 (665 nm) MicaSense kamera (668 nm), Phantom 4 (650 nm).



24. ábra: Rasterkalkulátorban NDVI térkép készítése az (1) egyenletben bemutatott képlet alapján.

Ekkor a pixelértékek 0 és 1 közötti értéket vettek fel. A MicaSense kamerával készített felvételeknél ezt egy georeferálási folyamat követett, mivel a felvételezés nem RTK pontossággal készült. A következő lépés a legelső felvételezés előtt kitzűzött és bemért pontok koordinátáinak beolvasása volt.

A kitzűzött pontok körül 25 centiméteres sugárban mértem le az őszi búzával fedett területeket. Ekkor egy átlag NDVI érték jelent meg a GreenSeeker kijelzőjén. Annak érdekében, hogy a drónképek NDVI értékei is összehasonlíthatóvá válhassanak a GreenSeekerrel mért értékekkel, egy 25 centiméter sugarú bufferzónát (25. ábra) jelöltem ki a pontok körül.



25. ábra: A 225 mintavételi pont (piros) elhelyezkedése. A sárga kör jelöli a 25 cm sugarú bufferzónát.

A zónastatisztika funkció alkalmazásával minden egyes ponthoz, egy átlag NDVI értéket kaptam a MicaSense és a Phantom 4 multispektrális kamera esetében is. Az attribútum táblázat adatait *.csv formátumban exportáltam ki, így idősorosan Excel táblázatba rendezhettem a kapott adatokat.

3.5.3. Meteorológiai adatok elemzésének módszertana

Kutatásom egyik részét az NDVI értékek és a hozamok közötti kapcsolatot vizsgálata tette ki, azonban annak érdekében, hogy minél pontosabb hozampredikációs-modellt tudjak felállítani, meteorológiai adatokat is bevontam az elemzésekbe. A hatékonyabb eredmények elérése érdekében a (2) egyenletet alkalmaztam.

NDVI/VUN arányt úgy kaptam meg, hogy az NDVI értéket elosztottam a VUN (Vetés utáni napok) számával, vagyis a vetéstől a felvételezés időpontjáig eltelt napok számával, abban az esetben, amikor az NFKHÖ (napi fejlődési hőmérsékleti összeg) > 0 .

$$\text{NFKHÖ} = \frac{T_{\text{max}} + T_{\text{min}}}{2} - 0^{\circ}\text{C} \quad (2)$$

ahol:

T_{max} = napi maximum hőmérséklet

T_{min} = napi minimum hőmérséklet

0°C az őszi búza bázishőmérséklete (Salazar-Gutierrez et al., 2013).

Az NDVI/KNFKHÖ arány kiszámításánál az NDVI értéket elosztottam a KNFKHÖ (kumulált napi fejlődési hőmérsékleti összeg) értékkel a vetéstől a felvételezés időpontjáig, amikor NFKHÖ > 0 .

3.6. Alkalmazott statisztikai módszerek bemutatása

3.6.1. Genezises kísérlet

A statisztikai elemzéseket kezelésként, időpontként és szenzoroként is külön-külön elvégeztem az R statisztikai szoftver „rcompanion” csomagjával (R Core Team, 2020; Mangiafico, 2021.)

Első lépésként (1) leíró statisztikai módszert használtam az adatkészletek jellemzőinek leírására. Kiszámoltam a két szenzor különböző időpontokban mért átlag NDVI értékeit és szórásait.

Második lépésben (2) a szenzorok (MicaSense és GreenSeeker) méréseit eltérő időpontokban és külön kezelésként is összehasonlítottam a kétmintás t-próbával $p \leq 0,05$ szignifikanciaszinten. Azonban ezt megelőzte a szóráshomogenitás vizsgálat a Levene-teszt (Levene, 1960) segítségével. Végül regresszióanalízissel elemeztem a különböző kezeléseknél a két szenzor mérése közötti kapcsolatot.

Harmadik lépésben (3) a kéttényezős varianciaanalízis (ANOVA) után Tukey-féle post hoc-teszttel (Honestly Significant Difference - HSD) feltártam a szenzorok adataiból nyert NDVI értékek alapján a kezelések közötti különbségeket. Mindkét statisztikai eljárás $p \leq 0,05$ szignifikanciaszinten történt.

Negyedik lépésben (4) a GreenSeeker (GS) és MicaSense (MS) kamera adataiból kalkulált NDVI értékek és az őszi búza hozama közötti kapcsolatot (11. táblázat) elemeztem $p \leq 0,05$ szignifikanciaszinten. Az elemzés során a két év mérési adatait összevontan, így egy időpontban, egy kezelés eredményét nyolc minta reprezentálja.

11. táblázat: Pearson-féle korreláció kapcsolati erőssége.

| Tartomány | Kapcsolat erőssége |
|------------------|---------------------------|
| 0,80 – 1,00 | Nagyon erős pozitív |
| 0,60 – 0,79 | Erős pozitív |
| 0,40 – 0,59 | Mérsékelten pozitív |
| 0,20 – 0,39 | Gyenge pozitív |
| 0,00 – 0,19 | Nagyon gyenge pozitív |
| -0,19 – -0,01 | Nagyon gyenge negatív |

Ötödik lépésben (5) a GreenSeeker által mért, valamint a MicaSense kamera adataiból kalkulált NDVI értékek és az őszi búza hozama közötti determinációs együtthatókat (r^2) (12. táblázat) határoztam meg ($p \leq 0,05$, $p \leq 0,01$, és $p \leq 0,001$ szignifikanciaszinten) lineáris, exponenciális és kvadratikusan egyenletek használatával.

12. táblázat: Determinációs együtthatók (r^2) erőssége.

| Tartomány | Összefüggés erőssége |
|------------------|-----------------------------|
| 0,8 – 1,00 | Nagyon erős |
| 0,6 – 0,79 | Erős |
| 0,4 – 0,59 | Mérsékelt |
| 0,2 – 0,39 | Gyenge |
| 0,0 – 0,19 | Nagyon gyenge |

Hatodik lépésben (6) a Pearson-féle korreláció és a determinációs együttható vizsgálatával kiválasztottam azt az időpontot, amikor a legjobban előre jelezhető NDVI értékek alapján a várható hozam. Az átlagos négyzetgyökhibát (root mean square error – RMSE) (3) is

kiszámoltam a különböző predikciós egyenletekhez, hogy információt kaphassak az előrejelzés pontosságáról.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3)$$

ahol:

n = megfigyelések száma

y_i = mért értékek

\hat{y} = modell által meghatározott értékek

Hetedik lépésben (7) új modelleket alakítottam ki, amelyeknél az adatállományt már a KNFHÖ (kumulált napi fejlődési hőmérsékleti összeg) és a VUN (Vetés utáni nap) paraméterekkel bővítettem a környezeti tényezők torzító hatásának minimalizálása érdekében. Az RMSE értékeket ezeknél az új modelleknél is kiszámoltam.

Nyolcadik lépésben (8) elvégeztem a modell validálását. Az újonnan kifejlesztett NDVI és KNFHÖ értékekkel módosított modellt a determinációs együtthatók és az RMSE értékek kiszámolásával validáltam.

3.6.2. Fenyőmajori kísérlet

Első lépésként (1) leíró statisztikai módszert használtam az adatkészletek jellemzőinek leírására. Kiszámoltam a három szenzor (GreenSeeker, Phantom 4 és MicaSense multispektrális kamera) négy időpontban mért átlag NDVI értékeit és szórásait 225 mintavételi pontra vetítve.

Második lépésben (2) a szenzorok adataiból kalkulált NDVI értékeket eltérő időpontokban kétmintás t-próbával $p \leq 0,001$

szignifikanciaszinten hasonlítottam össze. Azonban ezt megelőzte még a szóráshomogenitás vizsgálat a Levene-teszt (Levene, 1960) segítségével. Végül regresszióanalízissel feltártam a különböző szenzorok mérése közötti kapcsolatot.

Harmadik lépésben (3) Tukey-féle post hoc-teszttel elemeztem a négy szenzor (GreenSeeker, Phantom 4 és MicaSense multispektrális kamera, Sentinel-2 műhold) adataiból nyert NDVI értékek közötti különbségeket $p \leq 0,05$ szignifikanciaszinten.

Negyedik lépésben (4) lineáris kevert modellt építettem, ahol a kézi/terepi NDVI-mérés volt a fix faktor (háttérváltozó), az időpont a random faktor, a válaszváltozó pedig a műholdképről származó NDVI. Mivel időpontonként összesen kilenc darab Sentinel-2 pixel állt a rendelkezésre, a modell tanításánál mindig hat (véletlenszerűen választott) műholdkép pixelt választottam ki, a maradék hármat pedig a kiértékelésnél használtam fel. A hat tanító pixelből pixelenként és időpontonként először egy terepi NDVI-értéket választottam a tanításhoz. Ezt követően két GreenSeekeres NDVI értékkel végeztem el a számolást, majd egyesével növeltem a minták számát, míg el nem értem a 25-t. Ez azt jelentette, hogy a 25 (egy Sentinel-2 pixelen belüli GreenSeekeres mérés) \times 6 (tanítási modell) \times 4 (időpont) lehetséges értékből az $1 \times 6 \times 4$ pontot 1000 féle módon választom ki, majd újra a $2 \times 6 \times 4$ pont, $3 \times 6 \times 4$ pont esetében, míg el nem értem a $25 \times 6 \times 4$ pontot.

A modell tanítását és a kiértékelést is minden egyes kombinációnál 1000 ismétléssel futtattam le. A kiértékelést viszont a három kiértékelő pixelhez tartozó összes adatsorra (összes időpont és összes kézi mérési mintaterület) végeztem.

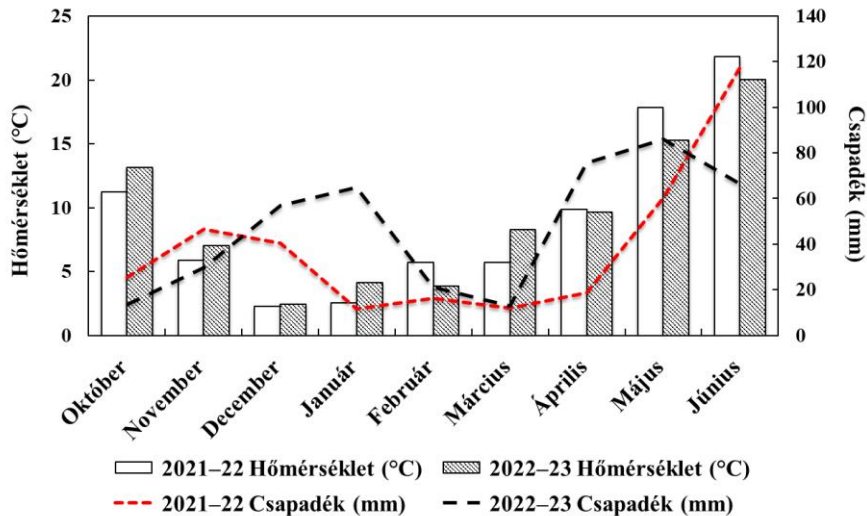
Ötödik lépésben (5) a lineáris kevert modell eredményeit a determinációs együtthatók és az RMSE értékek kiszámolásával vizsgáltam.

4. EREDMÉNYEK ÉS ÉRTÉKELÉSÜK

4.1. Genezises kísérlet

4.1.1. Kutatáshoz kapcsolódó meteorológiai adatok

Az Országos Meteorológiai Szolgálat (OMSZ) adatai szerint (26. ábra) a havi átlaghőmérséklet a felvételezések ideje alatt (április, május, június) 9,7°C, 17,6°C és 21,9°C volt a 2022-es évben, míg ugyanezekben a hónapokban 2023-ban 9,2°C, 15,1°C és 19,9°C-ot mértek. A vizsgált három hónap legmagasabb hőmérséklete 22,5°C, 30,3°C és 35,8°C volt 2022-ben, míg 2023-ban jóval alacsonyabb – 17,4°C, 20,4°C és 25,9°C – értékek születtek. 2022. áprilisában, májusában és júniusában 18,6 mm, 60,2 mm és 117,6 mm csapadék hullott, míg 2023-ban ez az érték 75,5 mm, 86,6 mm és 66,4 mm volt. A 2021-22-es és a 2022-23-as fejlődési ciklusban a napsütéses órák száma a vetéstől a betakarításig 1549,8 óra, illetve 1135,7 óra volt.



26. ábra: A kísérleti terület átlaghőmérséklete (°C) és csapadékmennyisége (mm) októbertől júniusig a 2021-22-es és 2022-23-as vegetációs időszakban havi szintű bontásban.

4.1.2. Szűkített talajvizsgálati eredmények

A Fenyőmajori és K3 Genezises táblákon kialakított kísérleti területek talajmintái 2019-ben egy szűkített kémiai talajvizsgálatnak lettek alávetve a mosonmagyaróvári Synlab Hungary Kft. talajtani laboratóriumában.

A laboratóriumi eredmények alapján (13. táblázat) mind a két kísérleti terület Ph-ja (Fenyőmajor: 6,93; Genezises: 7,17) a semleges kémhatású tartományba tartozik. A fizikai talajféleség és az Arany-féle kötöttségi szám közötti összefüggés alapján a Fenyőmajori (45) és a Genezises (45) terület is az agyagos vályog kategóriába sorolható. A Fenyőmajori táblarész sótartalma 0,13 %, a kalcium-karbonát 0,95 %, míg a termőterület humusztartalma 4,15 % volt. A nitrit-nitrát érték 142

mg/kg, míg a további két makroelem, vagyis a foszfor 347 mg/kg (P₂O₅) és a kálium 288 mg/kg (K₂O) mennyiségben volt megtalálható a talajmintákban.

A Genezises kísérlet (13. táblázat) területének sótartalma alacsonyabb volt (0,08 %), mint a Fenyőmajori (0,13 %), azonban a CaCO₃ tartalomra már jóval magasabb (24 %) értéket mértek. Humusztartalma 3,56 %, a nitrit-nitrát érték 65 mg/kg, míg a foszfor 180 mg/kg és a kálium 170 mg/kg értékek szintén jóval alacsonyabbak, mint a Fenyőmajori táblarészen.

13. táblázat: A Fenyőmajori és Genezises terület szűkített talajvizsgálati eredményei a 2019-es talajmintavételezés során.

| Kísérlet terület elnevezése | pH [KCl] | K _A | Vízoldható össz. só % (m/m) | Szénsavas mész (CaCO ₃) % (m/m) | Humusz % (m/m) | Nitrit+nitrát mg/kg | Foszfor [P ₂ O ₅] mg/kg | Kálium [K ₂ O] mg/kg |
|-----------------------------|----------|----------------|-----------------------------|---|----------------|---------------------|--|---------------------------------|
| Fenyőmajori | 6,93 | 45 | 0,13 | 0,95 | 4,15 | 142,0 | 347 | 288 |
| Genezises | 7,17 | 45 | 0,08 | 24,00 | 3,56 | 65,7 | 180 | 170 |

4.1.3. NDVI értékek összehasonlítása a különböző kezeléseknél

Az 14. táblázatban mindkét szenzor (GreenSeeker és MicaSense) adataiból kalkulált NDVI értékek átlaga figyelhető meg hat eltérő időpontban a 2021-22-es és 2022-23-as termesztési időszakban. Kezeléstől függetlenül, a MicaSense kamera adataiból számított NDVI értékek minden mérési időpontban szignifikánsan magasabb értékeket mutattak, mint a GreenSeeker által mért NDVI értékek p≤0,001 szignifikanciaszinten. Mind a 12 mérési időpontban elmondható, hogy a GreenSeeker által gyűjtött NDVI értékek szignifikánsan

alacsonyabbak ($p \leq 0,001$) voltak a kontroll parcelláknál a kezelt területekhez képest. A MicaSense kamera adataiból kalkulált NDVI értékek hasonlóságot mutattak a GreenSeekeres mérések eredményeivel, kivéve május 12-én, amikor a kontroll, a környezetkímélő, a mérleg és a genezis kezelések között nem volt szignifikáns különbség ($p \geq 0,05$) megállapítható.

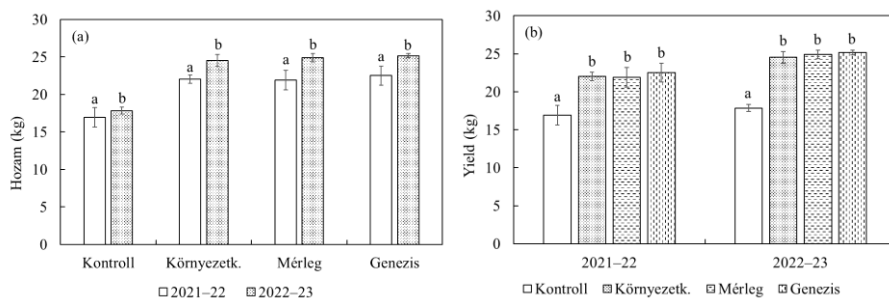
14. táblázat: A négy kezelés (kontroll, környezetkímélő (környezetk.), mérleg, genezis) átlag NDVI értéke ($n = 12$ / kezelés) és szórása hat felvételezési időpontban a 2021-22-es és a 2022-23-as vegetációs periódusban. (A kezelések közötti szignifikáns különbséget ($p \leq 0,05$) az eltérő betűjelek jelölik az egyes szenzoroknál a két kísérleti évben).

| Év | Szenzor | Kezelés | Április 12. | Április 28. | Május 12. | Május 24. | Június 7. | Június 21. |
|---------|-------------|-------------|------------------------|------------------------|------------------------|------------------------|------------------------|------------------------|
| 2021-22 | GreenSeeker | Kontroll | 0,46±0,06 ^a | 0,55±0,08 ^a | 0,59±0,06 ^a | 0,47±0,07 ^a | 0,43±0,06 ^a | 0,13±0,05 ^a |
| | | Környezetk. | 0,54±0,06 ^b | 0,69±0,04 ^b | 0,70±0,02 ^b | 0,61±0,03 ^b | 0,53±0,03 ^b | 0,20±0,03 ^b |
| | | Mérleg | 0,51±0,10 ^b | 0,67±0,10 ^b | 0,68±0,04 ^b | 0,58±0,03 ^b | 0,51±0,04 ^b | 0,20±0,05 ^b |
| | | Genezis | 0,53±0,05 ^b | 0,68±0,03 ^b | 0,68±0,03 ^b | 0,59±0,04 ^b | 0,53±0,05 ^b | 0,20±0,05 ^b |
| | MicaSense | Kontroll | 0,60±0,07 ^a | 0,80±0,05 ^a | 0,84±0,03 ^a | 0,79±0,04 ^a | 0,71±0,06 ^a | 0,35±0,08 ^a |
| | | Környezetk. | 0,67±0,07 ^b | 0,89±0,02 ^b | 0,89±0,01 ^a | 0,86±0,01 ^b | 0,79±0,02 ^b | 0,47±0,06 ^b |
| | | Mérleg | 0,64±0,10 ^b | 0,88±0,06 ^b | 0,86±0,10 ^a | 0,85±0,03 ^b | 0,77±0,05 ^b | 0,47±0,06 ^b |
| | | Genezis | 0,66±0,05 ^b | 0,89±0,02 ^b | 0,89±0,01 ^a | 0,86±0,01 ^b | 0,78±0,04 ^b | 0,45±0,07 ^b |
| 2022-23 | GreenSeeker | Kontroll | 0,65±0,07 ^a | 0,60±0,07 ^a | 0,66±0,05 ^a | 0,58±0,05 ^a | 0,45±0,06 ^a | 0,15±0,03 ^a |
| | | Környezetk. | 0,76±0,07 ^b | 0,76±0,06 ^b | 0,76±0,04 ^b | 0,70±0,03 ^b | 0,60±0,05 ^b | 0,25±0,04 ^b |
| | | Mérleg | 0,79±0,02 ^b | 0,79±0,02 ^b | 0,78±0,02 ^b | 0,71±0,02 ^b | 0,62±0,02 ^b | 0,24±0,02 ^b |
| | | Genezis | 0,78±0,03 ^b | 0,79±0,02 ^b | 0,79±0,02 ^b | 0,72±0,01 ^b | 0,62±0,02 ^b | 0,24±0,03 ^b |
| | MicaSense | Kontroll | 0,88±0,04 ^a | 0,86±0,04 ^a | 0,85±0,04 ^a | 0,80±0,03 ^a | 0,75±0,03 ^a | 0,38±0,04 ^a |
| | | Környezetk. | 0,92±0,04 ^b | 0,91±0,03 ^b | 0,89±0,02 ^a | 0,86±0,03 ^b | 0,83±0,01 ^b | 0,53±0,04 ^b |
| | | Mérleg | 0,94±0,01 ^b | 0,92±0,01 ^b | 0,89±0,01 ^a | 0,86±0,02 ^b | 0,83±0,02 ^b | 0,52±0,03 ^b |
| | | Genezis | 0,94±0,01 ^b | 0,92±0,01 ^b | 0,90±0,01 ^a | 0,87±0,01 ^b | 0,83±0,01 ^b | 0,49±0,03 ^b |

4.1.4. Különböző kezelések kapcsolata a hozammal

A 27a. ábrán a különböző kezelések hozamai figyelhetők meg a 2021-22-es és a 2022-23-as termesztési időszakban, rámutatva az egyes kezelések hozamánál tapasztalható szignifikáns különbségre ($p \leq 0,05$) a

megfigyelt két évben. A 27b. ábra a vizsgált két esztendőben a kontroll és kezelt parcellák átlaghozama közti szignifikáns különbséget ($p \leq 0,05$) mutatja meg. Ugyanakkor a környezetkímélő, a mérleg és a genezis kezelésekre egymással történő összehasonlításakor, egyik évben sem volt szignifikáns különbség ($p \geq 0,05$) tapasztalható. A vizsgált időszak hozamának összevetésénél (27b. ábra) a 2021-22-es vegetációs periódusban magasabb szórásértékeket figyelhetők meg a különböző kezeléseknél (0,56-1,31 kg), mint a 2022-23-as termelési ciklusban (0,30-0,77). Ennek oka, hogy a 2022-23-as időszakban jóval kedvezőbb időjárási feltételek adódtak az őszi búza termesztéséhez, amelyre a 3.1.2.-es fejezetben taglaltak is következtetni engednek.



