

# **DIPLOMADOLGOZAT**

**Jóri Bertalan**