27. ábra:(a) őszi búza hozama a 2021-22-es és a 2022-23-as periódusban, (b) őszi búza hozama a különböző kezeléseknél (kontroll, környezetkímélő (környezetk.), mérleg, genezis) a 2021-22-es és a 2022-23-as vegetációs időszakban. a–szignifikáns differencia ($p \leq 0,05$), b–nincs szignifikáns differencia ($p \geq 0,05$)

4.1.5. Korreláció az NDVI értékek és az őszi búza hozama között

A GreenSeeker kézi szenzor, illetve a MicaSense kamera adataiból kalkulált NDVI értékek és az őszi búza hozama közötti Pearson-féle

korrelációelemzés eredménye az 15. táblázatban található. A táblázatban szereplő eredmények a vizsgált két évben begyűjtött adatokat összevontan ábrázolja. A GreenSeekerrel végzett méréseknél a „Pearson r” értékek alapján a kontroll kezelés kivételével (15. táblázat), minden kezelésnél erős vagy nagyon erős korreláció ($r = 0,67-0,95$) figyelhető meg a NDVI értékek és az őszi búza betakarított hozama között. A kontroll kezelésnél a „Pearson r” értékek 0,23 és 0,86 között változtak a különböző felvételezési időpontokban. A környezetkímélőnél 0,67 és 0,88, a mérlegnél 0,67 és 0,94, míg a genézis kezeléseknél 0,73 és 0,90 közötti értékeket vettek fel.

A MicaSense kamera esetében egy gyengülő kapcsolat figyelhető meg a hozam és az NDVI értékek között a 170. vetés utáni naptól (VUN) a 200. napig tartó időintervallumban. Ettől kivétel a Genézis kezelés 186. vetési utáni napja, ugyanis ekkor volt a legmagasabb a Pearson-féle korrelációs együttható ($r = 0,95$) $p \leq 0,001$ szignifikanciaszinten. Negatív értékek is megfigyelhetők a MicaSense kameránál a VUN 200-as időpontban, amely valószínűleg az NDVI értékek telítődése miatt következett be. A legmagasabb „Pearson r” értékek a különböző kezeléseknél eltérő időpontokban találhatók, azonban az NDVI értékek és a hozam közötti legerősebb korrelációk mindkét szenzor esetében a 170. VUN-nál és a 226. VUN-nál mutatkoztak.

15. táblázat: Pearson-féle korrelációelemzés a GreenSeeker (GS) és a MicaSense (MS) kamera adataiból kalkulált NDVI értékek és az őszi búza négy kezelésének (kontroll–Kon., környezetkímélő–Kör., mérleg–Mér., genezis–Gen.) hozama alapján.

| VUN | Kon. (GS) | Kon. (MS) | Kör. (GS) | Kör. (MS) | Mér. (GS) | Mér. (MS) | Gen. (GS) | Gen. (MS) |
|-----|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| 170 | 0,29 | 0,35 | 0,85** | 0,87** | 0,83* | 0,85** | 0,86** | 0,89** |
| 186 | 0,23 | 0,26 | 0,73* | 0,45 | 0,67 | 0,50 | 0,83* | 0,95*** |
| 200 | 0,36 | -0,08 | 0,88** | -0,09 | 0,85** | 0,29 | 0,89** | 0,30 |
| 212 | 0,49 | 0,27 | 0,88** | 0,10 | 0,87** | 0,52 | 0,90** | 0,63 |
| 226 | 0,32 | 0,68 | 0,87** | 0,87** | 0,95*** | 0,87** | 0,87** | 0,82* |
| 240 | 0,86** | 0,94*** | 0,67 | 0,57 | 0,82* | 0,83** | 0,73* | 0,67 |

Szignifikanciaszint: * $p \leq 0,05$; ** $p \leq 0,01$; *** $p \leq 0,001$. A korrelációs koefficiens mindegyik mérési pontnál és időpontnál $n=8$ -ra lett kikalkulálva.

Az NDVI értékek és az őszi búza terméshozama közötti összefüggések meghatározásához három különböző egyenletet (exponenciális (E), lineáris (L) és kvadratikus (Q)) alkalmaztam a 170. VUN és 240. VUN közötti időszakban (16. táblázat).

A GreenSeeker esetében a kontroll kezelésnél az NDVI értékek és az őszi búza hozama közötti legerősebb összefüggés ($r^2 = 0,70-0,86$, $p \leq 0,01$) a 240. VUN-on tapasztalható. Ezzel szemben a kvadratikus egyenlet 212. VUN-ot és 226. VUN-ot leszámítva, az összes mérési időpontban és egyenletnél nagyon gyenge vagy gyenge ($r^2 = 0,05-0,25$, $p \geq 0,05$) volt az NDVI értékek és a hozam adatok illeszkedésének mértéke.

A környezetkímélő ($r^2 = 0,43-0,45$) és a genezises ($r^2 = 0,53-0,57$) kezeléseknél a 240. VUN-on tapasztalható mérsékelt kapcsolat a GreenSeekerrel mért NDVI értékek és a hozam között, míg a mérleg kezelésnél ($r^2 = 0,42-0,75$) a 186. VUN-on. A többi mérési időpontban és egyenletnél minden esetben erős vagy nagyon erős összefüggés

állapítható meg. A hat felvételezési időpontból mindhárom kezelést figyelembe véve a 226. VUN-on születtek a legmagasabb determinációs együtthatókat ($r^2 = 0,76-0,91$, $p \leq 0,05$).

A GreenSeekerhez hasonlóan a MicaSense kamera adataiból kalkulált NDVI értékek és a hozam közötti összefüggés a 240. VUN-on volt a legerősebb a kontrol kezelésnél ($r^2 = 0,89-0,90$, $p \leq 0,01$). A 170. VUN és a 212. VUN közötti időintervallumban ez esetben is nagyon gyenge vagy gyenge volt a két változó közötti kapcsolat ($r^2 = 0-0,32$, $p \geq 0,05$). A MicaSense kamera által a környezetkímélő, mérleg és genezis parcellákról gyűjtött adatok alapján a 200. VUN-on és a 212. VUN-on is nagyon gyenge vagy gyenge ($r^2 = 0,1-0,37$, $p \geq 0,05$) volt az NDVI értékek és hozam illeszkedésének mértéke. Ellenben erős és nagyon erős volt a 170. VUN-on ($r^2 = 0,71-0,86$, $p \leq 0,05$) és a 226. VUN-on ($r^2 = 0,69-0,86$, $p \leq 0,05$). A kezelt parcellák közül a genezises kezelésnél volt a legerősebb összefüggés ($r^2 = 0,88$, $p \leq 0,001$) a MicaSense kamera adataiból kalkulált NDVI értékek és az őszi búza hozama között mindhárom egyenletnél.

A két szenzorból kinyert adatok összehasonlítása során a GreenSeeker mérésekből kapott NDVI értékek jóval megbízhatóbb adatokat szolgáltatnak a hozambecsléshez a szárbaindulás kezdetétől (BBCH-30) egészen a betakarítás előtti időszakig (BBCH 80-85). A 16. táblázat alapján minimális eltéréseket lehet megfigyelni a különböző egyenletek között, ezért mindkét szenzor esetében mindhárom modell alkalmazható a búza hozamának előrejelzésére a 226. VUN-on.

16. táblázat: Determinációs együtthatók (r^2) meghatározása a GreenSeeker optikai érzékelő, valamint a MicaSense kamera adataiból kalkulált NDVI értékek és az őszi búza eltérő kezeléseinek (kontroll, környezetkímélő, mérleg, genezis) hozama alapján három különböző egyenlet (exponenciális (E^1), lineáris (L^2), kvadratikus (Q^3)) segítségével.

| | | VUN | 170 | 186 | 200 | 212 | 226 | 240 |
|-------------|-----------------|--------|--------|---------|--------|--------|---------|---------|
| GreenSeeker | Kontroll | E^1 | 0,09 | 0,06 | 0,12 | 0,25 | 0,13 | 0,70** |
| | | L^2 | 0,09 | 0,05 | 0,11 | 0,23 | 0,11 | 0,70** |
| | | Q^3 | 0,09 | 0,09 | 0,16 | 0,47 | 0,61 | 0,86** |
| | Környezetkímélő | E^1 | 0,72** | 0,52* | 0,78** | 0,81** | 0,76** | 0,44 |
| | | L^2 | 0,73** | 0,53* | 0,89** | 0,80** | 0,77** | 0,43 |
| | | Q^3 | 0,74* | 0,78* | 0,82* | 0,81* | 0,82* | 0,45 |
| | Mérleg | E^1 | 0,81* | 0,42 | 0,68* | 0,74** | 0,90*** | 0,68* |
| | | L^2 | 0,70** | 0,44 | 0,70** | 0,77** | 0,91*** | 0,66** |
| | | Q^3 | 0,68* | 0,75* | 0,73* | 0,77* | 0,91** | 0,84** |
| Genezis | E^1 | 0,74** | 0,67* | 0,77** | 0,78** | 0,78** | 0,53* | |
| | L^2 | 0,75** | 0,80* | 0,78** | 0,79** | 0,79** | 0,53* | |
| | Q^3 | 0,76* | 0,68 | 0,85** | 0,80* | 0,79* | 0,57 | |
| MicaSense | Kontroll | E^1 | 0,13 | 0,32 | 0,00 | 0,07 | 0,50 | 0,90*** |
| | | L^2 | 0,12 | 0,09 | 0,00 | 0,06 | 0,48 | 0,89*** |
| | | Q^3 | 0,23 | 0,12 | 0,12 | 0,25 | 0,70 | 0,89** |
| | Környezetkímélő | E^1 | 0,74** | 0,19 | 0,08 | 0,04 | 0,79** | 0,37 |
| | | L^2 | 0,75** | 0,20 | 0,01 | 0,04 | 0,79** | 0,35 |
| | | Q^3 | 0,82* | 0,21 | 0,01 | 0,30 | 0,86** | 0,38 |
| | Mérleg | E^1 | 0,71** | 0,28 | 0,07 | 0,28 | 0,79** | 0,71** |
| | | L^2 | 0,72** | 0,29 | 0,08 | 0,28 | 0,78** | 0,87* |
| | | Q^3 | 0,80* | 0,88** | 0,20 | 0,28 | 0,79** | 0,69 |
| | Genezis | E^1 | 0,78* | 0,88*** | 0,15 | 0,37 | 0,69* | 0,47 |
| | | L^2 | 0,79** | 0,88*** | 0,15 | 0,37 | 0,69* | 0,47 |
| | | Q^3 | 0,86** | 0,88*** | 0,15 | 0,37 | 0,69* | 0,48 |



¹exponenciális egyenlet és képlete: $y_{\text{yield}} = a \times e^{b \times \text{xNDVI}}$; ²lineáris egyenlet és képlete $y_{\text{yield}} = a \times \text{xNDVI} + b$; ³kvadratikus egyenlet és képlete $y_{\text{yield}} = a \times \text{xNDVI}^2 + b \times \text{xNDVI} + c$. *Szignifikanciaszint $p \leq 0,05$; ** szignifikanciaszint $p \leq 0,01$; *** szignifikanciaszint $p \leq 0,001$.

4.1.6. Őszi búza hozambecslése NDVI értékek alapján

A 16. táblázat eredményei alapján mindkét szenzor esetében a 226. VUN-on határozható meg legpontosabb az őszi búza várható hozama. Ezt az időpontot kiválasztva vizsgáltam tovább a négy eltérő kezelés NDVI értékei és az őszi búza hozama közötti összefüggést. Az elemzés során a 2021-22-es és a 2022-23-as év adatait kezelésenként összevontan. A kezelésenként elért eredményeket három különböző egyenlet (lineáris, exponenciális és kvadratikus) alkalmazásával (28-30. ábra) szemléltettem.

A lineáris egyenletnél a GreenSeeker mérések esetében (28a. ábra) a kontroll kezelésnél volt megfigyelhető a leggyengébb összefüggés ($r^2 = 0,15$; RMSE = 0,89 kg) a mért NDVI értékek és a hozam között. Ellenben a legerősebb összefüggés a környezetkímélő kezelésnél ($r^2 = 0,78$; RMSE = 0,65 kg) tapasztaltam. A négy kezelés egységesítésekor mérsékelt ($r^2 = 0,54$; RMSE = 3,29 kg) volt az adatok illeszkedésének mértéke.

A MicaSense kameránál (28b. ábra) is a kontroll kezelésnél figyelhető meg a leggyengébb összefüggés ($r^2 = 0,15$; RMSE = 0,89 kg), míg a legerősebb a genezis kezelésnél ($r^2 = 0,78$; RMSE = 0,73 kg) látható. A négy kezelés összevonásakor szintén mérsékelt ($r^2 = 0,53$; RMSE = 3,21 kg) az NDVI értékek és a hozam adatok illeszkedése.





28. ábra: Az őszi búza hozama és a kalkulált NDVI értékek közötti kezelésenkénti (kontroll, környezetkímélő, mérleg, génezis) összefüggések. A vizsgált két év adatai összevontan szerepelnek. (a) GreenSeeker lineáris egyenlet, (b) MicaSense lineáris egyenlet.

Az exponenciális egyenlet kézi szenzoros vizsgálatánál (29c. ábra) szintén a kontroll kezelésnél állapítottam meg a leggyengébb

összefüggést ($r^2 = 0,15$; $RMSE = 0,88$ kg) a kalkulált NDVI értékek és a kapott terméseredmények között. A legerősebb összefüggés viszont már a Genezis kezelésnél ($r^2 = 0,83$; $RMSE = 0,64$ kg) figyelhető meg. A kezelések összevonásakor a determinációs együttható ugyanannyi ($r^2 = 0,54$) lett, mint a lineáris egyenletnél, azonban ehhez magasabb átlagos négyzetgyökhiba ($RMSE = 4,11$ kg) társult.

A MicaSense multispektrális kamera adataiból kalkulált NDVI értékek és hozam közötti összefüggések exponenciális egyenlettel történő elemzésénél (29d. ábra) ugyanazok a kezelések teljesítettek nagyon gyengén (kontroll: $r^2 = 0,15$; $RMSE = 0,89$ kg) és erősen (genezis: $r^2 = 0,78$; $RMSE = 0,73$ kg), mint a lineáris modellnél. A kezelések egységesítésekor az NDVI értékek és a hozam adatok illeszkedése mérsékelt ($r^2 = 0,54$; $RMSE = 4,13$ kg) volt.






29. ábra: Az őszi búza hozama és a kalkulált NDVI értékek közötti kezelésenkénti (kontroll, környezetkímélő, mérleg, genezis) összefüggések. A vizsgált két év adatai összevontan szerepelnek. (c) GreenSeeker exponenciális egyenlet, (d) MicaSense exponenciális egyenlet.


Végül a GreenSeekeres NDVI értékek kvadratikus egyenlettel (30e. ábra) történő vizsgálatánál is a kontroll kezelés adatai mutatták ($r^2 = 0,21$; $RMSE = 0,85$ kg) a leggyengébb illeszkedést. A legerősebb összefüggést szintén a Genezis kezelésnél ($r^2 = 0,85$; $RMSE = 0,60$ kg) kaptam. A különböző kezelések összevonásakor az $r^2 = 0,54$, míg az $RMSE = 4,10$ kg lett.

A MicaSense adatainak a kvadratikus egyenlettel történő elemzésénél (30f. ábra) a másik két egyenlethez hasonlóan, a kontroll kezelés érte el a legalacsonyabb determinációs együtthatót ($r^2 = 0,17$; $RMSE = 0,88$ kg), míg a legmagasabbat a genezis ($r^2 = 0,78$; $RMSE = 1,34$ kg) kezelésnél tapasztaltam. A kezelések összevonásakor mérsékelt ($r^2 = 0,54$; $RMSE$

= 4,11 kg) összefüggést állapítottam meg az NDVI értékek és a hozam között.

Összegzésként, mindhárom egyenlet és szenzor tekintetében a kontroll parcellák mutatták a leggyengébb összefüggést a NDVI értékek és a betakarított hozam között. Ezt az eredményt erősítette meg korábban a Pearson-féle korrelációelemzés (15. táblázat) és a regresszióelemzés (16. táblázat) is. A kezelések összevont elemzésénél mindhárom modellnél hasonló ($r^2 = 0,53-0,54$) összefüggés látható a hozam adatok és az NDVI értékek között. Azonban az átlagos négyzetgyökhiba vizsgálatánál – a három egyenlet közül – a lineáris modellel lehetett a legalacsonyabb értékeket elérni a GreenSeeker (RMSE = 3,29 kg) és a MicaSense kamera (RMSE = 3,21 kg) esetében is.





30. ábra: Az őszi búza hozama és a kalkulált NDVI értékek közötti kezelésenkénti (kontroll, környezetkímélő, mérleg, genezis) összefüggések. A vizsgált két év adatai összevontan szerepelnek. (e) GreenSeeker kvadratikus egyenlet, (f) MicaSense kvadratikus egyenlet.

4.1.7. Hozambecslési egyenlet kiegészítése a VUN és a KNFHÖ értékekkel

A 27a. ábra kezelésenként, az évek közötti terméskülönbséget ábrázolja úgy, hogy mind a négy kezelés, mind a két évben ugyanazt a tápanyagmennyiséget kapta alap- és fejtrágya formájában. Ez alapján (27a. ábra) a hozameredményeket jelentősen módosítják a különböző időjárási körülmények. Ezért a hozampredikciós-modell javítása céljából (31-33. ábra) kumulált napi fejlődési hőmérsékleti összeg (KNFHÖ) és vetés utána napok (VUN) bevonásával fejleszttem tovább a modellt. A 31-33. ábra szemlélteti a három hozampredikciós



egyenletet, szenzorokra és évekre bontva. A különböző kezelések adatai évenkénti csoportosításban szerepelnek.

A 2021-22-es vegetációs periódusban a 226. VUN-on $819,1^{\circ}\text{C}$ volt a kumulált napi fejlődési hőmérsékleti összeg, míg a 2022-23-as időszakban már jóval magasabb, $964,2^{\circ}\text{C}$ volt ez az érték.

Azonban a VUN száma – amikor a napi fejlődési hőmérsékleti összeg > 0 – már az első mérési időponttól kezdve azonosak voltak (170 nap) mind a két felvételezési évben.

A lineáris KNFHÖ értékekkel bővített (31a. ábra) hozampredikációs egyenletnél a GreenSeeker méréseknél jóval magasabb determinációs együttható ($r^2 = 0,71$) és alacsonyabb RMSE = 1,63 kg értékeket kaptam, mint a MicaSense kamera adatai ($r^2 = 0,16$; RMSE = 2,77 kg) alapján a két év adatainak összesítésekor. Mindkét szenzor esetében a 2022-23-as esztendőben látható erős (MicaSense: $r^2 = 0,69$; RMSE = 1,72 kg) és nagyon erős (GreenSeeker: $r^2 = 0,90$; RMSE = 0,97 kg) összefüggés a hozamok és a NDVI/KNFHÖ értékek között.

A lineáris VUN adatokkal kibővített (31b. ábra) modellnél a két vizsgált év összevonásakor már jóval kiegyenlítettebb eredmények születtek a GreenSeeker ($r^2 = 0,54$; RMSE = 2,06 kg) és a MicaSense kamera ($r^2 = 0,53$; RMSE = 2,07 kg) adatainak összehasonlításánál. Azonban a 2022-23-as vegetációs periódust figyelembe véve, már jóval pontosabban prediktálható a GreenSeekerrel ($r^2 = 0,90$; RMSE = 0,57 kg) a várható hozam, mint a MicaSense multispektrális kamerával ($r^2 = 0,69$; RMSE = 1,72 kg).





31. ábra: KNFHÖ és VUN adatokkal módosított lineáris (a,b) hozampredikciós egyenlet a GreenSeeker (GS) és a MicaSense (MS) adataiból kalkulált NDVI értékek alapján. Az ábrák mindkét szenzor esetében a 2021-22-es és a 2022-23-as időszak mérési eredményeit szemléltetik. A KNFHÖ és a VUN értékek a vetéstől az adatgyűjtés időpontjáig a kumulált napi fejlődési hőmérsékleti összeget és az eltelt

napok számát fejezik ki, amikor a napi fejlődési hőmérsékleti összeg (NFHÖ) > 0.

A KNFHÖ értékekkel bővített exponenciális egyenletnél (32c. ábra) a lineáris modellhez hasonlóan, két év adatainak egyesítésekor a GreenSeeker magasabb determinációs együttható ($r^2 = 0,71$) és alacsonyabb RMSE = 1,62 kg értékeket mutat, mint a MicaSense kamera adatai ($r^2 = 0,15$; RMSE = 2,80 kg). Évenkénti bontásban itt is a 2022-23-as időszakban állapítható meg pontosabban a GreenSeeker ($r^2 = 0,89$; RMSE = 1,02 kg) és a MicaSense kamera ($r^2 = 0,68$; RMSE = 1,76 kg) adatai alapján a hozamok és a NDVI/KNFHÖ értékek illeszkedésének mértéke.

Az exponenciális VUN adatokkal bővített (32d. ábra) hozampredikációs-modellnél a két vizsgált időszak összevonásakor azonos eredmények láthatók mind a két szenzor tekintetében ($r^2 = 0,54$; RMSE = 2,06 kg). Évenkénti bontásnál, a 2022-23-as évben a GreenSeekerrel ($r^2 = 0,89$; RMSE = 1,02 kg) hatékonyabban határozható meg a várható hozam, mint a MicaSense kamera ($r^2 = 0,68$; RMSE = 1,76 kg) alkalmazásával.



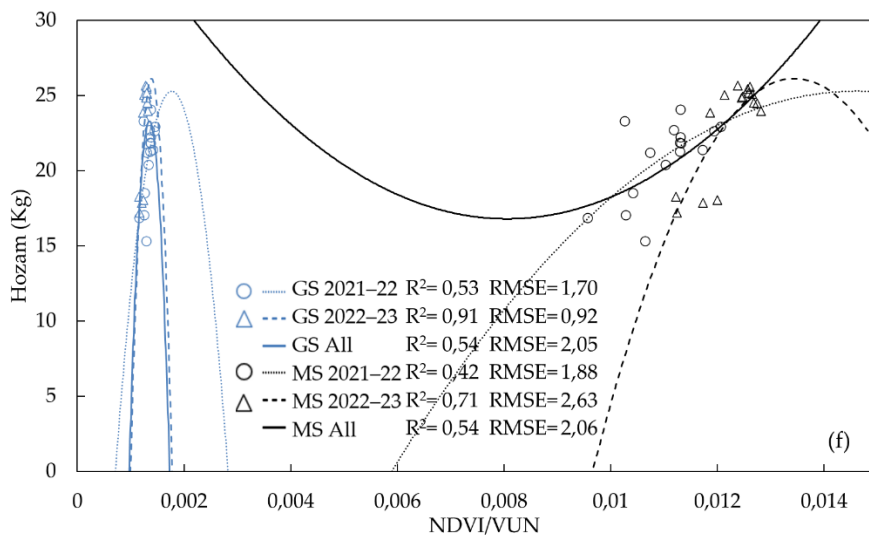

32. ábra: KNFHÖ és VUN adatokkal módosított exponenciális (c,d) hozampredikációs egyenlet a GreenSeeker (GS) és a MicaSense (MS) adataiból kalkulált NDVI értékek alapján. Az ábrák mindkét szenzor esetében a 2021-22-es és a 2022-23-as időszak mérési eredményeit szemléltetik. A KNFHÖ és a VUN értékek a vetéstől az adatgyűjtés időpontjáig a kumulált napi fejlődési hőmérsékleti összeget és az eltelt

napok számát fejezik ki, amikor a napi fejlődési hőmérsékleti összeg (NFHÖ) > 0.

A kvadratikus KNFHÖ értékekkel módosított (33e. ábra) egyenlet esetében a kétéves kutatási időszak adatainak összevonásakor is a GreenSeeker adatok ($r^2 = 0,71$; RMSE = 4,36 kg) bizonyultak alkalmasabbnak hozampredikációs célokra a MicaSense kamera adataival ($r^2 = 0,32$; RMSE = 66,5 kg) szemben.

Mindkét szenzor esetében a 2022-23-as esztendőben erős (MicaSense: $r^2 = 0,71$; RMSE = 2,38 kg) és nagyon erős (GreenSeeker: $r^2 = 0,92$) összefüggés állapítható meg a hozamok és a NDVI/KNFHÖ értékek között. Azonban a GreenSeekernél már jóval magasabb RMSE = 5,24 kg értékeket kaptam, mint a lineáris és az exponenciális modelleknél.

A kvadratikus VUN adatokkal módosított (33f. ábra) modellnél a két vizsgált év összevonásakor a GreenSeeker esetében $r^2 = 0,54$; RMSE = 2,05 kg, míg a MicaSense kamera adatai alapján $r^2 = 0,54$; RMSE = 2,06 kg értékek figyelhetők meg. A 2022-23-as időszakban a GreenSeekerrel ($r^2 = 0,91$; RMSE = 0,92 kg) kisebb hibaszázalékkal prediktálható a várható termés hozam, mint a MicaSense multispektrális kamera ($r^2 = 0,71$; RMSE = 2,63 kg) adatai alapján.



33. ábra: KNFHÖ és VUN adatokkal módosított kvadratikus (e,f) hozampredikációs egyenlet a GreenSeeker (GS) és a MicaSense (MS) adataiból kalkulált NDVI értékek alapján. Az ábrák mindkét szenzor esetében a 2021-22-es és a 2022-23-as időszak mérési eredményeit szemléltetik. A KNFHÖ és a VUN értékek a vetéstől az adatgyűjtés

időpontjáig a kumulált napi fejlődési hőmérsékleti összeget és az eltelt napok számát fejezik ki, amikor a napi fejlődési hőmérsékleti összeg (NFHÖ)>0.

Az eredmények alapján elmondható, hogy a vizsgált két év adatainak összevonásakor a GreenSeeker esetében a KNFHÖ értékek javíthatják a hozamelőrejelzés-modellek pontosságát. A GreenSeeker és MicaSense kamera esetében is a 2022-23-as időszakban erős összefüggés állapítható meg a hozam és NDVI/KNFHÖ értékek között. A három egyenlet összehasonlításánál a kvadratikus egyenletnél nagymértékben nőttek az átlagos négyzetgyökhibák (RMSE = 2,38-66,5 kg), míg az exponenciális (RMSE = 1,02-2,80 kg) és a lineáris (RMSE = 0,97-2,77 kg) modellnél jóval alacsonyabb értékeket kaptam. A VUN értékekkel módosított hozampredikciós egyenleteknél minimális eltérések voltak tapasztalhatók a két szenzor és a különböző egyenletek között. Évenkénti bontásnál a 2022-23-as vegetációs periódus volt alkalmasabb az őszi búza hozamának becsléséhez. Azonban két év mérési adatainak egyesítésekor mind a két szenzorral mérsékelten ($r^2 = 0,53-54$) lehetett meghatározni a várható hozamot. Ezzel szemben a KNFHÖ lineáris modell alkalmazásánál a GreenSeeker determinációs együtthatója $r^2 = 0,71$ lett, így a további számításokat a lineáris modell KNFHÖ értékekkel módosított egyenletével végeztem. A modellből a legmagasabb determinációs együtthatókkal és legalacsonyabb RMSE értékekkel rendelkező szenzor értékeivel validáltam a hozampredikciós modellt.

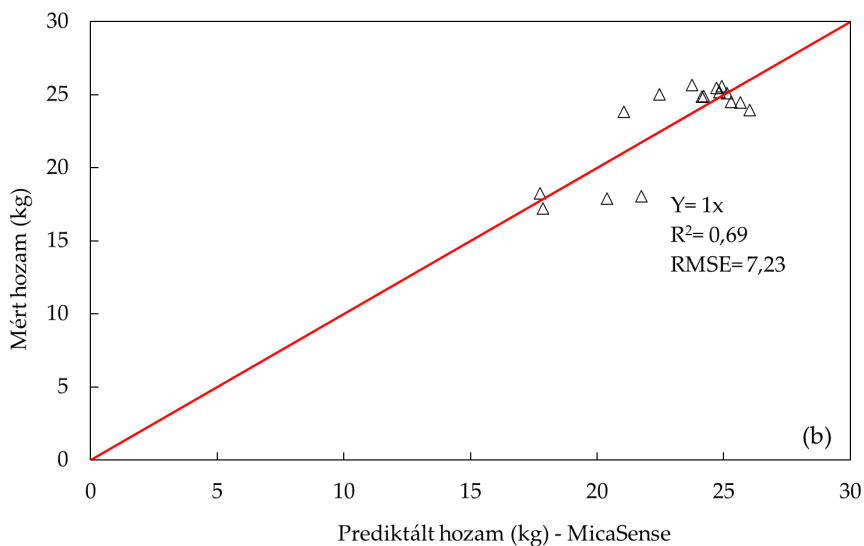
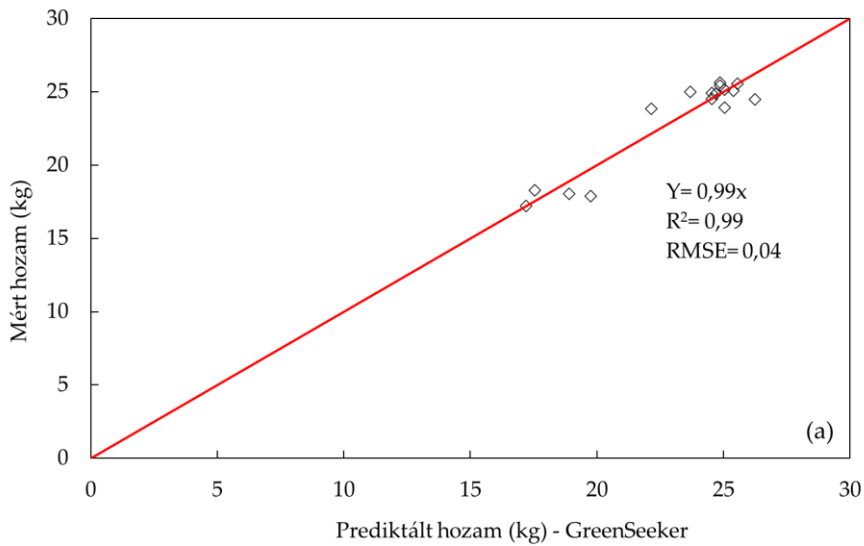
4.1.8. Modell validáció

Az előző fejezetben bemutatott eredmények alapján a két szenzor (GreenSeeker és MicaSense) NDVI értékeinek kumulált napi fejlődési hőmérsékleti összeggel (KNFHÖ) módosított lineáris egyenletével határozható meg legpontosabban a várható terméshozam (17. táblázat) a vetéstől számított 226. napon, amikor a napi fejlődési hőmérsékleti összeg > 0 . A GreenSeekeres hozampredikációs-modell nagyon erős összefüggést ($r^2 = 0,90$) és viszonylag alacsony RMSE-t (0,97) mutatott. A MicaSense kamera hozamelőrejelzési-modelljében (17. táblázat) is erős a két változó illeszkedésének mértéke, azonban itt már magasabb RMSE (1,72) értékek láthatók. A hozampredikációs-modellek validálási eredményei alapján (34. ábra) a GreenSeekeres mérésekkel jóval pontosabban (RMSE = 0,04) lehet előre jelezni az őszi búza várható hozamát, mint MicaSense kamerával (RMSE = 7,23) végzett felmérések esetében.

17. táblázat: Regressziós együtthatók (a, b), determinációs együttható (r^2) és átlagos négyzetgyökhiba (RMSE) használata az őszi búza hozampredikációs-modelljének kialakításához két szenzor esetében.

| | Növény index | Felvételezés ideje | R^2 | Regressziós paraméterek ^a | | RMSE |
|--|--------------|--------------------|-------------------|--------------------------------------|---------|------|
| | | | | a | b | |
| Hozam-predikációs modell (GreenSeeker) | NDVI/KNFHÖ | 226. VUN | 0,90 [*] | 34206 | -11,483 | 0,97 |
| Hozam-predikációs modell (MicaSense) | NDVI/KNFHÖ | 226. VUN | 0,69 [*] | 50110 | -40,336 | 1,72 |

^a Regressziós paraméter, várható hozam = $a \times e^b \times \text{indexérték}$. Az integrált hozampredikációs-modell négy kezelés (kontroll, környezetkímélő, mérleg, genezis) és két érzékelő (GreenSeeker, MicaSense kamera) adataiból épült fel, amelyek a 2021-22-es és a 2022-23-as vegetációs periódusban lettek begyűjtve. * $p \leq 0,001$



34. ábra: Őszi búza várható hozamának becslésére szolgáló lineáris hozampredikációs-modell, amelyen a mért és prediktált hozama közötti kapcsolatot mutatja meg (a) GreenSeeker adatai (b) MicaSense kamera adatai alapján.

4.2. Fenyőmajori kísérlet

4.2.1. GreenSeeker, Phantom 4 és MicaSense kamera adataiból kalkulált NDVI értékek összehasonlítása

Eredményeim alapján ($p \leq 0,001$) a Phantom 4 és a MicaSense kamera NDVI értékei 2023. május 5-e kivételével ($r^2 = 0,73$) minden esetben nagyon erős összefüggéseket ($r^2 \geq 0,95$) mutattak (18. táblázat). Azonban a Phantom 4 és a MicaSense multispektrális kamerák adataiból kalkulált NDVI értékeinek a GreenSeeker kézi szenzor NDVI értékeivel való összehasonlítása – mindegyik időpontra vonatkoztatva – 0,24 és 0,76 közötti determinációs együtthatókat eredményeztek (18. táblázat). Mint a két drón összevetésénél, a GreenSeeker és a multispektrális kamerák összehasonlítása során is 2023. május 5-én gyengén ($r^2 \leq 0,26$) illeszkednek egymáshoz az NDVI értékek a 18. táblázat alapján. Ez annak tulajdonítható, hogy ebben a fejlődési periódusban volt a legnagyobb az őszi búza zöldtömege, ezért az érzékelők már kevésbé tudtak különbséget detektálni a gyengébben és erősebben fejlett vegetáció között (Sellers, 1985; Gitelson et al., 2002; Gu et al., 2013; Cao et al., 2016; Goffart et al., 2022). A legmagasabb determinációs együtthatók 2023. június 16-án figyelhető meg a Phantom 4 és a kézi szenzor esetében ($r^2 = 0,76$), míg a MicaSense kamera és a GreenSeeker vizsgálatánál 2023. április 12-én ($r^2 = 0,70$).

18. táblázat: Regresszióelemzés ($n = 225$) a MicaSense (MS) és a Phantom 4 (P4) multispektrális kamera, valamint a GreenSeekeres (GS) mérések adataiból kalkulált NDVI értékek alapján négy eltérő időpontban.

| Eszközök | Felvételezés időpontja | | | |
|----------|------------------------|---------------|---------------|---------------|
| | 2023. 04. 12. | 2023. 05. 05. | 2023. 05. 22. | 2023. 06. 16. |
| GS-MS | 0,70* | 0,24* | 0,62* | 0,69* |
| GS-P4 | 0,66* | 0,26* | 0,66* | 0,76* |
| P4-MS | 0,95* | 0,73* | 0,96* | 0,95* |

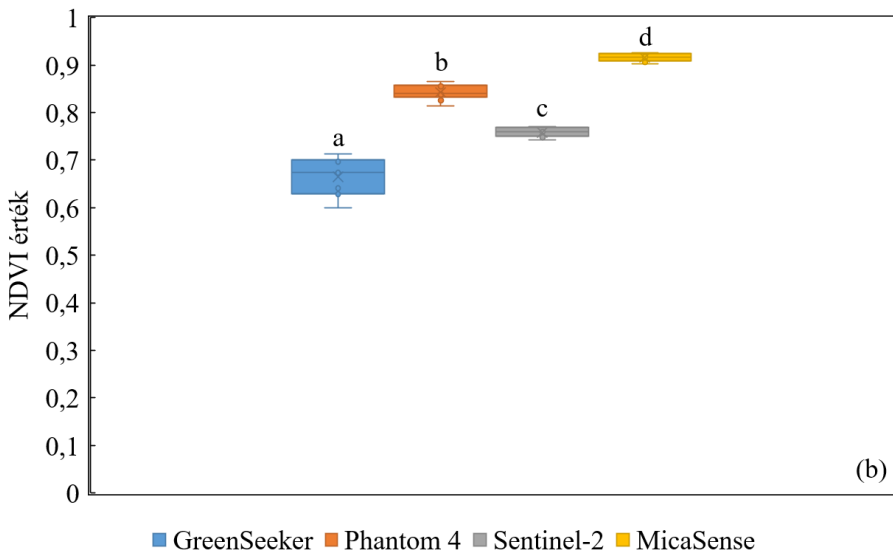
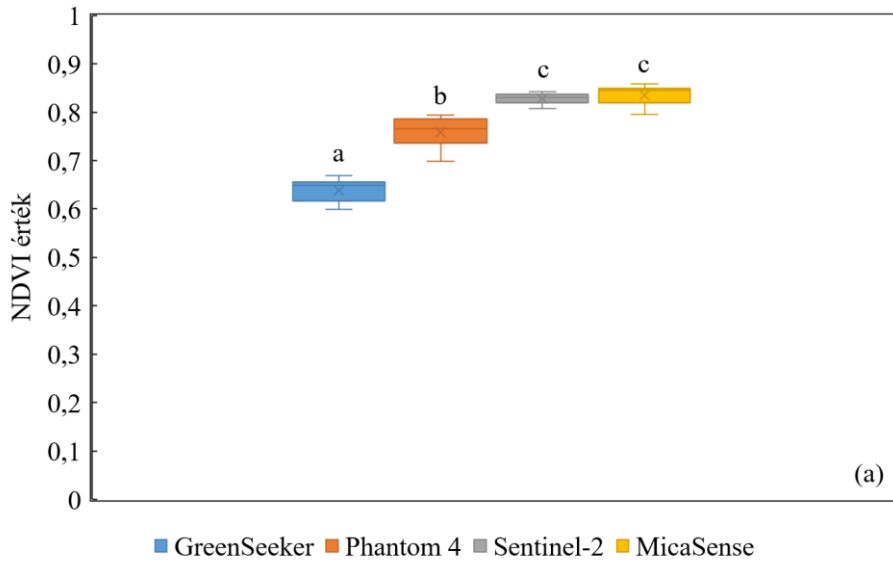
* $p \leq 0,001$

4.2.2. Négy szenzor adataiból kalkulált NDVI értékek összehasonlítása

A regresszióelemzést követően Tukey-féle post hoc teszttel vizsgáltam (35. ábra) a négy szenzor (GreenSeeker, Phantom 4 és MicaSense multispektrális kamera, Sentinel-2) adataiból kalkulált átlag NDVI értékeket. Mivel a Sentinel-2 műhold rendelkezett a legalacsonyabb térbeli felbontással (10×10 méter / pixel), ezért minden mérési időpontban 9 mintaszámmal ($n = 9$) tudtam számolni.

Méréseim alapján az egy időben végzett felvételezések során a legtöbb esetben eltérő NDVI értékeket kaptam a különböző szenzorok egymással történő összehasonlításánál. A legnagyobb különbség 2023. május 5-én volt tapasztalható (35b. ábra). Ekkor mind a négy szenzor adatából számított NDVI értékek között (35b. ábra) szignifikáns különbséget lehetett megállapítani $p \leq 0,05$ szignifikanciaszinten. 2023. április 12-én (35a. ábra) a MicaSense kamera és a Sentinel-2 műhold

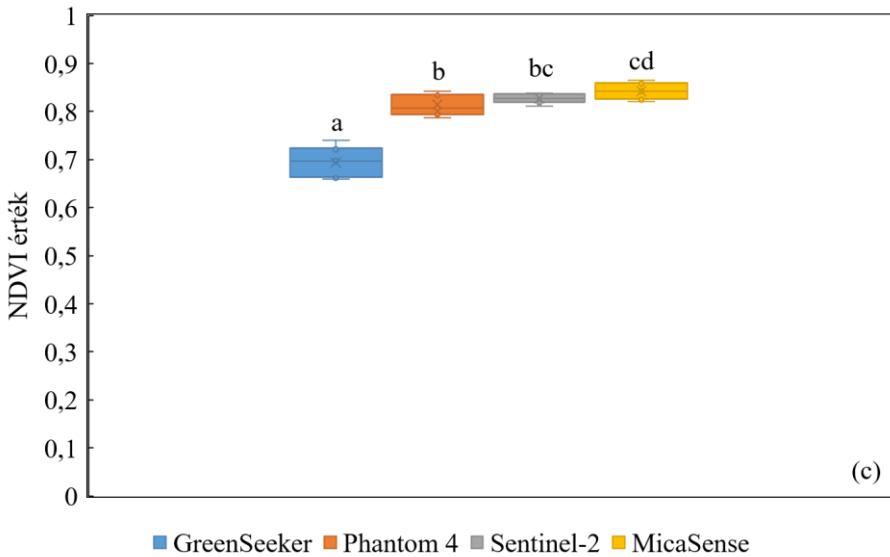
NDVI értékei között nem volt szignifikáns különbség ($p \geq 0,05$) tapasztalható.

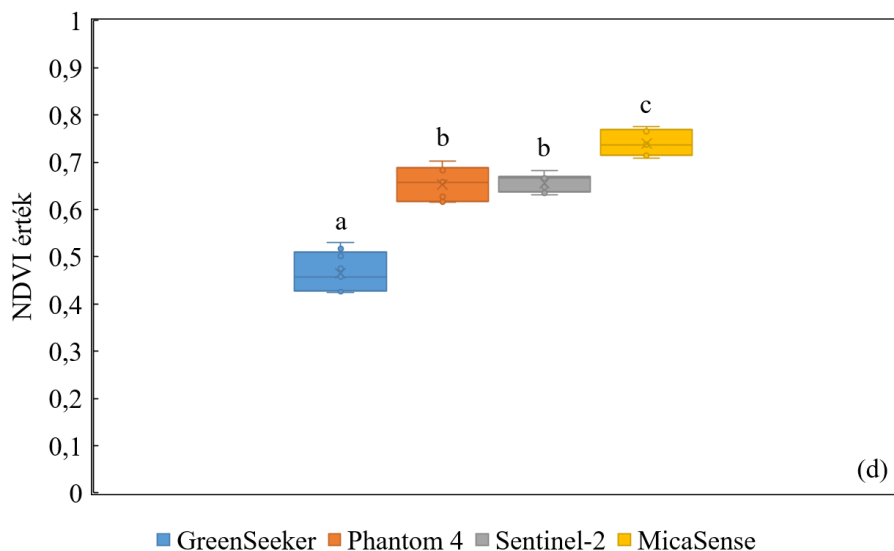


35. ábra: A négy különböző szenzor két időpontban (2023. április 12. (a), 2023. május 5. (b)) kalkulált átlag NDVI értékei ($n = 9$). Az eltérő

betűjelek a szenzorok adataiból számított átlag NDVI értékek szignifikanciáját ábrázolja, Tukey-féle HSD post-hoc teszttel kimutatva $p \leq 0,05$ szignifikanciaszinten.

2023. június 16-án (36d. ábra) a Phantom 4 multispektrális kamera és a Sentinel-2 műhold adataiból nyert NDVI értékek sem mutattak szignifikáns különbséget $p \geq 0,05$ szignifikanciaszinten. A négy felvételezési időpontot tekintve, az NDVI értékek közötti legnagyobb kapcsolatot ($p \leq 0,05$) 2023. május 22-én lehetett tapasztalni (36c. ábra), ekkor a Phantom 4 és a MicaSense multispektrális kamera sem mutatott szignifikáns különbséget ($p \geq 0,05$) a Sentinel-2 műhold adataiból számított NDVI értékekkel.






36. ábra: A négy különböző szenzor két időpontban (2023. május 22. (c), 2023. június 16. (d)) kalkulált átlag NDVI értékei ($n = 9$). Az eltérő betűjelek a szenzorok adataiból számított átlag NDVI értékek szignifikanciáját ábrázolja, Tukey-féle HSD post-hoc teszttel kimutatva $p \leq 0,05$ szignifikanciaszinten.

4.2.3. GreenSeeker és Sentinel-2 műhold adataiból számított NDVI értékek összehasonlítása


A két szenzor NDVI értékének determinációs együtthatója alapján történő összehasonlítása során a mintavételezések számának növelése minimálisan ($r^2 \leq 0,003$) befolyásolta a két adat közötti összefüggést (37. ábra). Ezen eredmények alapján a GreenSeekeres mérések számának emelésével javuló tendencia figyelhető meg (37. ábra) a hatodik mérési pontig, azonban ezt követően már nem javult a modell a mintaszámok növelésével.



coefficient of determination (r^2)=determinációs együttható (r^2); number of field measurements per pixel=pixelen belüli mérések száma

37. ábra: A GreenSeeker mérések (1-25-ig) és a Sentinel-2 műhold adataiból kinyert pixelenkénti NDVI értékek összehasonlítása és determinációs együtthatói.

A determinációs együttható mellett az elemzések átlagos négyzetgyökhibáját (RMSE) is kiszámoltam mintánkénti 1000 ismétlésben (38. ábra). Az RMSE értékek tekintetében szintén a hatodik mérési pontig lehet egy csökkenő tendenciát megfigyelni, majd a mérési számok növekedésével ezen értékek csökkenési görbéje is ellaposodik.



*root mean square error (RMSE)=átlagos négyzetgyökhiba (RMSE);
number of field measurements per pixel=pixelen belüli mérések száma*

38. ábra: A GreenSeeker mérések (1-25-ig) és a Sentinel-2 műhold adataiból kinyert pixelenkénti NDVI értékek összehasonlítása és átlagos négyzetgyökhibája (root mean square error – RMSE).

5. KÖVETKEZTETÉSEK ÉS JAVASLATOK

A bemutatott vizsgálati eredmények alapján a következő megállapításokat teszem.

5.1. A GreenSeeker és a MicaSense NDVI értékek összehasonlítása

A 14. táblázat eredményei alapján a kontroll parcellákban mért NDVI értékek szignifikánsan ($p \leq 0,05$) eltérnek a környezetkímélő, mérleg és genezis parcellákban mért NDVI értékektől. Ezzel szemben a környezetkímélő, mérleg és genezis kezelések NDVI-értékei szignifikánsan ($p \geq 0,05$) nem tértek el egymástól. A három kezelésre kijuttatott nitrogén-hatóanyag mennyiség közel azonos volt (4. táblázat), de eltérő mennyiségű foszfor-műtrágyában, míg a genezis kezelés kálium-műtrágyában is részesültek a területek (4. táblázat). Azonban ezeket a differenciákat az őszi búza a növekedése során kompenzálni tudhatta (He et al., 2007), emiatt lehetett csekély eltérés a a kezelések között kontrollt leszámítva.

Az elért eredmények rávilágítanak, hogy a szenzorválasztásnak is nagy szerepe van a várható hozamok meghatározásánál. Ugyanis a zászlóslevél megjelenés és a kalászhányás kezdete (BBCH 37-50) közötti időszakban a GreenSeeker kézi optikai érzékelő szignifikáns különbséget ($p \leq 0,05$) képes kimutatni a kezelések között (14. táblázat), míg a légi felvételeken alapuló NDVI értékekkel ez nem lehetséges. Ennek oka, hogy a MicaSense kamera adataiból számított NDVI értékek körülbelül 0,2-vel magasabbak voltak, mint a GreenSeekeré. Emiatt az NDVI értékek közelítettek egy telítettségi ponthoz, ahol az

érzékelő már nem képes egy adott érték felett különbséget detektálni a növényi zöldtömegek között, még akkor sem, ha azok tovább fejlődnek. Sellers (1985), Gitelson et al. (2002), Gu et al. (2013), Cao et al. (2016) Goffart et al. (2022) is erre a jelenségre hívják fel a figyelmet kutatásukban, míg Goffart et al. (2022) hasonló problémába ütköztek az őszi búza felvételezése során és egy másik vegetációs index (pl. Normalized Difference Index – NDI) alkalmazását javasolták ebben a kritikus fejlődési szakaszban.

A kritikus felvételezési időszakokban tehát érdekesebb egy másik vegetációs indexet (pl. NDI vagy NDRE) alkalmazni, amely az NDVI-nál érzékenyebben képes detektálni nagy zöldtömeg esetén is a különbségeket.

5.2. Hozampredikció az NDVI értékek alapján

A Pearson-féle korrelációs elemzések (15. táblázat) alapján mindkét érzékelő (GreenSeeker, MicaSense) alkalmas a várható termésmennyiségek meghatározására a szárbaindulás (170. VUN / BBCH 30-32) és a szemképződés (226. VUN / BBCH 70-75) időszakában. A kontroll kezelések kivétel nagyon erős kapcsolatot állapítottam meg a 170. VUN-on ($r = 0,83-0,89$) és a 226. VUN-on ($r = 0,82-0,95$) $p \leq 0,05$ szignifikanciaszinten.

Ezeket a megállapításokat több búzában készült tanulmány is megerősítette. Royo et al. (2003) vizsgálatai alapján a tejesérés időszakában (BBCH 75) becsülhető meg legpontosabban ($r^2 = 0,95$; $p \leq 0,001$) NDVI értékek alapján a várható hozam. Guan et al. (2019) erős összefüggést ($r^2 = 0,61-0,81$; $p \leq 0,001$) állapítottak meg a virágzás

és a korai érés időszakában (BBCH = 60-82). Naser et al. (2020) eredményeikben a virágzás és a tejesérés (BBCH = 61-75) közötti periódusban érték el a legmagasabb ($r = 0,91$; $p \leq 0,05$) korrelációs együtthatót. Azonban tanulmányukban arra is felhívták a figyelmet, hogy öntözött körülmények között nem alkalmas a GreenSeeker a hozambecslésre az előző fejezetben ismertetett NDVI telítődés miatt. Walsh et al. (2023) ellenben a szárbaindulás időszakában (BBCH 30) érték el a legerősebb korrelációt a GreenSeeker ($r = 0,56$, $p \leq 0,05$) és az UAV ($r = 0,66$, $p \leq 0,05$) adataiból kalkulált NDVI értékek alapján is. A Pearson-féle korrelációelemzés alapján a Mosoni-síkon a szemképződés (BBCH 70-75) időszakában a legerősebb az NDVI értékek és a várható hozamok közötti kapcsolat, így az őszi búza ezen fejlődési szakaszában érdemes hozambecslést végezni.

5.3. Hozampredikciós egyenletek alkalmazása

Számos szerző, Raun et al., (2001), Ratjen et al., (2012), Kogan et al., (2013) és Almeida-Ñauñay et al., (2023) lineáris és nem lineáris egyenleteket alkalmaztak az őszi búza várható hozamának meghatározására. Vizsgálataim során (16. táblázat) a lineáris és az exponenciális egyenletek sok esetben jelentősen eltértek a kvadratikus egyenleteknél kapott eredményektől a különböző kezelések hozamainak prediktálása során. A vizsgálati eredmények döntő többségében a kvadratikus egyenlet érte el a legmagasabb determinációs együttható értékeket mindkét szenzor esetében, míg a lineáris és az exponenciális egyenletek alacsonyabb értékeket reprezentáltak.

Azonban az időjárás tényezőkkel módosított (31-33. ábra) modelleknél már a lineáris egyenletek mutatták a legmegbízhatóbb hozampredikációs eredményeket. Ezért a lineáris egyenlettel végeztem el a további számításokat az exponenciális és a kvadratikus egyenletek helyett. Több kutatás is megerősítette ezt a döntést. Lineáris egyenlettel vizsgálták a búza hozama és az NDVI közötti kapcsolatot.

Magneya et al. (2016) kétéves kísérletükben különböző időpontokban lineáris modell alkalmazásával elemezték az NDVI értékek és a búza hozama közti összefüggést. Eredményeikben rámutatnak, hogy a kalászhányás időszakában ($r^2 = 0,67$; $p \leq 0,05$) prediktálható a legjobban a várható terméseredmény. Lineáris hozambecslést végeztek Almeida-Ñauñay et al. (2023) az őszi búza 2 nóduszos, (BBCH 32), zászlóslevél kiterülése (BBCH 39) és a teljes virágzás (BBCH 65) időszakában. Méréseik alapján a BBCH 39 fejlődési fázisban a legerősebb az összefüggés ($r^2 = 0,58$) a NDVI értékek és a hozam között. Szintén lineáris modellel végeztek hozambecslést őszi káposztarepcében (*Brassica napus* L.), amely eredményeként erős korrelációt ($r = 0,70$; $p \leq 0,05$) állapítottak meg az NDVI értékek és a repce hozama között (Lukas et al., 2022).

Ellenben Raun et al. (2001) lineáris, kvadratikus, logaritmikus és exponenciális modellek alkalmazásával határozták meg az őszi búza várható hozamát. Két éves, hat helyszíni méréseik alapján az exponenciális modellel tudták a legpontosabban ($r^2 = 0,83$, $p \leq 0,0001$) meghatározni a becsült hozamot. Szintén exponenciális modell alkalmazásával végeztek hozampredikációs vizsgálatokat 2002 és 2005 között kukoricában. A kukorica nyolc leveles állapotában volt a

legerősebb az NDVI értékek és a hozam közötti összefüggés ($r^2 = 0,77$) $p \leq 0,0001$ szignifikanciaszinten (Teal et al., 2006).

A disszertációban bemutatott eredmények alapján a lineáris egyenlet alkalmazásával ajánlatos a hozampredikációs vizsgálatokat elvégezni őszi búzában.

5.4. Időjárási körülmények kapcsolata a hozammal

Két év terméseredményei szignifikánsan eltértek $p \leq 0,05$ szignifikanciaszinten egymástól (27. ábra), ezért az időjárási körülményeket is megvizsgáltam a pontosabb termésbecslési-modell kialakítása érdekében.

Számos kutatási eredményt publikáltak, ahol a talajtulajdonságokon kívül az eltérő időjárási viszonyok is befolyásolták a búza várható hozamát (Linina et al., 2018; Erekul et al., 2019; Iwańska et al., 2019). Ennek eredményeként a KNFHÖ (kumulált napi fejlődési hőmérsékleti összeg) és VUN (vetés utáni napok) értékeket más szerzők Bauer et al., (1984), Harrell et al., (2011) Giolo et al., (2021) munkájához hasonlóan felhasználtam a hozampredikációs-modell javítása céljából.

Eredményeim alapján a GreenSeeker kézi szenzor NDVI értékeinek KNFHÖ és VUN értékekkel történő kiegészítése javította a hozampredikációs-modell hatékonyságát. Mindkét év tekintetében a KNFHÖ ($r^2 = 0,71$) értékekkel pontosabb hozambecslési modell alakítható ki, mint a VUN ($r^2 = 0,54$) értékekkel (31-33. ábra).

Ezt támasztják alá Raun et al. (2001) és Tagakarlis et al. (2017a), kutatása is őszi búzában és kukoricában, ugyanis a KNFHÖ értékek bevonásával javítani tudták hozampredikációs-modelljüket. Hasonló

eredményekről számoltak be cukornád ültetvényénél (Lofton et al., 2012) is, míg rizsnél sem a VUN, sem a KNFHÖ értékek nem javították a hozampredikációs-modell hatékonyságát (Harrell et al., 2011). Ali et al., (2014) és Varinderpal-Singh (2022) rizsnél, míg Teal et al. (2006) kukoricánál vizsgálták az NDVI értékek és a hozam közötti kapcsolatot és eredményeik rávilágítottak, hogy egyik kutatásnál sem növeli a hozampredikáció pontosságát a KNFHÖ értékek modellbe integrálása. Ezt erősítette Tagarakis et al. (2017b) munkája is cirokban, azonban a VUN-ok használatával már javítani tudtak a hozampredikáció mértékén. Azonban Ji et al. (2017) káposztában végzett kutatásukban rácsafolnak ezen megállapításukra, ugyanis az NDVI értékek VUN-okkal történő korrekciója nem eredményezett erősebb determinációs együtthatókat. A különböző publikációk eredményei alapján tehát megállapítható, hogy kultúrától és éghajlati viszonyoktól függően, nincs egy egységesen elfogadható álláspont a KNFHÖ és VUN értékek hatékonyságával kapcsolatban a kutatók körében.

Azonban a meteorológiai adatok hozambecslési-modellbe történő beépítése ígéretes eredményeket hozott a GreenSeeker mérések tekintetében. Az RMSE értéket sikerült 0,97-ről 0,04-re csökkenteni (34. ábra). Ezzel szemben az időjárási adatok alkalmazása a MicaSense kamera esetében negatívan hatott (34. ábra), ami az RMSE érték 1,71-ről 7,23-ra való növekedésében nyilvánult meg.

5.5. Szenzorok összehasonlítása a hozampredikációs-modellben

A hozambeclési-modell alapján a GreenSeeker kézi optikai szenzor alkalmasabb volt a MicaSense kameránál az őszi búza várható hozamának meghatározására. Előnye, hogy megbízható adatokat szolgáltatott a szárbaindulástól (BBCH 30) egészen az érési (BBCH 80) szakaszig (34. ábra).

Nakamo et al. (2023) egy GreenSeeker és egy Parrot Sequoia kamera adataiból kalkulált NDVI értékek és a rizs hozama közötti kapcsolatot vizsgálták. Kutatásukban megállapították, hogy a kalászás előtti harmadik héttől kezdődően, minden időpontban és nitrogéndózisnál a GreenSeeker erősebb korrelációt ($r = 0,80-0,95$; $p \leq 0,001$) mutatott a hozammal, mint a Sequoia kamera ($r = 0,30-0,80$; $p \leq 0,05$). A legerősebb korreláció egy ($r = 0,90-0,95$; $p \leq 0,001$) és három héttel ($r = 0,8-0,9$; $p \leq 0,001$) a kalászás előtt állapították meg. Szintén az előbb említett két eszközt hasonlították össze őszi búzában öntözött és korlátozottan öntözött körülmények között. A Pearson-féle korreláció alapján az UAV-NDVI és a hozam között alacsony korreláció volt megfigyelhető a szemképződés időszakában limitált öntözésnél ($r = 0,29-0,37$), de ezek az értékek magasabbak voltak, mint a GS-NDVI értékek esetében (Hassan et al., 2019).

Oglesby et al. (2022) kukoricában végeztek hozambeclést, ahol egy leaf SPAD, egy GreenSeeker, egy Crop Circle és MicaSense adatait hasonlították össze. Méréseik alapján a MicaSense kamera adatai alapján lehetett a legjobban megbecsülni a várható hozamot a címerhányás és a virágzás ($r^2 = 0,78$ és $0,83$) időszakában. A Crop

Circle és a SPAD ($r^2 = 0,57$ és $0,49$) szintén a címerhányás szakaszában, míg a GreenSeeker mérések a tízleveles állapotban ($r^2 = 0,52$) $p \leq 0,001$ szignifikanciaszinten mutatta a legjobb kapcsolatot a hozammal.

Choudhury et al. (2021) egy GreenSeekert és egy ötcsatornás MicaSense RedEdge-M kamerát alkalmazott az NDVI értékek és a búza hozam közötti kapcsolat vizsgálatára közepesen és erősen szikes talajon. Vizsgálataik során megfigyelték, hogy a MicaSense kamera adatai erősebb összefüggést mutattak közepesen ($r^2 = 0,75$; $p \leq 0,001$) és erősen ($r^2 = 0,53$; $p \leq 0,001$) szikes talajon is a hozammal, mint a GreenSeekeré ($r^2 = 0,38$; $p \leq 0,001$ és ($r^2 = 0,31$; $p \leq 0,05$).

A disszertációban vizsgált két szenzor piaci értékének az összehasonlítása során a GreenSeeker egy jóval alacsonyabb árkatóriát képvisel a MicaSense kamerához képest. Gazdálkodói szemmel pedig azért lehet előnyösebb a GreenSeeker használata, mert jóval egyszerűbb az adatkinyerési folyamat. Hátránya viszont, hogy rendkívül munkaigényes a vele való mérési folyamat és kizárólag kisebb területek vizsgálatára alkalmas.

5.6. Négy szenzor NDVI értékének összehasonlítása

A négy szenzor mérési adatainak összehasonlításakor bizonyos periódusokban szignifikáns különbség ($p \leq 0,05$) állapítható meg a kiszámított NDVI értékek között. Ilyen időszak május eleje (35. ábra), a zászlóslevél megjelenésének és a kalász kezdeti fejlődésének időszaka (BBCH 37-43). Ekkor nem érdemes a különböző szenzorok adataiból kalkulált NDVI értékeket egymással összehasonlítani.

Walsh et al. (2022) egy GreenSeeker és egy MicaSense RedEdge-M típusú kamerát hasonlítottak össze az NDVI értékek alapján búzában. Szárbainduláskor (BBCH 30) erősebb összefüggést ($r^2 = 0,85$; $p \leq 0,05$) állapítottak meg a két szenzor adatai között, mint a levélhüvelynövekedés (BBCH 45) végén ($r^2 = 0,85$; $p \leq 0,05$).

Rizsben egy Phantom 4 multispektrális és egy GreenSeeker szenzor adataiból kalkulált NDVI értékeket vizsgáltak (Nakamo et al., 2023) négy héttel a kalászhányást megelőző időszakról a kalászhányásig. Vizsgálataik során megfigyelték, hogy amikor a két év négy-négy mérési időpontját összevonták, akkor jóval alacsonyabb korrelációs értéket kaptak ($r = 0,51$; $p \leq 0,001$), mint az egyes mérési napokon ($r = 0,79-0,96$; $p \leq 0,001$). Továbbá a GreenSeeker adataiból kalkulált NDVI értékek sokkal szélesebb skálán (0,58-0,75) mozogtak, mint a multispektrális kameráé (0,87-0,91). Hasonló eredményt figyeltek meg a GreenSeeker és MicaSense kamera adataiból kalkulált NDVI értékek összehasonlításakor is. Normál ($r^2 = 0,85$; $p \leq 0,001$) és késői ($r^2 = 0,84$; $p \leq 0,001$) búzavetés ($r = 0,79-0,96$; $p \leq 0,001$) vizsgálatánál a kézi szenzor NDVI értékei 0,25-0,90 között, míg a drónra szerelt kamera esetében ez az érték 0,40-0,95 között változott (Duan et al., 2017).

Zabala (2017) a Sentinel-2 és a MicaSense kamera adatait hasonlította össze számos kultúra bevonásával. A három felvételezés (november eleje és vége, december eleje) eredményei alapján erős korreláció ($r = 0,81$; $0,84$; $0,99$) figyelhető meg ($p \leq 0,05$) a két szenzor adataiból számított NDVI értékek között.

Shafiee et al. (2023) búzában végzett kutatásukban megerősítik, hogy a Phantom 4 multispektrális kamera adataiból számított NDVI értékek állandóbbak a napfény beesési szögének változása ellenére is a

MicaSense kamera adataiból számolt NDVI értékekkel összehasonlítva.

Azonban a disszertációban elért eredmények alapján a kalászás és a virágzás időszakában (BBCH 55-65) a Sentinel-2 műhold NDVI értékei nem különböznek szignifikánsan $p \leq 0,05$ szignifikanciaszinten (36. ábra) a Phantom 4 és MicaSense multispektrális kamera eredményeitől. Ennek köszönhetően a nagyobb szántóföldi területeken a drónos felvételezéseket kiválthatják a műholdas megfigyelések és elemzések.

5.7. GreenSeeker és Sentinel-2 műhold adataiból kalkulált NDVI értékek összehasonlítása

A GreenSeeker és a Sentinel-2 műhold adataiból számított NDVI értékek összehasonlítása során csekély mértékben ($r^2 \leq 0,003$) javult a modell a GreenSeekeres mérések számának növelésével (37. ábra). Hat mérési pontig emelkedik a determinációs együttható és csökken az RMSE érték (38. ábra). Azonban ezt követően a mérésszámok növelése nem javítja a kézi szenzor és a műhold adataiból kalkulált NDVI értékek közötti kapcsolatot. Ennek eredményeként maximum hat GreenSeekeres mérést kell végrehajtani, ha a Sentinel-2 10×10 méteres pixelértékeivel akarjuk összehasonlítani a kapott átlagértékeket, ezt követően már nem tudunk a modellen javítani.

Ritz et al. (2020) erős összefüggést ($r^2 = 0,92$) állapítottak meg $p \leq 0,001$ szignifikanciaszinten a GreenSeeker és a Sentinel-2 műhold adataiból számított NDVI értékek között. Ezt erősítette meg Mostaza-Colado et al. (2019) kutatása is, akik szintén nagyon erős korrelációt ($r = 0,94$; $p < 0,005$) kaptak az NDVI értékek elemzésénél. Azonban

Skandináviában a három helyszínen végzett zuzmó vizsgálatánál már nem sikerült ilyen erős korrelációs eredményeket ($r = 0,61$; $p < 0,001$) elérni a két szenzor NDVI értékek alapján történő összehasonlításnál (Erlandsson et al., 2023).

6. ÚJ TUDOMÁNYOS EREDMÉNYEK

1. A két szenzorral (GreenSeeker és MicaSense kamera) történő vizsgálataim alapján megállapítottam, hogy a Mosoni-sík kistájon a műtrágyázott őszi búzák várható hozamát a szemképződés (BBCH 70-75) időszakában lehet a legpontosabban modellezni ($p \leq 0,05$ szignifikanciaszinten).

2. Statisztikai számításokkal bebizonyítottam (28-30. ábra), hogy a szemképződés (BBCH 70-75) időszakában a különböző kezelések hozamai és a vizsgált területre vonatkoztatott NDVI értékek közötti összefüggések vizsgálatánál (lineáris, exponenciális, kvadratikus) a GreenSeeker adatai ($r^2 = 0,15-0,85$) pontosabb hozambecslést eredményeznek a MicaSense kamera adataihoz ($r^2 = 0,15-0,78$) képest.

3. Igazoltam (28-30. ábra), hogy a GreenSeeker kézi optikai szenzor adataira alapozott hozampredikációs egyenletekkel (lineáris, exponenciális, kvadratikus) pontosabb (RMSE = 0,56-1,03) hozammeghatározásra van lehetőség, mint a MicaSense kamera (RMSE = 0,73-1,34) adatainak alkalmazásával.

4. Statisztikai számításokkal alátámasztottam (31-33. ábra), hogy a lineáris egyenlet (RMSE = 0,97-2,77) alkalmazása a leghatékonyabb a hozamok prediktálására, mivel az exponenciális (RMSE = 1,02-2,80) és a kvadratikus (RMSE = 2,38-66,5) egyenletnél magasabb RMSE értékeket kaptam.

5. Vizsgálataim során igazoltam, hogy a négy különböző szenzor (Sentinel-2, MicaSense multispektrális kamera, Phantom 4 multispektrális kamera, GreenSeeker) adataiból kalkulált NDVI

értékek egy időben történő összehasonlításakor (33-34. ábra) a legtöbb esetben egymástól szignifikánsan ($p \leq 0,05$) eltérő NDVI értékeket kaptam az őszi búza felvételezésnél. Ebből következően megállapítottam, hogy az eltérő szenzorok egymással bizonyos esetekben nem összemérhető értékeket mérnek.

6. Lineáris modell segítségével alátámasztottam (37-38. ábra), hogy a GreenSeeker optikai érzékelő és a Sentinel-2 műhold adataiból kalkulált NDVI értékek alapján a GreenSeekeres mintavételezések számának növelése kezdetben minimálisan ($r^2 \leq 0,003$) befolyásolta, a két adat közötti determinációs együtthatót $p \leq 0,001$ szignifikanciaszinten. Azonban a hatodik mérési ponttól már nem javul tovább a modell pontossága.

7. ÖSSZEFOGLALÁS

A disszertációban bemutatott szántóföldi kísérletek a Széchenyi István Egyetem Albert Kázmér Mosonmagyaróvári Karához tartozó Uni-Agro-Food Kft. kezelésében lévő földterületeken 2021. október 25-e és 2023. július 3-a között valósultak meg. Mindkét kísérletnél őszi búza volt a vizsgált kultúra.

Az értekezés alapjául szolgáló kísérletek kialakítása során kiemelt figyelmet fordítottam, hogy olyan kutatásokat végezzek, amelyek a gyakorlati gazdálkodás számára is hasznos tudást jelenthet és a már meglévő tudásanyagba beintegrálható. A napjainkban tapasztalható extrém időjárási körülményeknek kitett gazdálkodóknak egyre nagyobb kihívást jelent a várható hozamok pontos meghatározása. Ez korlátozza a hatékony munkaszervezés megvalósítását, illetve komoly pénzügyi veszteségeket okozhat a magasabb áron történő terménylekötések elmaradása.

A hozampredikciós-modell kidolgozásához egy randomizált blokk elrendezésű négy ismétléses kisparcellás kísérletet alakítottam ki, ahol különböző mennyiségű és típusú műtrágya lett kijuttatva. Az adatgyűjtés egy kézi GreenSeeker optikai érzékelővel és egy DJI Matrice 210V2 típusú drónra szerelt MicaSense RedEdge-MX Dual multispektrális kamerával valósult meg. A kutatási terület első felvételezésére mindkét esztendőben (2022 és 2023) április közepén került sor. Ezt követően egészen a betakarításig, kéthetes időintervallumokban nyomon követtem az őszi búza fejlődését.

Az említett két szenzor adataiból NDVI értékeket kalkuláltam ki, amelyek később a hozampredikciós-modell alapadatbázisát képezték.

Az NDVI és a hozameredmények összehasonlítása során megállapítottam, hogy mindkét szenzor tekintetében a szárbaindulás (BBCH 30-32) és a szemképződés (BBCH 70-75) időszakában korrelált egymással a legjobban a két változó.

Ezt követően különböző modellszámítások végeztem a kumulált napi fejlődési hőmérsékleti összeg (KNFHÖ) és a vetés utáni nap (VUN) paraméterek bevonásával. Eredményeim alapján csak a KNFHÖ értékek alkalmazásával lehetett hatékonyabb hozamelőrejelzési modellt kialakítani. Azonban az évjárathatás nagymértékben befolyásolhatja egy-egy hozampredikációs-modell pontosságát és sikerességét.

Továbbá az általam vizsgált három egyenlet (lineáris, exponenciális, kvadratikus) közül a lineáris egyenlet alkalmazása szolgáltatta a legmegbízhatóbb hozambecslési eredményeket, amelyet több hasonló kutatás is megerősített (Magneya et al., 2016; Almeida-Ñauñay et al., 2023;).

A két szenzor NDVI értékek alapján történő összehasonlítása során a kézi GreenSeekerrel hatékonyabban lehet meghatározni a várható terméseredményeket. A vizsgált időszakban a kontroll és a többi kezelés között szignifikáns különbség mutatható ki vele $p \leq 0,05$ szignifikanciaszinten. A MicaSense kamera adataiból kalkulált NDVI értékeket ellenben irracionális alkalmazni a zászlóslevél megjelenésétől (BBCH 37) a kalászhányás végéig (BBCH 59) tartó időintervallumban. A hozampredikációs-modell első éves eredményeinek elemzését követően a felvételezési időpontok változásával különböző mértékű eltéréseket tapasztaltam a két szenzor adataiból kalkulált NDVI értékek között. Ennek vizsgálatára 2023 februárjában egy újabb kísérletet állítottam be.

További két érzékelő (Phantom 4 multispektrális kamera és Sentinel-2 műhold) bevonásával vizsgáltam a GreenSeeker és a MicaSense kamera adataiból kalkulált NDVI értékeket. Az új szenzorok alkalmazásával a hozampredikációs-modell is kibővíthetővé válhat a jövőben.

Mivel a Sentinel-2 műhold rendelkezik a legalacsonyabb térbeli felbontással (10×10 méter), ezért a műhold iránya és felbontása határozta meg a kísérlet kialakítását. Összesen kilenc pixelméretet ölelt fel a Fenyőmajori kísérlet. Minden műholdpixelben további 25, egymástól egyenlő távolságra kimért terület lett kijelölve. A felvételezések időpontját minden esetben a műhold visszatérési ideje és az adott nap időjárási körülménye határozta meg. Végül négy alkalommal sikerült a négy szenzorral egy időben méréseket végezni. Az eredményeim rámutatnak, hogy a szenzorok közötti legnagyobb NDVI értékbeli differenciát a BBCH 37-42 közötti időszakban lehet mérni. Ellenben a legnagyobb hasonlóság a BBCH 55-60 szakaszban figyelhető meg.

A hozampredikációs modellben a GreenSeeker kézi szenzorral lehetett pontosabban előre jelezni a várható hozamot. Ennek köszönhetően vizsgálatokat végeztem, hogy mekkora az a mintaszám, amely után már nem érdemes a GreenSeekerrel méréseket végezni, ha a Sentinel-2 műhold pixelértékeivel arányos NDVI értékeket akarunk kapni.

A determinációs együtthatók és az RMSE értékek figyelembevételével a hatodik mérésig javul a felállított modellem. Az ezen érték felletti mintaszám már nem növeli az illeszkedés mértékének pontosságát.

8. PUBLIKÁCIÓS JEGYZÉK

8.1. Az értekezés témakörében megjelent publikációk

8.1.1. Tudományos közlemény, magyar nyelvű, lektorált folyóiratban:

Zsebő, S.; Kukorelli, G.; Milics, G.; Vona, V.M.; Kulmány, I.M. (2023): GreenSeeker és MicaSense kamera NDVI értékeinek összehasonlítása, valamint kapcsolatuk a hozammal. Acta Agronomica Óváriensis Vol. 64. (1) 95-111 p.

Zsebő, S.; Milics, G.; Kovács, A. (2022): Képpalkotási eljárások a precíziós gazdálkodásban. Acta agronomica Óváriensis Vol. 63. (2) 125-157 p.

8.1.2. Tudományos közlemény, idegen nyelvű, lektorált folyóiratban:

Zsebő, S.; Bede, L.; Kukorelli, G.; Kulmány, I.M.; Milics, G.; Stencinger, D.; Teschner, G.; Varga, Z.; Vona, V.; Kovács, A.J. (2024): Yield Prediction Using NDVI Values from GreenSeeker and MicaSense Cameras at Different Stages of Winter Wheat Phenology. Drones, 8, 88. <https://doi.org/10.3390/drones8030088>
Q1 – IF: 4,4

8.1.3. Proceedings, idegen nyelven:

Zsebő, S.; Kukorelli, G.; Horváth, B.; Hegedüs, G.; Abdinoor, A.J.; Vona, V.; Bede, L.; Stencinger, D.; Kovács, A.J.; Milics, G.; Kulmány M.I. (2024): Comparison of NDVI values at different phenological stages of winter wheat (*Triticum Aestivum* L.). Proceedings of the 16th International Conference on Precision Agriculture, Manhattan, Kansas USA.

Milics, G.; **Zsebő, S.**; Stencinger, D.; Kovacs; A. J. (2021): Creating augmented reality spaces for digital farming. IEEE International Conference on Cognitive Infocommunications [szerk.]. 12th IEEE International Conference on Cognitive Infocommunications (CogInfoCom 2021): Proceedings. 753-756 p.

8.2. Egyéb témakörben megjelent publikációk:

8.2.1. Impakt faktoros:

Kalocsai, R.; Giczi, Z.; Szakál, T.; Centeri, C.; Biró, Z.; Vona, M.; Kubina, L.; **Zsebő, S.**; Kulmány, I.; Vona, V. (2024): Effect of pH, Carbonate and Clay Content on Magnesium Measurement Methods on Hungarian Soils. Soil Systems. 8, 49. <https://doi.org/10.3390/soilsystems8020049> Q2 – IF: 2,9

Kulmány, I.M.; Bede, L.; Stencinger, D.; **Zsebő, S.**; Csavajda, P.; Kalocsai, R.; Vona, M.; Jakab, G.; Vona, V.M.; Bede-Fazekas, Á. (2024): Challenges in mapping soil variability using apparent soil electrical conductivity under heterogeneous topographic conditions Agronomy 14, 1161. <https://doi.org/10.3390/agronomy14061161> Q1 – IF: 3,3

Hashim, Z.K.; De Silva, A.G.S.D.; Hassouni, A.A.; Vona, V.M.; Bede, L.; Stencinger, D.; Horváth, B.; **Zsebő, S.**; Kulmány, I.M. (2024): Effects of Various Herbicide Types and Doses, Tillage Systems, and Nitrogen Rates on CO₂ Emissions from Agricultural Land: A Literature Review. Agriculture 14,1800. <https://doi.org/10.3390/agriculture14101800> Q1 – IF: 3,3

8.2.2. Proceedings, idegen nyelven:

Kulmány, I.; **Zsebő, S.**; Nyéki, A.; Milics, G.; Kovács, A. J.; Neményi, M. (2018): Improving yield prediction accuracy using energy balance trial, on-the-go and remote sensing procedure. Proceedings of the 14th International Conference on Precision Agriculture, Montreal, Quebec, Canada, 24-27. 9 p.

Milics, G.; **Zsebő, S.**; Szabó, Sz.; Búdi, K.; Takács, A.; Láng, V. (2018): Increasing corn (*Zea Mays L.*) profitability by sitespecific seed and nutrient management in Igmand-Kisber Basin, Hungary. Proceedings of the 14th International Conference on Precision Agriculture, Montreal, Quebec, Canada, 24-27. 7 p.

8.2.3. Ismeretterjesztő közlemények:

Zsebő S. (2023): Különböző eszközök NDVI értékeinek összehasonlítása, az NDVI kapcsolata a hozammal. ÚNKP Tanulmánykötet 2022/2023. Széchenyi István Egyetem, Győr, 231-239 p.

Csepregi A.; **Zsebő S.**; Kauser J.; Milics G. (2020): Érdemes-e automatikus szakaszvezérléssel felszerelni a vetőgépünket? Beszéljenek a számok! Agrofórum: 31. évf. 4. sz., 18-20 p.

Milics G.; **Zsebő S.**; Varga A.; Pörnczi A. (2017): Egyről a kettőre: Precíziós gazdálkodás gazdaszemmel IV. rész –Tapasztalatok a kelés során – Tő- és sortávellenőrzés. AgroNapló: 21. évf. 7.sz 70-71 p.

9. IRODALOMJEGYZÉK

1. *Aase, J.K., Siddoway, F.H.* 1981. Assessing winter wheat dry matter production via spectral reflectance measurements. *Remote Sensing of Environment* 11, 267–277. [https://doi.org/10.1016/0034-4257\(81\)90025-0](https://doi.org/10.1016/0034-4257(81)90025-0)
2. *Aasen, H., Bolten, A.* 2018. Multi-temporal high-resolution imaging spectroscopy with hyperspectral 2D imagers—From theory to application. *Remote Sensing of Environment* 205, 374–389. <https://doi.org/10.1016/j.rse.2017.10.043>
3. *Agarwal, A., Mukherjee, B., Kandari, A., Ramakrishna, B.N., Kumar A.K.A.* 2022. Post-mission de-orbiting of Cartosat-2. *Advances in Space Research* (70), 1312–1324. <https://doi.org/10.1016/j.asr.2022.06.007>
4. *Ali, A.M., Ibrahim, S.M.* 2020. Wheat grain yield and nitrogen uptake prediction using atLeaf and GreenSeeker portable optical sensors at jointing growth stage. *Information Processing in Agriculture* 7(3), 375–383. <https://doi.org/10.1016/j.inpa.2019.09.008>
5. *Ali, A.M., Thind, H.S., Sharma, S., Varinderpal-Singh.* 2014. Prediction of dry direct-seeded rice yields using chlorophyll meter, leaf color chart and GreenSeeker optical sensor in northwestern India. *Field Crops Research* 161, 11–15. <https://doi.org/10.1016/j.fcr.2014.03.001>
6. *Ali, J., Jewel, Z. A., Mahender, A., Anandan, A., Hernandez, J., Li, Z.* 2018. Molecular genetics and breeding for nutrient use efficiency in rice. *International Journal of Molecular Sciences* 19(6), 1762. <https://doi.org/10.3390/ijms19061762>
7. *Almeida-Ñauñay, A.F., Tarquis, A.M., López-Herrera, J., Pérez-Martín, E., Pancorbo, J.L., Raya-Sereno, M.D., Quemada, M.* 2023. Optimization of soil background removal to improve the prediction of wheat traits with UAV imagery. *Computers and Electronics in Agriculture*, 205, 107559. <https://doi.org/10.1016/j.compag.2022.107559>
8. *Ambrosia, V.G., Wegener, S.S., Sullivan, D.V., Buechel, S.W., Dunagan, S.E., Brass, J.A., Stoneburner, J., Schoenung, S.M.* 2003. Demonstrating

- UAV-acquired real-time thermal data over fires. *Photogramm. Eng. Remote Sens.* 69(4), 391–402. <https://doi.org/10.14358/pers.69.4.391>
9. An, N., Palmer, C.M., Baker, R.L., Markelz, R.J.C., Ta, J., Convington, M.F., Maloof, J.N., Welch, S.M., Weinig, C. 2016. Plant high-throughput phenotyping using photogrammetry and imaging techniques to measure leaf length and rosette area. *Computers and Electronics in Agriculture*, 127, 376–394. <https://doi.org/10.1016/j.compag.2016.04.002>
 10. Antal, J., Kismányoky, T., Ragasits, I. 1992. Szántóföldi Növénytermesztés. Mezőgazda kiadó. Budapest. 212-283. ISBN: 963-7362-20-7
 11. Antal, J., Berzsényi, Z., Birkás, M., Bocz, E., Csík, L., Dér, S., Györi, Z., Gyuricza, Cs., Izsáki, Z., Jolánkai, M., Késmárki, I., Kismányoky, T., Lázár, L., Pepó, P., Tóth, Z. 2005. Növénytermesztés tan 1. /A növénytermesztés alapjai – gabonafélék. Mezőgazda Kiadó, Budapest. 183–204. ISBN: 978-963-286-439-6.
 12. Arnall, D.B., Abit, M.J.M., Taylor, R.K., Raun W.R. 2016. Development of an NDVI-based nitrogen rate calculator for cotton. *Crop Science* 56(6), 3263-3271. <https://doi.org/10.2135/cropsci2016.01.0049>
 13. Ashapure, A., Jung, J., Chang, A., Oh, S., Yeom, J., Maeda, M., Maeda, A., Dube, N., Landivar, J., Hague, S., et al. 2020. Developing a machine learning based cotton yield estimation framework using multi-temporal UAS data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 169, 180–194. <https://doi.org/10.1016/j.isprsjprs.2020.09.015>
 14. Assmann, J.J., Kerby, J.T., Cunliffe, A.M., Myers-Smith, I.H. 2018. Vegetation monitoring using multispectral sensors - best practices and lessons learned from high latitudes. *Journal of Unmanned Vehicle Systems*. <https://doi.org/10.1101/334730>
 15. Atzberger, C., Eilers, P.H. 2011. A time series for monitoring vegetation activity and phenology at 10-daily time steps covering large parts of South America. *International Journal of Digital Earth*, 4, 365–386. <https://doi.org/10.1080/17538947.2010.505664>
 16. Ágoston, T., Pepó, P. 2005. Évjáráthatás vizsgálata őszi búzafajták termésére és termésstabilitására. *Agrártudományi Közlemények*, 16. 62–67.

17. *Bauer, A., Frank, A.B., Black, A.L.* 1984. Estimation of Spring Wheat Leaf Growth Rates and Anthesis from Air Temperature. *Agronomy Journal*, 76, 829–835. <https://doi.org/10.2134/agronj1984.00021962007600050027x>
18. *Benincasa, P., Antognelli, S., Brunetti, L., Fabbri, C.A., Natale, A., Sartoretti, V., Modeo, G., Guiducci, M., Tei, F. Vizzari, M.* 2018. Reliability of NDVI derived by high resolution satellite and UAV compared to in-field methods for the evaluation of early crop N status and grain yield in wheat. *Experimental Agriculture*, 54(4), 604–622. <https://doi.org/10.1017/S0014479717000278>
19. *Berni, J.A.J., Zarco-Tejada, P.J., Suárez, L., Fereres, E.* 2009. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *IEEE Transactions on Geoscience and Remote Sensing* 47(3), 722–738. <https://doi.org/10.1109/TGRS.2008.2010457>
20. *Bi, F.K., Hou, J.Y., Wang, Y.T., Chen, Y., Wang, Y.P.* 2019. Land cover classification of multispectral remote sensing images based on time-spectrum association features and multikernel boosting incremental learning, *Journal of Applied Remote Sensing* 13(4) 044510. <https://doi.org/10.1117/1.jrs.13.044510>
21. *Bollas, N., Kokinou, E., Polychronos, V.* 2021. Comparison of Sentinel-2 and UAV Multispectral Data for Use in Precision Agriculture: An Application from Northern Greece. *Drones* 5(2), 35. <https://doi.org/10.3390/drones5020035>
22. *Bordoni, A., Danesi, F., Di Nunzio, M., Taccari, A., Valli, V.* 2017. Ancient wheat and health: A legend or reality? A review on KAMUT khorasan wheat. *International Journal of Food Sciences and Nutrition* 68(3), 278–286. <https://doi.org/10.1080/09637486.2016.1247434>
23. *Borgogno-Mondino, E., Lessio, A., Gomarasca, M.A.* 2016. A fast operative method for NDVI uncertainty estimation and its role in vegetation analysis. *European Journal of Remote Sensing*, 49, 137–156. <https://doi.org/10.5721/EuJRS20164908>

24. *Borlaug, N.E.* 1958. The impact of agricultural research on Mexican wheat production. *Transactions of the New York Academy of Sciences* 20 (3), 278–295.
25. *Bouchet, A.S., Laperche, A., Bissuel-Belaygue, C., Snowdon, R., Nesi, N., Stahl, A.* 2016. Nitrogen use efficiency in rapeseed. A review. *Agronomy for Sustainable Development* 36, 38. <https://doi.org/10.1007/s13593-016-0371-0>
26. *Bu, H., Sharma, L. K., Denton, A., Franzen, D.W.* 2017. Comparison of Satellite Imagery and Ground-Based Active Optical Sensors as Yield Predictors in Sugar Beet, Spring Wheat, Corn, and Sunflower, *Agronomy Journal*. 109(1), 299–308. <https://doi.org/10.2134/agronj2016.03.0150>
27. *Canicatti, M., Vallone, M.* 2024. Drones in vegetable crops: A systematic literature review. *Smart Agricultural Technology*. 7, 100396. <https://doi.org/10.1016/j.atech.2024.100396>
28. *Choudhary, S.S., Biswal, S., Saha, R., Chatterjee, C.* 2021. A non-destructive approach for assessment of nitrogen status of wheat crop using unmanned aerial vehicle equipped with RGB camera. *Arabian Journal of Geosciences* 14, 1739. <https://doi.org/10.1007/s12517-021-08139-3>
29. *Choudhury, M.R., Das, S., Christopher, J., Apan, A., Chapman, S., Menzies, N.W., Dang, Y.P.* 2021. Improving Biomass and Grain Yield Prediction of Wheat Genotypes on Sodic Soil Using Integrated High-Resolution Multispectral, Hyperspectral, 3D Point Cloud, and Machine Learning Techniques. *Remote Sensing*. 13, 3482. <https://doi.org/10.3390/rs13173482>
30. *Chu, D., Shen, H., Guan, X., Chen, J.M., Li, X., Li, J., Zhang, L.* 2021. Long time-series NDVI reconstruction in cloud-prone regions via spatio-temporal tensor completion. *Remote Sensing of Environment* 264, 112632 <https://doi.org/10.1016/j.rse.2021.112632>.
31. *Colomina, I., Molina, P.* 2014. Unmanned aerial systems for photogrammetry and remote sensing: a review. *ISPRS Journal of Photogrammetry and Remote Sensing* 92, 79–97. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>

32. *C'ulibrk, D., Lugonja, P., Minic', V., Crnojevic', V.* 2011. Neural network approach to water-stressed crops detection using multispectral worldview-2 satellite imagery. 1: Artificial Intelligence Applications and Innovations 9(12), 323–331. https://doi.org/10.1007/978-3-642-23960-1_39
33. *Curtis, B.C.* 2002. Wheat in the World. In: Curtis, B.C., Rajaram, S. and Macpherson, H.G., Eds., Bread Wheat Improvement and Production, Plant Production and Protection Series 30, FAO, Roma, 1–18.
34. *Curtis, T., Halford, N.G.* 2014. Food security: the challenge of increasing wheat yield and the importance of not compromising food safety. *Annals of Applied Biology* 164(3), 354–372. <https://doi.org/10.1111/aab.12108>
35. *Dall'Asta, E., Forlani, G., Roncella, R., Santise, M., Diotri, F., di Cella, U.M.* 2017. Unmanned aerial systems and DSM matching for rock glacier monitoring. *ISPRS Journal of Photogrammetry and Remote Sensing* 127, 102–114. <https://doi.org/10.1016/j.isprsjprs.2016.10.003>
36. *Dahnke, W.C., Swenson, L.J., Goos, R.J., Leholm A.G.* 1984. Choosing a crop yield goal, Better Crops with Plant Food (USA). Soil Science Department and Extension Agricultural Economics.
37. *De Rango, F., Palmieri, N., Santamaria, A.F., Potrino, G.* 2017. A simulator for UAVs management in agriculture domain. International Symposium on Performance Evaluation of Computer and Telecommunication Systems (SPECTS), 345. <https://doi.org/10.23919/spects.2017.8046780>
38. *Della Nave, F.N., Ojeda, J.J., Irisarri, J.G.N., Pembleton, K., Oyarzabal, M., Oosterheld, M.* 2022. Calibrating APSIM for forage sorghum using remote sensing and field data under sub-optimal growth conditions. *Agricultural Systems*, 201, 103459. <https://doi.org/10.1016/j.agsy.2022.103459>
39. *Dellinger, A.E., Schmidt, J.P., Beegle, D.B.* 2008. Developing nitrogen fertilizer recommendations for corn using an active sensor. *Agronomy Journal*, 100, 1546–1552. <https://doi.org/10.2134/agronj2007.0386>
40. *Deng, L., Mao, Z., Li, X., Hu, Z., Duan, F., Yan, Y.* 2018. UAV-based multispectral remote sensing for precision agriculture: a comparison between different cameras. *ISPRS Journal of Photogrammetry and Remote Sensing* 146, 124–136. <https://doi.org/10.1016/j.isprsjprs.2018.09.008>

41. *Dimiyati, M., Supriatna, S., Nagasawa, R., Pamungkas, F.D., Pramayuda, R.A.* 2023. Comparison of Several UAV-Based Multispectral Imageries in Monitoring Rice Paddy (A Case Study in Paddy Fields in Tottori Prefecture, Japan). *ISPRS International Journal of Geo-Information*, 12, 36.
<https://doi.org/10.3390/ijgi12020036>
42. *Domínguez, J.A., Kumhálová, J., Novák, P.* 2015. Winter oilseed rape and winter wheat growth prediction using remote sensing methods. *Plant Soil Environment* 61, 410–416. <https://doi.org/10.17221/412/2015-PSE>
43. *Domínguez, J.A., Kumhálová, J., Novák, P.* 2017. Assessment of the relationship between spectral indices from satellite remote sensing and winter oilseed rape yield. *Agronomy Research* 15(1), 055-068.
44. *Dövényi, Z., 2010.* Magyarország kistájainak katasztere. MTA Földrajztudományi Kutatóintézet, Budapest. 299–303.
45. *Duan, B., Liu, Y., Gong, Y., Peng, Y., Wu, X., Zhu, R., Fang, S.* 2019. Remote estimation of rice LAI based on Fourier spectrum texture from UAV image. *Plant Methods* 15(1), 124. <https://doi.org/10.1186/s13007-019-0507-8>
46. *Duan, T. Chapman, S.C. Guo, Y. Zheng, B.* 2017. Dynamic monitoring of NDVI in wheat agronomy and breeding trials using an unmanned aerial vehicle. *Field Crops Research* 210, 71-80.
<https://doi.org/10.1016/j.fcr.2017.05.025>
47. *Edwards, D., Oldroyd, G., Kyratzis, A., Skarlatos, D., Fotopoulos, V., Vamvakousis, V., Katsiotis, A.* 2015. Agriculture and climate change – adapting crops to increased uncertainty (AGRI 2015) investigating correlation among NDVI index derived by unmanned aerial vehicle photography and grain yield under late drought stress conditions. *Procedia Environmental Sciences* 29, 225–226.
<https://doi.org/10.1016/j.proenv.2015.07.284>
48. *Erekul, O., Köhn, W.* 2006. Effect of Weather and Soil Conditions on Yield Components and Bread-Making Quality of Winter Wheat (*Triticum aestivum* L.) and Winter Triticale (*Triticosecale* Wittm.) Varieties in North-East Germany. *Journal of Agronomy and Crop Science*, 192, 452–464.
<https://doi.org/10.1111/j.1439-037X.2006.00234.x>

49. *Erlandsson, R., Arneberg, M. K., Tømmervik, H., Finne, E. A., Nilsen, L., Bjerke, J. W.* 2023. Feasibility of active handheld NDVI sensors for monitoring lichen ground cover. *Fungal Ecology*, 63, 101233. <https://doi.org/10.1016/j.funeco.2023.101233>
50. *European Space Agency (ESA_a)*. ESA Sentinel Online. Sentinel-2 Mission Objectives. <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/mission-objectives> Letöltve: 2024. 01. 04.
51. *European Space Agency (ESA_b)*. ESA Sentinel Online. Sentinel-2 Mission. http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Sentinel-2 Letöltve: 2024. 01. 04.
52. *European Space Agency (ESA)* 2015. Sentinel-2 User Handbook. European Space Agency, 2015. chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook. Letöltve: 2024. 09. 14.
53. *Farbo, A., Sarvia, F., De Petris, S., Basile, V., Borgogno-Mondino, E.* 2024. Forecasting corn NDVI through AI-based approaches using Sentinel-2 image time series. *ISPRS Journal of Photogrammetry and Remote Sensing*, 211, 244–261. <https://doi.org/10.1016/j.isprsjprs.2024.04.011>
54. *Farkas, Z., Varga-László, E., Anda, A., Veisz, O., Varga, B.* 2020. Effects of Waterlogging, Drought and Their Combination on Yield and Water-Use Efficiency of Five Hungarian Winter Wheat Varieties. *Water*, 12(5), 1318. <https://doi.org/10.3390/w12051318>
55. *Feekes, W.* 1941. “De tarwe en haar milieu.Verslagen van de Technische Tarwe Commissie. (in Dutch).17: 523–888.
56. *Fei, S., Hassan, M.A., Xiao, Y., Su, X., Chen, Z., Cheng, Q., Duan, F., Chen, R., Ma, Y.*, 2022. UAV-based multi-sensor data fusion and machine learning algorithm for yield prediction in wheat. *Precision Agriculture*, 24, 187–212 <https://doi.org/10.1007/s11119-022-09938-8>

57. Feng, A., Zhou, J., Vories, E.D., Sudduth, K.A., Zhang, M. 2020. Yield estimation in cotton using UAV-based multi-sensor imagery. *Biosystems Engineering*, 193, 101–114.
<https://doi.org/10.1016/j.biosystemseng.2020.02.014>
58. Feng, A., Zhou, J., Vories, E., Sudduth, K.A. 2023. Prediction of cotton yield based on soil texture, weather conditions and UAV imagery using deep learning. *Precision Agriculture*, 25, 303–326.
<https://doi.org/10.1007/s11119-023-10069-x>
59. Fortin, J.G., Ancil, F., Parent, L.É., Bolinder, M.A. 2011. Site-specific early season potato yield forecast by neural network in Eastern Canada. *Precision Agriculture*, 12, 905–923. <https://doi.org/10.1007/s11119-011-9233-6>
60. Foster, A.J., Kakani, V.G., Mosali, J. 2016. Estimation of bioenergy crop yield and N status by hyperspectral canopy reflectance and partial least square regression. *Precision Agriculture* 18, 192–209.
<https://doi.org/10.1007/s11119-016-9455-8>
61. Franch, B., Bautista, A.S., Fita, D., Rubio, C., Tarrazó-Serrano, D., Sánchez, A., Skakun, S., Vermote, E., Becker-Reshef, I., Uris, A. 2021. Within-Field Rice Yield Estimation Based on Sentinel-2 Satellite Data. *Remote Sensing* 13, 4095. <https://doi.org/10.3390/rs13204095>
62. Franzen, D., Kitchen, N., Holland, K., Schepers, J., Raun, W. 2016. Algorithms for in-season nutrient management in cereals *Agronomy Journal* 108(5), 1775–1781. <https://doi.org/10.2134/agronj2016.01.0041>
63. Gabriel, J.L., Zarco-Tejada, P.J., López-Herrera, P.J., Pérez-Martín, E., Alonso-Ayuso, M., Quemada, M. 2017. Airborne and ground level sensors for monitoring nitrogen status in a maize crop. *Biosystems Engineering*, 160, 124–133. <https://doi.org/10.1016/j.biosystemseng.2017.06.003>
64. Gajdács, L., Palik, M., Dudás, Z. 2021. Drónok és hagyományos légi járművek közös légtérben történő alkalmazásának repülésbiztonsági kockázatai. *Repüléstudományi Közlemények*, 33(1), 157–170.
<https://doi.org/10.32560/rk.2021.1.12>
65. Ghafarian Malamiri, H.R., Zare, H., Rousta, I., Olafsson, H., Izquierdo Verdiguier, E., Zhang, H., Mushore, T.D. 2020. Comparison of Harmonic

- Analysis of Time Series (HANTS) and Multi-Singular Spectrum Analysis (M-SSA) in Reconstruction of Long-Gap Missing Data in NDVI Time Series. *Remote Sensing* 12(17), 2747. <https://doi.org/10.3390/rs12172747>
66. *Gim, H.J., Ho, C.H., Jeong, S., Kim, J., Feng, S., Hayes, M.J.* 2020. Improved mapping and change detection of the start of the crop growing season in the US Corn Belt from long-term AVHRR NDVI. *Agricultural and Forest Meteorology* 294, 108143 <https://doi.org/10.1016/j.agrformet.2020.108143>
67. *Giolo, M., Sallenave, R., Pornaro, C., Velasco-Cruz, C., Macolino, S., Leinauer, B.* 2021. Base temperatures affect accuracy of growing degree day model to predict emergence of bermudagrasses. *Agronomy Journal* 113, 2960–2966. <https://doi.org/10.1002/agj2.20660>
68. *Gitelson, A.A., Kaufman, Y.J., Stark, R., Rundquist, D.C.* 2002. Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment* 80(1), 76–87. [https://doi.org/10.1016/s00344257\(01\)00289-9](https://doi.org/10.1016/s00344257(01)00289-9).
69. *Goffart, D., Dvorakova, K., Crucil, G., Curnel, Y., Limbourg, Q., Van Oost, K., Castaldi, F., Planchon, V., Goffart, J.P., van Wesemael, B.* 2022. UAV Remote Sensing for Detecting within-Field Spatial Variation of Winter Wheat Growth and Links to Soil Properties and Historical Management Practices. A Case Study on Belgian Loamy Soil. *Remote Sensing*, 14, 2806. <https://doi.org/10.3390/rs14122806>
70. *Gonzalez-Dugo, V., Hernandez, P., Solis, I., Zarco-Tejada, P.J.* 2015. Using High-Resolution Hyperspectral and Thermal Airborne Imagery to Assess Physiological Condition in the Context of Wheat Phenotyping. *Remote Sensing*, 7, 13586–13605. <https://doi.org/10.3390/rs71013586>
71. *Goodwin, A.W., Lindsey, L.E., Harrison, S.K., Paul, P.A.* 2018. Estimating Wheat Yield with Normalized Difference Vegetation Index and Fractional Green Canopy Cover. *Crop Forage & Turfgrass Management*. 4, 1–6. <https://doi.org/10.2134/cftm2018.04.0026>
72. *Grenzdörffer, G.J., Engel, A., Teichert, B.* 2008. The photogrammetric potential of low-cost UAVs in forestry and agriculture. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. XXXVII.

73. Gu, Y., Wylie, B.K., Howard, D.M., Phuyal, K.P., Ji, L. 2013. NDVI saturation adjustment: A new approach for improving cropland performance estimates in the Greater Platte River Basin, USA. *Ecological Indicators*. 30, 1–6. <https://doi.org/10.1016/j.ecolind.2013.01.041>
74. Guan, S., Fukami, K., Matsunaka, H., Okami, M., Tanaka, R., Nakano, H., Sakai, T., Nakano, K., Ohdan, H., Takahashi, K. 2019. Assessing Correlation of High-Resolution NDVI with Fertilizer Application Level and Yield of Rice and Wheat Crops Using Small UAVs. *Remote Sensing*. 11, 112. <https://doi.org/10.3390/rs11020112>
75. Guo, L., An, N., Wang, K. 2016. Reconciling the discrepancy in ground- and satellite-observed trends in the spring phenology of winter wheat in China from 1993 to 2008. *Journal of Geophysical Research Atmospheres* 121(3), 1027–1042. <https://doi.org/10.1002/2015jd023969>
76. Gutiérrez, S., Wendel, A., Underwood, J. 2019. Ground based hyperspectral imaging for extensive mango yield estimation. *Computers and Electronics in Agriculture*, 157, 126–135. <https://doi.org/10.1016/j.compag.2018.12.041>
77. Hafeez, A., Husain, M.A., Singh, S.P., Chauhan, A., Khan, M.T., Kumar, N., Chauhan, A., Soni, S.K. 2023. Implementation of drone technology for farm monitoring & pesticide spraying: A review. *Information Processing in Agriculture*, 10(2), 192–203. <https://doi.org/10.1016/j.inpa.2022.02.002>
78. Han, M., Okamoto, M., Beatty, P.H., Rothstein, S.J., Good, A.G. 2015. The genetics of nitrogen use efficiency in crop plants. *Annual Review of Genetics* 49(1), 269–289. <https://doi.org/10.1146/annurev-genet-112414-055037>
79. Harrell, D.L., Tubana, B.S., Walker, T.S., Phillips, S.B. 2011. Estimating rice grain yield potential using normalized difference vegetation index. *Agronomy Journal*, 103, 1717–1723. <https://doi.org/10.2134/agronj2011.0202>
80. Hassan, M.A.; Yang, M.; Rasheed, A.; Yang, G.; Reynolds, M.; Xia, X.; Xiao, Y.; He, Z. 2019. A rapid monitoring of NDVI across the wheat growth cycle for grain yield prediction using a multi-spectral UAV platform. *Plant Science* 282, 95–103. <https://doi.org/10.1016/j.plantsci.2018.10.022>

81. He, C.E., Liu, X.J., Fangmeier, A., Zhang, F.S. 2007. Quantifying the total airborne nitrogen input into agroecosystems in the North China Plain. *Agriculture, Ecosystems & Environment*, 121, 395–400. <https://doi.org/10.1016/j.agee.2006.12.016>
82. Heege, H.J., Thiessen, E. 2013. Sensing of Crop Properties. In *Precision in Crop Farming: Site Specific Concepts and Sensing Methods: Applications and Results*; Heege, H., Ed.; Springer Science + Business Media: Dordrecht, The Netherlands. 103–141.
83. Heffer, P., Gruère, A., Roberts T. 2017. Assessment of fertilizer use by crop at the global level International Fertilizer Industry Association, Paris.
84. Heinemann, P., Haug, S., Schmidhalter, U. 2022. Evaluating and defining agronomically relevant detection limits for spectral reflectance-based assessment of N uptake in wheat. *European Journal of Agronomy*, 140 (7), 126609. <https://doi.org/10.1016/j.eja.2022.126609>
85. Holland, K.H., Lamb, D.W., Schepers, J.S. 2012. Radiometry of proximal active optical sensors (AOS) for agricultural sensing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 5 (6), 1793–1802. <https://doi.org/10.1109/JSTARS.2012.2198049>
86. Houborg, R., McCabe, M., Houborg, R., McCabe, M.F. 2016. High-resolution NDVI from planet’s constellation of earth observing nano-satellites: A new data source for precision agriculture. *Remote Sensing* 8 (9), 768. <https://doi.org/10.3390/rs8090768>
87. Huddleston, H.F. 1978. Sampling Techniques for Measuring and Forecasting Crop Yields. 112–191.
88. Huzsvai, L., Juhász, C., Seddik, L., Kovács, G., Zsembeli, J. 2024. The Future Probability of Winter Wheat and Maize Yield Failure in Hungary Based on Long-Term Temporal Patterns. *Sustainability*, 16, 3962. <https://doi.org/10.3390/su16103962>
89. Inman, D., Khosla, R., Mayfield, T. 2005. On-the-go active remote sensing for efficient crop nitrogen management. *Sensor Review*. 25, 209–214. <https://doi.org/10.1108/02602280510606499>

90. *Inman, D., Khosla, R., Reich, R., Westfall, D.G.* 2008. Normalized difference vegetation index and soil color-based management zones in irrigated maize. *Agronomy Journal* 100(1), 60-66. <https://doi.org/10.2134/agronj2007.0020>
91. *Iwańska, M., Stępień, M.* 2019. The effect of soil and weather conditions on yields of winter wheat in multi-environmental trials. *Biometrical Letters*, 56, 263–279. <https://doi.org/10.2478/bile-2019-0016>
92. *Ji, R., Min, J., Wang, Y., Cheng, H., Zhang, H., Shi, W.* 2017. In-Season Yield Prediction of Cabbage with a Hand-Held Active Canopy Sensor. *Sensors*, 17, 2287. <https://doi.org/10.3390/s17102287>
93. *Jin, X., Liu, S., Baret, F., Hemerlé, M., Comar, A.* 2017. Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sensing of Environment* 198, 105–114. <https://doi.org/10.1016/j.rse.2017.06.007>
94. *Johansen, K., Sallam, N., Robson, A., Samson, P., Chandler, K., Derby, L., Eaton, A., Jennings J.* 2018. Using GeoEye-1 imagery for multitemporal object-based detection of canegrub damage in sugarcane fields in Queensland, Australia. *GIScience and Remote Sensing*, 55 (2), 285–305. <https://doi.org/10.1080/15481603.2017.1417691>
95. *Johnson, M.D., Hsieh, W.W., Cannon, A.J., Davidson, A., Bédard, F.* 2016. Crop yield forecasting on the Canadian Prairies by remotely sensed vegetation indices and machine learning methods. *Agricultural and Forest Meteorology*, 218, 74–84. <https://doi.org/10.1016/j.agrformet.2015.11.003>
96. *Khadka, K., Burt, A.J., Earl, H.J., Raizada, M.N., Navabi, A.* 2021. Does leaf waxiness confound the use of NDVI in the assessment of chlorophyll when evaluating genetic diversity panels of wheat? *Agronomy* 11 (3), 486. <https://doi.org/10.3390/agronomy11030486>
97. *Khot, L.R., Sankaran, S., Carter, A.H., Johnson, D.A., Cummings, T.F.* 2016. UAS imaging-based decision tools for arid winter wheat and irrigated potato production management. *International Journal of Remote Sensing* 37 (1), 125–137. <https://doi.org/10.1080/01431161.2015.1117685>
98. *Kizilgeci, F., Yildirim, M., Islam, M.S., Ratnasekera, D., Iqbal, M.A., Sabagh, A.E.* 2021. Normalized Difference Vegetation Index and

- Chlorophyll Content for Precision Nitrogen Management in Durum Wheat Cultivars under Semi-Arid Conditions. *Sustainability* 13 (7), 3725. <https://doi.org/10.3390/su13073725>
99. Kogan, F., Kussul, N., Adamenko, T., Skakun, S., Kravchenko, O., Kryvobok, O., Shelestov, A., Kolotii, A., Kussul, O., Lavrenyuk, A. 2013. Winter wheat yield forecasting in Ukraine based on Earth observation, meteorological data and biophysical models. *International Journal of Applied Earth Observation and Geoinformation*, 23, 192–203. <https://doi.org/10.1016/j.jag.2013.01.002>
100. Kowalik, W.S., Gold, D.P. 1974. The Use of LANDSAT-1 Imagery in Mapping Lineaments in Pennsylvania. *Proceedings of the First International Conference on the New Basement Tectonics*, 236–249.
101. Kumar, C., Mubvumba, P., Huang, Y., Dhillon, J., Reddy, K. 2023. Multi-stage corn yield prediction using high-resolution UAV Multispectral data and machine learning models. *Agronomy* 13, 1277. <https://doi.org/10.3390/agronomy13051277>
102. Kumar, P. Pandey, P.C., Singh, B.K., Katiyar, S., Mandal, V.P., Rani, M., Tomar, V., Patariya, S. 2016a. Estimation of accumulated soil organic carbon stock in tropical forest using geospatial strategy. *The Egyptian Journal of Remote Sensing and Space Science* 19 (1), 109–123. <https://doi.org/10.1016/j.ejrs.2015.12.003>
103. Kumar, S., Röder, M.S., Singh, R.P., Kumar, S., Chand, R., Joshi, A.K., Kumar, U. 2016b. Mapping of spot blotch disease resistance using NDVI as a substitute to visual observation in wheat (*Triticum aestivum* L.). *Molecular Breeding* 36 (95), 1–11. <https://doi.org/10.1007/s11032-016-0515-6>
104. Kumar, C., Mubvumba, P., Huang, Y., Dhillon, J., Reddy, K. 2023. Multi-Stage Corn Yield Prediction Using High-Resolution UAV Multispectral Data and Machine Learning Models. *Agronomy* 13, 1277. <https://doi.org/10.3390/agronomy13051277>
105. Kumhálová, J., Matějková, Š. 2017. Yield variability prediction by remote sensing sensors with different spatial resolution. *International Agrophysics* 31, 195–2020. <https://doi.org/10.1515/intag-2016-0046>

106. *Large, E.C.* 1954. Growth stages in cereals—Illustration of the Feekes scale. *Plant pathology.*, 3, 128–129. <https://doi.org/10.1111/j.1365-3059.1954.tb00716.x>
107. *Láng, G.* 1976. Szántóföldi növénytermesztés. Mezőgazdasági Kiadó, Budapest, 64–91. ISBN: 963-230-375-x
108. *Lesk, C., Rowhani, P., Ramankutty, N.* 2016. Influence of extreme weather disasters on global crop production. *Nature* 529, 84–87. <https://doi.org/10.1038/nature16467>
109. *Levene, H.* 1960. In *Contributions to Probability and Statistics: Essays in Honor of Harold Hotelling*, I. Olkin et al. eds., Stanford University Press, 278–292.
110. *Li, B., Xu, X., Zhang, L., Han, J., Bian, C., Li, G., Liu, J., Jin, L.* 2020. Above-ground biomass estimation and yield prediction in potato by using UAV-based RGB and hyperspectral imaging. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 161–172. <https://doi.org/10.1016/j.isprsjprs.2020.02.013>
111. *Li, C., Li, H., Li, J., Lei, Y., Li, C., Manevski, K., Shen, Y.* 2019. Using NDVI percentiles to monitor real-time crop growth. *Computers and Electronics in Agriculture* 162, 357–363. <https://doi.org/10.1016/j.compag.2019.04.026>
112. *Li, F., Miao, Y., Zhang, F., Cui, Z., Li, R., Chen, X., Zhang, H., Schroder, J., Raun, W.R., Jia, L.* 2009. In-season optical sensing improves nitrogen use efficiency for winter wheat. *Soil Science Society of America Journal*, 73, 1566–1574. <https://doi.org/10.2136/sssaj2008.0150>
113. *Li, J., Roy, D.P.* 2017. A Global Analysis of Sentinel-2A, Sentinel-2B and Landsat-8 Data Revisit Intervals and Implications for Terrestrial Monitoring. *Remote Sensing* 9 (9), 902. <https://doi.org/10.3390/rs9090902>
114. *Li, M., Shamshiri, R.R., Weltzien, C., Schirrmann, M.* 2022. Crop Monitoring Using Sentinel-2 and UAV Multispectral Imagery: A Comparison Case Study in Northeastern Germany. *Remote Sensing* 14, 4426. <https://doi.org/10.3390/rs14174426>

115. *Li, T., Feng, Y., Li, X.* 2009. Predicting crop growth under different cropping and fertilizing management practices. *Agricultural and Forest Meteorology*, 149, 985–998. <https://doi.org/10.1016/j.agrformet.2008.12.005>
116. *Li, Z., Chen, Z., Cheng, Q., Fei, S., Zhou, X.* 2023. Deep learning models outperform generalized machine learning models in predicting winter wheat yield based on multispectral data from drones. *Drones*, 7 (8), 505. <https://doi.org/10.3390/drones7080505>
117. *Liaqat, M.U., Cheema, M.J.M., Huang, W., Mahmood, T., Zaman, M., Khan, M.M.* 2017. Evaluation of MODIS and Landsat multiband vegetation indices used for wheat yield estimation in irrigated Indus Basin. *Computers and Electronics in Agriculture* 138, 39–47. <https://doi.org/10.1016/j.compag.2017.04.006>
118. *Lie, F., Miao, Y., Zhang, F., Cui, Z., Li, R., Chen, X. et al.* 2009. In-season optical sensing improves nitrogen-use efficiency for winter wheat. *Soil Science Society of America Journal* 73 (5), 1566–1574. <https://doi.org/10.2136/sssaj2008.0150>
119. *Linina, A., Ruza, A.* 2018. The influence of cultivar, weather conditions and nitrogen fertilizer on winter wheat grain yield. *Agronomy Research*, 16, 147156. <https://doi.org/10.15159/AR.18.034>
120. *Liu, K., Shen, X., Cao, L., Wang, G., Cao, F.* 2018. Estimating forest structural attributes using UAV-LiDAR data in Ginkgo plantations. *ISPRS Journal of Photogrammetry and Remote Sensing* 146, 465–482. <https://doi.org/10.1016/j.isprsjprs.2018.11.001>
121. *Lofton, J., Tubana, B.S., Kanke, Y., Teboh, J., Viator, H., Dalen, M.* 2012. Estimating sugarcane yield potential using an in-season determination of normalized difference vegetative index. *Sensors*. 12, 7529–7547. <https://doi.org/10.3390/s120607529>
122. *Lopes, M.S., Reynolds, M.P.* 2012. Stay-green in spring wheat can be determined by spectral reflectance measurements (normalized difference vegetation index) independently from phenology. *Journal of Experimental Botany* 63(10), 3789–3798. <https://doi.org/10.1093/jxb/ers071>

123. *Lopresti, M.F., Di Bella, C.M., Degioanni, A.J.* 2015. Relationship between MODIS-NDVI data and wheat yield: a case study in Northern Buenos Aires province, Argentina. *Information Processing in Agriculture* 2(2), 73–84. <https://doi.org/10.1016/j.inpa.2015.06.001>
124. *Lu, J., Miao, Y., Huang, Y., Shi, W., Hu, X., Wang, X., Wan, J.* 2015. Evaluating an unmanned aerial vehicle-based remote sensing system for estimation of rice nitrogen status, in: 2015 Fourth International Conference on Agro-Geoinformatics (AgroGeoinformatics). IEEE, 198–203. <https://doi.org/10.1109/AgroGeoinformatics.2015.7248117>
125. *Lulla, K., Nellis, M. D., Rundquist, B., Srivastava, P. K., Szabo, S.* 2021. Mission to earth: LANDSAT 9 will continue to view the world. *Geocarto International*, 36 (20), 2261–2263. <https://doi.org/10.1080/10106049.2021.1991634>
126. *Ma, B.L., Dwyer, L.M., Costa, C., Cober, E.R., Morrison, M.J.* 2001. Early prediction of soybean yield from canopy reflectance measurements. *Agronomy Journal* 93(6), 1227–1234. <https://doi.org/10.2134/agronj2001.1227>
127. *Magda, S., Marselek, S., Miller, Gy.* 2000. A mezőgazdasági és élelmiszeripari technológia alapjai. Növénytermesztés. Mezőgazdasági Szaktudás Kiadó, Budapest. 162–166. ISBN: 963-356-294-5.
128. *Magneya, T.S., Eitel, J.U.H., Huggins, D.R., Vierling, L.A.* 2016. Proximal NDVI derived phenology improves in-season predictions of wheat quantity and quality. *Agricultural and Forest Meteorology* 217, 46–60. <https://doi.org/10.1016/j.agrformet.2015.11.009>
129. *Magney, T.S., Eitel, J.U.H., Vierling, L.A.* 2017. Mapping wheat nitrogen uptake from RapidEye vegetation indices. *Precision Agriculture* 2017, 18, 429–451. <https://doi.org/10.1007/s11119-016-9463-8>.
130. *Mahlein, A.K., Steiner, U., Dehne, H.W., Oerke, E.C.* 2010. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. *Precision Agriculture* 11, 413–431. <https://doi.org/10.1007/s11119-010-9180-7>

131. *Maimaitijiang, M., Sagan, V., Sidike, P., Hartling, S., Esposito, F., Fritschi, F.B.* 2020. Soybean yield prediction from UAV using multimodal data fusion and deep learning. *Remote Sensing of Environment* 237, 111599. <https://doi.org/10.1016/j.rse.2019.111599>
132. *Mangiafico, S.* 2021. Package ‘Rcompanion’: Functions to Support Extension Education Program Evaluation, R Package Version 2.4.1; GNU Project: Vienna, Austria.
133. *Maresma, A., Chamberlain, L., Tagarakis, A., Kharel, T., Godwin, G., Czymmek, K.J., Shields, E., Ketterings, Q.M.* 2020. Accuracy of NDVI-derived corn yield predictions is impacted by time of sensing. *Computers and Electronics in Agriculture* 169, 105236. <https://doi.org/10.1016/j.compag.2020.105236>
134. *Marti, J., Bort, J., Slafer, G.A., Araus, J.L.* 2007. Can wheat yield be assessed by early measurements of Normalized Difference Vegetation Index? *Annals of Applied Biology* 150 (2), 253–257. <https://doi.org/10.1111/j.1744-7348.2007.00126.x>
135. *Meier, U.* 2001. Growth stages of mono- and dicotyledonous plants BBCH Monograph. Federal Biological Research Centre for Agriculture and Forestry, Bonn.
136. *Meng, L., Liu, H., Ustin, S., Zhang, X.* 2021. Predicting maize yield at the plot scale of different fertilizer systems by multi-source data and machine learning methods. *Remote Sensing*, 13, 3760. <https://doi.org/10.3390/rs13183760>.
137. *Miao, Y., Stewart, B., Zhang, F.* 2011. Long-term experiments for sustainable nutrient management in China. A review. *Agronomy for Sustainable Development* 31, 397–414. <https://doi.org/10.1051/agro/2010034>
138. *Mika, J., Utasi, Z., Biró, Cs.P., Kónya E.* 2011. Műholdakról távérzékelt adatok feldolgozása és hasznosítása. *EKF TTK* 71–74.
139. *Miller, J.O., Adkins, J.* 2021. Monitoring winter wheat growth at different heights using aerial imagery. *497 Agronomy Journal*, 113 (2), 1586–1595. <https://doi.org/10.1002/agj2.20539>

140. Molberg, O., Uhlen, A.K., Jensen, T., Flaete, N.S., Fleckenstein, B., Arentz-Hansen, H., Raki, M., Lundin, K.E., Sollid, L.M. 2005. Mapping of gluten T-cell epitopes in the bread wheat ancestors: Implications for celiac disease. *Gastroenterology* 128 (2), 393–401.
<https://doi.org/10.1053/j.gastro.2004.11.003>
141. Mostaza-Colado, D., Ablanque, P. V. M., Capuano, A. 2019. Assessing the Yield of a Multi-varieties Crop of *Camelina sativa* (L.) Crantz through NDVI Remote Sensing. Sixth International Conference on Internet of Things: Systems, Management and Security (IOTSMS).
<https://doi.org/10.1109/iotsms48152.2019.8>
142. Mulla, D.J. 2013. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering, Special Issue: Sensing in Agriculture* 114 (4), 358–371.
<https://doi.org/10.1016/j.biosystemseng.2012.08.009>
143. Nagy, A., Fehér, J., Tamás, J. 2018. Wheat and maize yield forecasting for the Tisza river catchment using MODIS NDVI time series and reported crop statistics. *Computers and Electronics in Agriculture* 151, 41–49.
<https://doi.org/10.1016/j.compag.2018.05.035>.
144. Nakano, H., Tanaka, R., Guan, S., Ohdan, H. 2023. Predicting rice grain yield using normalized difference vegetation index from UAV and GreenSeeker. *Crop and Environment* 2 (2), 59–65.
<https://doi.org/10.1016/j.crope.2023.03.001>
145. Naser, M.A., Khosla, R., Longchamps, L., Dahal, S. 2020. Using NDVI to Differentiate Wheat Genotypes Productivity under Dryland and Irrigated Conditions. *Remote Sensing* 12, 824. <https://doi.org/10.3390/rs12050824>
146. National Aeronautics and Space Administration (NASA). Landsat Data Continuity Mission (LDCM).
https://www.nasa.gov/mission_pages/landsat/main/index.html Letöltve: 2024. 01. 04.
147. Navrozidis, I., Alexandridis, T. K., Dimitrakos, A., Lagopodi, A. L., Moshou, D., Zalidis, G. 2018. Identification of purple spot disease on asparagus crops

- across spatial and spectral scales. *Computers and Electronics in Agriculture* 148, 322–329. <https://doi.org/10.1016/j.compag.2018.03.035>
148. Neale, C.M.U., Jayanthi, H., and Wright, J.L., 2003. Crop and irrigation water management using high-resolution airborne remote sensing. In Proc. ICID Workshop Remote Sensing of ET for Large Regions, CD-ROM. New Delhi, India: International Commission on Irrigation and Drainage.
149. Neupane, K., Baysal-Gurel, F. 2021. Automatic Identification and Monitoring of Plant Diseases Using Unmanned Aerial Vehicles: A Review. *Remote Sensing* 13 (19), 3841. <https://doi.org/10.3390/rs13193841>
150. Ogaya, R., Peñuelas, J. 2003. Comparative field study of *Quercus ilex* and *Phillyrea latifolia*: photosynthetic response to experimental drought conditions. *Environmental and Experimental Botany*, 50, 137–148. [https://doi.org/10.1016/S0098-8472\(03\)00019-4](https://doi.org/10.1016/S0098-8472(03)00019-4)
151. Oglesby, C., Fox, A.A.A., Singh, G., Dhillon, J. 2022. Predicting In-Season Corn Grain Yield Using Optical Sensors. *Agronomy* 12, 2402. <https://doi.org/10.3390/agronomy12102402>
152. Ortiz, B.V., Thomson, S.J., Huang, Y. 2011. Determination of differences in crop injury from aerial application of glyphosate using vegetation indices. *Computers and Electronics in Agriculture* 77 (2), 204–213. <https://doi.org/10.1016/j.compag.2011.05.004>
153. Overton, M. 1979. Estimating Crop Yields from Probate Inventories: An Example from EastAnglia, 1585–1735. *The Journal of Economic History*, 39(02), 363–378. <https://doi.org/10.1017/S0022050700091567>
154. Patel, M.K., Ryu, D., Western, A.W., Suter, H., Young, I.M. 2021. Which multispectral indices robustly measure canopy nitrogen across seasons: Lessons from an irrigated pasture crop. *Computers and Electronics in Agriculture* 182, 106000. <https://doi.org/10.1016/j.compag.2021.106000>
155. Pavuluri, K., Chim, B.K., Griffey, C.A., Reiter, M.S., Balota, M., Thomason, W. 2015. Canopy spectral reflectance can predict grain nitrogen use efficiency in soft red winter wheat. *Precision Agriculture*. 16, 405–424. <https://doi.org/10.1007/s11119-014-9385-2>

156. *Pellegrini, P., Cossani, C.M., Di Bella, C.M., Piñeiro, G., Sadras, V.O., Oosterheld, M.* 2020. Simple regression models to estimate light interception in wheat crops with Sentinel-2 and a handheld sensor. *Crop Science*, 60 (3), 1234-1245. <https://doi.org/10.1002/csc2.20129>
157. *Pepó P., Sárvári M.* 2011. Gabonanövények termesztése. Elektronikus jegyzet. 14–39.
158. *Perry, E.M., Morse-McNabb, E.M., Nuttall, J.G., O’Leary, G.J., Clark, R.* 2014. Managing wheat from space: linking MODIS NDVI and crop models for predicting australian dryland wheat biomass. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7 (9), 3724–3731.
159. *Qi, H., Wu, Z., Zhang, L., Li, J., Zhou, J., Jun, Z., Zhu, B.* 2021. Monitoring of peanut leaves chlorophyll content based on drone-based multispectral image feature extraction. *Computers and Electronics in Agriculture* 187, 106292. <https://doi.org/10.1016/j.compag.2021.106292>
160. *R Core Team.* 2020. A Language and Environment for Statistical Computing; R Foundation for Statistical Computing: Vienna, Austria; Online: <https://www.r-project.org> (Letöltve: 2024. 09. 17).
161. *Radics L.* 2003. Szántóföldi növénytermesztés. Szaktudás Kiadó Ház Zrt., Budapest. 72-87. ISBN: 963 9422 97 5
162. *Radics, L.* 2010. Fenntartható szemléletű szántóföldi növénytermesztés 1., Agroinform kiadó, Budapest, 469–537.
163. *Ramcharan, A., Baranowski, K., McCloskey, P., Ahmed, B., Legg, J., Hughes, D.P.* 2017. Deep learning for image-based cassava disease detection. *Frontiers in Plant Science* 8, 1852. <https://doi.org/10.3389/fpls.2017.01852>
164. *Rasmussen, J., Ntakos, G., Nielsen, J., Svendsgaard, J., Poulsen, R.N., Christensen, S.* 2016. Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots? *European Journal of Agronomy* 74, 75–92. <https://doi.org/10.1016/j.eja.2015.11.026>

165. *Ratjen, A.M., Böttcher, U., Kage, H.* 2012. Improved modeling of grain number in winter wheat. *Field Crops Research*. 133, 167–175. <https://doi.org/10.1016/j.fcr.2012.04.002>
166. *Raun, W.R., Solie, J.B., Johnson, G.V., Stone, M.L., Lukina, E.V., Thomason, W.E., Schepers, J.S.* 2001. In-season prediction of potential grain yield in winter wheat using canopy reflectance. *Agronomy Journal*, 93 (1), 131–138. <https://doi.org/10.2134/agronj2001.931131x>
167. *Raun, W.R., Solie, J.B., Johnson, G.V., Stone, M.L., Mullens, R.W., Freeman, K.W., Thomason, W.E., Lukina, E.V.* 2002. Improving nitrogen use efficiency in cereal grain production with sensing and variable rate applications. *Agronomy Journal*, 94, 815–820. <https://doi.org/10.2134/agronj2002.8150>
168. *Raun, W.R., Solie, J.B., Stone, M.L., Martin, K.L., Freeman, K.W., Mullen, R.W., Zhang, H., Schepers, J.S., Johnson, G.V.* 2005. Optical sensor-based algorithm for crop nitrogen fertilization. *Communications in Soil Science and Plant Analysis*, 36(19-20), 2759–2781. <https://doi.org/10.1080/00103620500303988>
169. *Rembold, F., Atzberger, C., Savin, I., Rojas, O.* 2013. Using Low Resolution Satellite Imagery for Yield Prediction and Yield Anomaly Detection. *Remote Sensing*, 5, 1704–1733. <https://doi.org/10.3390/rs5041704>
170. *Reynolds, C.A., Yitayew, M., Slack, D.C., Hutchinson, C.F., Huete, A., Petersen, M. S.* 2000. Estimating crop yields and production by integrating the FAO crop specific water balance model with real-time satellite data and ground-based ancillary data. *International Journal of Remote Sensing*, 21(18), 3487–3508. <https://doi.org/10.1080/014311600750037516>
171. *Reynolds, M., Tattaris, M., Cossani, C.M., Ellis, M., Yamaguchi-Shinozaki, K., Pierre, C.S.* 2015. Exploring genetic resources to increase adaptation of wheat to climate change. In *Advances in Wheat Genetics: From Genome to Field: 12th International Wheat Genetics Symposium*; Ogihara, Y., Takumi, S., Handa, H., Eds.; Springer: Tokyo, Japan, 355–368. ISBN: 978-4-431-55674-9

172. Ritz, E., Bjerke, J. W., Tømmervik, H. 2020. Monitoring Winter Stress Vulnerability of High-Latitude Understory Vegetation Using Intraspecific Trait Variability and Remote Sensing Approaches. *Sensors*, 20 (7), 2102. <https://doi.org/10.3390/s20072102>
173. Rose, J.C., Kicherer, A., Wieland, M., Klingbeil, L., Töpfer, R., Kuhlmann, H. 2016. Towards Automated Large-Scale 3D Phenotyping of Vineyards under Field Conditions. *Sensors* 16 (12), 2136. <https://doi.org/10.3390/s16122136>
174. Rouse, J., Haas, R., Schell, J.A., Deering, D. 1973. Monitoring vegetation systems in the Great Plains with ERTS. In Proceedings of the Third ERTS-1 Symposium, NASA SP-351, Washington, DC, USA, 10-14 December 309–317.
175. Rouse, J., Haas, H., Schell, A., Deering, W., Harlan, C. 1974. Monitoring the vernal advancement of retrogradation (the green wave effect) of natural vegetation; Type III, Final Report; NASA, Washington, DC, USA, 1–371.
176. Royo, C., Aparicio, N., Villegas, D., Casadesus, J., Monneveux, P., Araus, J.L. 2003. Usefulness of spectral reflectance indices as durum wheat yield predictors under contrasting Mediterranean conditions. *International Journal of Remote Sensing*. 24, 4403–4419. <https://doi.org/10.1080/0143116031000150059>
177. Saberioon, M.M., Amin, M.S.M., Gholizadeh, A., Ezri, M.H. 2014. A review of optical methods for assessing nitrogen contents during rice growth. *Applied Engineering in Agriculture* 30 (4), 657–669. <https://doi.org/10.13031/aea.30.10478>
178. Salazar-Gutierrez, M.R., Johnson, J., Chaves-Cordoba, B., Hoogenboom, G. 2013. Relationship of base temperature to development of winter wheat. *International Journal of Plant Production.*, 7, 741–762. ISSN: 1735-6814
179. Sarkar, S., Sagan, V., Bhadra, S., Rhodes, K., Pokharel, M., Fritschi, F.B. 2023. Soybean seed composition prediction from standing crops using PlanetScope satellite imagery and machine learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 204, 257–274. <https://doi.org/10.1016/j.isprsjprs.2023.09.010>

180. *Satognon, F., Lelei, J. J., Owido, S. F. O.* 2021. Use of GreenSeeker and MC-100 as manual tools for nitrogen management and yield prediction in irrigated potato (*Solanum tuberosum*) production. *Archives of Agriculture and Environmental Science*, 6 (2), 121–128.
<https://dx.doi.org/10.26832/24566632.2021.060202>
181. *Schirrmann, M., Hamdorf, A., Garz, A., Ustyuzhanin, A., Dammer, K.H.* 2016. Estimating wheat biomass by combining image clustering with crop height. *Computers and Electronics in Agriculture* 121, 374–384.
<https://doi.org/10.1016/j.compag.2016.01.007>
182. *Segarra, J., González-Torralba, J., Aranjuelo, Í., Araus, J.L., Kefauver, S.C.* 2020. Estimating wheat grain yield using Sentinel-2 imagery and exploring topographic features and rainfall effects on wheat performance in Navarre, Spain. *Remote Sensing*, 12, 2278. <https://doi.org/10.3390/rs12142278>
183. *Sellers, P.J.* 1985. Canopy reflectance, photosynthesis and transpiration. *International Journal of Remote Sensing* 6 (8), 1335–1372.
<https://doi.org/10.1080/01431168508948283>.
184. *Shafiee, S., Lied, L.M., Burud, I., Dieseth, J.A., Alsheikh, M., Lillemo, M.* 2021. Sequential forward selection and support vector regression in comparison to LASSO regression for spring wheat yield prediction based on UAV imagery. *Computers and Electronics in Agriculture*. 183, 106036.
<https://doi.org/10.1016/j.compag.2021.106036>
185. *Shafiee, S., Mroz, T., Burud, I., Lillemo, M.* 2023. Evaluation of UAV multispectral cameras for yield and biomass prediction in wheat under different sun elevation angles and phenological stages. *Computers and Electronics in Agriculture*, 210, 107874.
<https://doi.org/10.1016/j.compag.2023.107874>
186. *Shahi, T.B., Dahal, S., Sitaula, C., Neupane, A., Guo, W.* 2023. Deep learning-based weed detection using UAV images: a comparative study. *Drones* 7, 624. <https://doi.org/10.3390/drones7100624>
187. *Shen, Y., Zhang, X., Yang, Z.* 2022. Mapping corn and soybean phenometrics at field scales over the United States Corn Belt by fusing time series of

- Landsat 8 and Sentinel-2 data with VIIRS data. *ISPRS Journal of Photogrammetry and Remote Sensing* 186, 55–69.
<https://doi.org/10.1016/j.isprsjprs.2022.01.023>
188. *Shendryk, Y., Sofonia, J., Garrard, R., Rist, Y., Skocaj, D., Thorburn, P.* 2020. Fine-Scale Prediction of Biomass and Leaf Nitrogen Content in Sugarcane Using UAV LiDAR and Multispectral Imaging. *International Journal of Applied Earth Observation and Geoinformation* 92, 102177.
<https://doi.org/10.1016/j.jag.2020.102177>
189. *Shi, G., Du, X., Du, M., Li, Q., Tian, X., Ren, Y., Zhang, Y., Wang, H.,* 2022. Cotton Yield estimation using the remotely sensed cotton boll index from UAV images. *Drones* 6, 254. <https://doi.org/10.3390/drones6090254>
190. *Shiferaw, B., Smale, M., Braun, H.J., Duveiller, E., Reynolds, M., Muricho, G.* 2013. Crops that feed the world 10. Past successes and future challenges to the role played by wheat in global food security. *Food Security* 5, 291–317. <https://doi.org/10.1007/s12571-013-0263-y>
191. *Solari, F., Shanahan, J., Ferguson, R., Schepers, J., Gitelson, A.* 2008. Active sensor reflectance measurements of corn nitrogen status and yield potential. *Agronomy Journal* 100(3), 571–579.
<https://doi.org/10.2134/agronj2007.0244>
192. *Solie, J.B., Monroe, A.D., Raun, W.R., Stone, M.L.* 2012. Generalized algorithm for variable-rate nitrogen application in cereal grains. *Agronomy Journal*, 104 (2), 378–387. <https://doi.org/10.2134/agronj2011.0249>
193. *Sozzi, M., Kayad, A., Marinello, F., Taylor, J., Tisseyre, B.* 2020. Comparing vineyard imagery acquired from Sentinel-2 and Unmanned Aerial Vehicle (UAV) platform. *OENO One* 54 (2). <https://doi.org/10.20870/oenone.2020.54.1.2557>
194. *Sozzi, M., Kayad, A., Gobbo, S., Cogato, A., Sartori, L., Marinello, F.* 2021. Economic comparison of satellite, plane and UAV-acquired NDVI images for site-specific nitrogen application: observations from Italy. *Agronomy*, 11 (11), 2098. <https://doi.org/10.3390/agronomy11112098>
195. *Stagakis, S., González-Dugo, V., Cid, P., Guillén-Climent, M.L., Zarco-Tejada, P.J.* 2012. Monitoring water stress and fruit quality in an orange

- orchard under regulated deficit irrigation using narrow-band structural and physiological remote sensing indices. *ISPRS Journal of Photogrammetry and Remote Sensing* 71, 47–61. <https://doi.org/10.1016/j.isprsjprs.2012.05.003>
196. *Stanford G.* 1973. Rationale for optimum nitrogen fertilization in corn production, *Journal of Environmental Quality* 2 (2), 159–166. <https://doi.org/10.2134/jeq1973.00472425000200020001x>
197. *Sumesh, K.C., Ninsawat, S., Som-ard, J.* 2021. Integration of RGB-based vegetation index, crop surface model and object-based image analysis approach for sugarcane yield estimation using unmanned aerial vehicle. *Computers and Electronics in Agriculture*, 180, 105903. <https://doi.org/10.1016/j.compag.2020.105903>
198. *Sumfleth, K., Duttmann, R.* 2008. Prediction of soil property distribution in paddy soil landscapes using terrain data and satellite information as indicators. *Ecological Indicators* 8 (5), 485–501. <https://doi.org/10.1016/j.ecolind.2007.05.005>
199. *Sun, J., Li, Y.P., Zhuang, X.W., Jin, S.W., Huang, G.H., Feng, R.F.* 2017. Identifying water resources management strategies in adaptation to climate change under uncertainty. *Mitigation and Adaptation Strategies for Global Change*, 23 (4), 553–578. <https://doi.org/10.1007/s11027-017-9749-9>
200. *Sun, Z., Li, Q., Jin, S., Song, Y., Xu, S., Wang, X., Cai, J., Zhou, Q., Ge, Y., Zhang, R., Zang, J., Jiang, D.* 2022. Simultaneous Prediction of Wheat Yield and Grain Protein Content Using Multitask Deep Learning from Time-Series Proximal Sensing. *Plant Phenomics* 2022, 1–13. <https://doi.org/10.34133/2022/9757948>
201. *Swoish, M., Da Cunha L. F. J.F., Reiter, M.S., Campbell, J.B., Thomason, W.E.* 2022. Comparing satellites and vegetation indices for cover crop biomass estimation. *Computers and Electronics in Agriculture*, 196, 106900. <https://doi.org/10.1016/j.compag.2022.106900>
202. *Szabó, M., Ángyán, J., Forgács, M., Tirczkai, I.* 1987. Magyarország klimatikus adatainak biometriai elemzése az őszi búza termésátlaga és minősége szempontjából. *Növénytermelés*, 36 (1) 17–30.

203. *Tagarakis, A.C., Ketterings, Q.M.* 2017_a. In-season estimation of corn yield potential using proximal sensing. *Agronomy Journal*, 109, 1323–1330. <https://doi.org/10.2134/agronj2016.12.0732>
204. *Tagarakis, A.C., Ketterings, Q.M., Lyons, S., Godwin, G.* 2017_b. Proximal sensing to estimate yield of brown midrib forage sorghum. *Agronomy Journal*, 109, 107–114. <https://doi.org/10.2134/agronj2016.07.0414>
205. *Teal, R.K., Tubana, B.S., Girma, K., Freeman, K.W., Arnall, D.B., Walsh, O., Raun, W.R.* 2006. In-season prediction of corn grain yield potential using normalized difference vegetation index. *Agronomy Journal*, 98, 1488–1494. <https://doi.org/10.2134/agronj2006.0103>
206. *Tenk A.* 2017. Dicső múltunk I. A Magyaróvári Gazdasági akadémia XIX. századi fénykorszaka és nagy tanári kara (1818-1918). Tarandus Kiadó, Mosonmagyaróvár. ISBN: 978-615-5584-46-6.
207. *Tester, M., Langridge, P.* 2010. Breeding technologies to increase crop production in a changing world. *Science* 327 (5967), 818–822. <https://doi.org/10.1126/science.1183700>
208. *Toth, C., Józskóv, G.* 2016. Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing* 115, 22–36. <https://doi.org/10.1016/j.isprsjprs.2015.10.004>
209. *Tottman, D.R., Makepeace, R.J., Broad, H.* 1979. An explanation of the decimal code for the growth stages of cereals, with illustrations. *Annals of Applied Biology*, 93 (2), 221–234. <https://doi.org/10.1111/j.1744-7348.1979.tb06534.x>
210. *Tubaña, B.S., Arnall, D.B., Walsh, O., Chung, B., Solie, J.B., Girma, K., Raun, W.R.* 2008. Adjusting midseason nitrogen rate using a sensor-based optimization algorithm to increase use efficiency in corn. *Journal of Plant Nutrition* 31 (8), 1393–1419. <https://doi.org/10.1080/01904160802208261>
211. *Tucker C.J.* 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment* 8 (2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

212. *Tucker, C.J., Holben, B.N., Elgin, J., McMurtrey, I.* 1980. Relationship of spectral data to grain yield variation. *Photogrammetric Engineering and Remote Sensing* 46, 657–666.
213. *Valencia-Ortiz, M., Sangjan, W., Selvaraj, M.G., McGee, R.J., Sankaran, S.* 2021. Effect of the solar zenith angles at different latitudes on estimated crop vegetation indices. *Drones* 5. <https://doi.org/10.3390/drones5030080>
214. *Varga, Z.* 2021. A Mosoni-síkot jellemző új éghajlati normál értékek agroklimatológiai elemzése. *Acta Agronomica Óváriensis*, 62 (2). 16–40. ISSN 1416-647X
215. *Varinderpal-Singh, Kunal, Mehtab-Singh, Bijay-Singh.* 2022. Spectral indices measured with proximal sensing using canopy reflectance sensor, chlorophyll meter and leaf color chart for in-season grain yield prediction of basmati rice. *Pedosphere*, 32 (6), 812–822.
<https://doi.org/10.1016/j.pedsph.2022.06.015>
216. *Veverka, D., Chatterjee, A., Carlson, M.* 2021. Comparisons of sensors to predict spring wheat grain yield and protein content. *Agronomy Journal* 113 (1), 2091–2101. <https://doi.org/10.1002/agj2.20621>
217. *Viscarra Rossel, R.A.; Adamchuk, V.I.* 2011. Proximal soil sensing. *Vadose Zone Journal* 10 (4), 1340–1341. <https://doi.org/10.2136/vzj2011.0105br>
218. *Walsh, O.S., Shafian, S., Marshall, J.M., Jackson, C., McClintick-Chess, J.R., Blanscet, S.M., Swoboda, K., Thompson, C., Belmont, K.M., Walsh, W.L.* 2018. Assessment of UAV based vegetation indices for nitrogen concentration estimation in spring wheat. *Advances in Remote Sensing*, 7 (2), 71–90. <https://doi.org/10.4236/ars.2018.72006>
219. *Walsh, O. S., Marshall, J., Jackson, C., Nambi, E., Shafian, S., Jayawardena, D. M., Lamichhane, R., Ansah, E. O., McClintick-Chess, J. R.* 2022. Wheat yield and protein estimation with handheld- and UAV-based reflectance measurements. *Agrosystems, Geosciences and Environment*. 5 (4), e20309 <https://doi.org/10.1002/agg2.20309>
220. *Walsh, O.S., Marshall, J.M., Nambi, E., Jackson, C.A., Ansah, E.O., Lamichhane, R., McClintick-Chess, J., Bautista, F.* 2023. Wheat Yield and

- Protein Estimation with Handheld and Unmanned Aerial Vehicle-Mounted Sensors. *Agronomy*, 13, 207. <https://doi.org/10.3390/agronomy13010207>
221. Wan, L., Cen, H., Zhu, J., Zhang, J., Zhu, Y., Sun, D., Du, X., Zhai, L., Weng, H., Li, Y., *et al.* 2020. Grain yield prediction of rice using multi-temporal UAV-based RGB and multispectral images and model transfer—a case study of small farmlands in the South of China. *Agricultural and Forest Meteorology* 291, 108096. <https://doi.org/10.1016/j.agrformet.2020.108096>
222. Wang, J., Badenhurst, P., Phelan, A., Pembleton, L., Shi, F., Cogan, N., Spangenberg, G., Smith, K. 2019. Using Sensors and Unmanned Aircraft Systems for High-Throughput Phenotyping of Biomass in Perennial Ryegrass Breeding Trials. *Frontiers in Plant Science* 10, 1381. <https://doi.org/10.3389/fpls.2019.01381>
223. Wang, K., Franklin, S.E., Guo, X., Cattet, M. 2010. Remote sensing of ecology, biodiversity and conservation: A review from the perspective of remote sensing specialists. *Sensors* 10 (11), 9647–9667. <https://doi.org/10.3390/s101109647>
224. Wardlow, B.D.; Egbert, S.L. 2008. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains. *Remote Sensing of Environment* 112, 1096–1116. <https://doi.org/10.1016/j.rse.2007.07.019>
225. Webster, C., Westoby, M., Rutter, N., Jonas, T. 2018. Three-dimensional thermal characterization of forest canopies using UAV photogrammetry. *Remote Sensing of Environment* 209, 835–847. <https://doi.org/10.1016/j.rse.2017.09.033>
226. White, M.A., Beurs, K.M.D., Didan, K., Inouye, D.W., Lauenroth, W.K. 2009. Intercomparison, interpretation, and assessment of spring phenology in North America estimated from remote sensing for 1982–2006. *Global Change Biology* 15 (10), 2335–2359. <https://doi.org/10.1111/j.1365-2486.2009.01910.x>
227. Winterhalter, L., Mistele, B., Schmidhalter, U. 2013. Evaluation of active and passive sensor systems in the field to phenotype maize hybrids with high-throughput. *Field Crops Research*, 154, 236–245.

- <https://doi.org/10.1016/j.fcr.2013.09.006>
228. Wilke, N., Siegmann, B., Postma, J.A., Muller, O., Krieger, V., Pude, R., Rascher, U. 2021. Assessment of plant density for barley and wheat using UAV multispectral imagery for high-throughput field phenotyping. *Computers and Electronics in Agriculture* 189, 106380. <https://doi.org/10.1016/j.compag.2021.106380>
229. Xia, J., Liu, M.Y., Jia, S.F. 2005. Water security problem in North China: research and perspective. *Pedosphere* 15, 563–575. ISSN: 1002-0160
230. Yang, W., Nigon, T., Hao, Z., Paiao, G.D., Fernández, F.G., Mulla, D., Yand, C. 2021. Estimation of corn yield based on hyperspectral imagery and convolutional neural network. *Computers and Electronics in Agriculture*, 184, 106092. <https://doi.org/10.1016/j.compag.2021.106092>
231. Yang, B., Zhu, W., Rezaei, E.E., Li, J., Sun, Z., Zhang, J. 2022. The optimal phenological phase of maize for yield prediction with high-frequency UAV remote sensing. *Remote Sensing*, 14, 1559. <https://doi.org/10.3390/rs14071559>.
232. Yost, M., Kitchen, N., Sudduth, K., Sadler, E., Drummond, S., Volkmann, M. 2017. Long-term impact of a precision agriculture system on grain crop production. *Precision Agriculture* 18 (5), 823–842. <https://doi.org/10.1007/s11119-016-9490-5>
233. Yu, J., Wang, J., Leblon, B., Song, Y. 2021. Nitrogen estimation for wheat using UAV-based and satellite multispectral imagery, topographic metrics, leaf area index, plant height, soil moisture, and machine learning methods. *Nitrogen*, 3 (1), 1–25. <https://doi.org/10.3390/nitrogen3010001>
234. Yuan, C., Zhang, Y., Liu, Z. 2015. A survey on technologies for automatic forest fire monitoring, detection, and fighting using unmanned aerial vehicles and remote sensing techniques. *Canadian Journal of Forest Research* 45 (7), 783–792. <https://doi.org/10.1139/cjfr-2014-0347>
235. Yue, J., Tian, J., Philpot, W., Tian, Q., Feng, H., Fu, Y. 2023. VNAI-NDVI-space and polar coordinate method for assessing crop leaf chlorophyll content and fractional cover. *Computers and Electronics in Agriculture* 207, 107758 <https://doi.org/10.1016/j.compag.2023.107758>

236. *Zabala, S.* 2017. Comparison of Multi-Temporal and Multispectral Sentinel-2 and Unmanned Aerial Vehicle Imagery for Crop Type Mapping. Master of Science (MSc) Thesis, Lund University, Lund, Sweden.
237. *Zadoks, J.C., Chang, T.T., Konzak, C.F.* 1974. A decimal code for the growth stages of cereals. *Weed Research*, 14 (6), 415–421.
<https://doi.org/10.1111/j.1365-3180.1974.tb01084.x>
238. *Zhang, L., Zhang, H., Niu, Y., Han, W.* 2019. Mapping Maize Water Stress Based on UAV Multispectral Remote Sensing. *Remote Sensing* 11 (6), 605.
<https://doi.org/10.3390/rs11060605>
239. *Zhang, M., Zhou, J., Sudduth, K.A., Kitchen, N.R.* 2020. Estimation of maize yield and effects of variable-rate nitrogen application using UAV-based RGB imagery. *Biosystems Engineering*, 189, 24–35.
<https://doi.org/10.1016/j.biosystemseng.2019.11.001>
240. *Zhang, T., Tan, Q., Zhang, S., Wang, S., Gou, T.* 2020. A robust multi-objective model for supporting agricultural water management with uncertain preferences. *Journal of Cleaner Production* 255, 120204.
<https://doi.org/10.1016/j.jclepro.2020.120204>
241. *Zheng, Y., Wu, B., Zhang, M., Zeng, H.* 2016. Crop phenology detection using high spatio-temporal resolution data fused from SPOT5 and MODIS products. *Sensors* 16 (12), 2099. <https://doi.org/10.3390/s16122099>
242. *Zhitao, Z., Lan, Y., Pute, W., Wenting, H.* 2014. Model of soybean NDVI change based on time series. *International Journal of Agricultural and Biological Engineering*, 70, 64–70.
<https://doi.org/10.3965/j.ijabe.20140705.007>
243. *Zhitao, Z., Lan, Y., Pute, W., Wenting, H.* 2015. Optimum Monitoring Time for the Normalized Difference Vegetation Index of Crops. *Transactions of the ASABE*. 58(3): 641–647. <https://doi.org/10.13031/trans.58.10693>
244. *Zhou, X., Zheng, H. B., Xu, X. Q., He, J. Y., Ge, X. K., Yao, X., Cheng, T., Zhu, Y., Cao, W., Tian, Y. C.* 2017. Predicting grain yield in rice using multi-temporal vegetation indices from UAVbased multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246–255. <https://doi.org/10.1016/j.isprsjprs.2017.05.003>

245.Zhou, G., Yin, X. 2018. Assessing nitrogen nutritional status, biomass and yield of cotton with NDVI, SPAD and petiole sap nitrate concentration. *Experimental Agriculture* 54 (4), 531–548.

<https://doi.org/10.1017/S0014479717000229>

246.Zhou, W., Liu, Y., Ata-Ul-Karim, S.T., Ge, Q., Li, X., Xiao, J. 2022. Integrating climate and satellite remote sensing data for predicting county-level wheat yield in China using machine learning methods. *International Journal of Applied Earth Observation and Geoinformation*, 111, 102861.

<https://doi.org/10.1016/j.jag.2022.102861>

9.1. Internetes források

URL¹: https://www.ksh.hu/stadat_files/mez/hu/mez0071.html

URL²: <https://physicsopenlab.org/2017/01/30/ndvi-index/>

10. MELLÉKLETEK

19. táblázat: *Genezis kísérlet 48 mintavételi pont koordinátája*

| Pontok | Szélesség | Hosszúság |
|---------------|------------------|------------------|
| 1 | 516653 | 284844 |
| 2 | 516655 | 284845 |
| 3 | 516658 | 284846 |
| 4 | 516671 | 284851 |
| 5 | 516674 | 284852 |
| 6 | 516677 | 284853 |
| 7 | 516690 | 284859 |
| 8 | 516692 | 284860 |
| 9 | 516695 | 284861 |
| 10 | 516708 | 284866 |
| 11 | 516711 | 284867 |
| 12 | 516714 | 284869 |
| 13 | 516651 | 284847 |
| 14 | 516654 | 284849 |
| 15 | 516656 | 284850 |
| 16 | 516669 | 284855 |
| 17 | 516672 | 284856 |
| 18 | 516675 | 284857 |
| 19 | 516688 | 284863 |
| 20 | 516691 | 284864 |
| 21 | 516694 | 284865 |
| 22 | 516707 | 284870 |
| 23 | 516709 | 284871 |
| 24 | 516712 | 284872 |
| 25 | 516649 | 284851 |
| 26 | 516652 | 284853 |
| 27 | 516655 | 284854 |
| 28 | 516668 | 284859 |
| 29 | 516671 | 284860 |
| 30 | 516673 | 284861 |
| 31 | 516686 | 284867 |

| | | |
|----|--------|--------|
| 32 | 516689 | 284868 |
| 33 | 516692 | 284869 |
| 34 | 516705 | 284874 |
| 35 | 516708 | 284875 |
| 36 | 516710 | 284876 |
| 37 | 516647 | 284855 |
| 38 | 516650 | 284856 |
| 39 | 516653 | 284857 |
| 40 | 516666 | 284863 |
| 41 | 516669 | 284864 |
| 42 | 516672 | 284865 |
| 43 | 516685 | 284870 |
| 44 | 516687 | 284872 |
| 45 | 516690 | 284873 |
| 46 | 516703 | 284878 |
| 47 | 516706 | 284879 |
| 48 | 516709 | 284880 |

11. A DISSZERTÁCIÓBAN SZEREPLŐ RÖVIDÍTETT VEGETÁCIÓS INDEXEK FELOLDÁSA

BNDVI – Blue Normalized Difference Vegetation Index
CARI – Chlorophyll Absorption Reflectance Index
CCCI – Canopy Chlorophyll Content Index
CVI – Chlorophyll Vegetation Index
DVI – Difference Vegetation Index
EVI – Enhanced Vegetation Index
GCC – Green Chromatic Coordinate
GNDVI – Green Normalized Difference Vegetation Index
LAI – Leaf Area Index
LCI – Land Cover Index
MCARI – Modified Chlorophyll Absorption in Reflectance Index
NDRE – Normalized Difference Red Edge Index
NDVI – Normalized Difference Vegetation Index
rNDVI – Red Normalized Difference Vegetation Index
reNDVI – Rededge Normalized Difference Vegetation Index
RVI – Ratio Vegetation Index
SIPI2 – Structure Intensive Pigment Index 2
VARI – Visible Atmospherically Resistant Index

12. KÖSZÖNETNYILVÁNÍTÁS

Ezúton szeretném megköszönni mindazoknak a támogatását, akik munkájukkal, útmutatásukkal és bátorításukkal hozzájárultak ezen disszertáció elkészüléséhez.

Köszönöm témavezetőimnek, **Prof. Dr. Kovács Attila Józsefnek** és **Prof. Dr. Milics Gábornak**, hogy a doktori képzés négy éve alatt biztosítottak a folyamatos támogatásukról.

Köszönöm **Dr. Kukorelli Gábornak** és az **Uni-Agro-Food Kft.** minden munkatársának, hogy lehetőséget, területet, technikát és alapanyagot biztosítottak a szántóföldi kísérletek elvégzéséhez.

Köszönöm – külön kiemelve – **Dr. Kulmány István Mihálynak** azt a rengeteg befektetett energiát és önzetlen fáradozást, amellyel segítette a publikációim és egyben doktori disszertációm elkészülését is. Végezetül köszönöm **Kollégáim** szakmai támogatását, valamint **Barátaim** és **Családom** kitartását és türelmét.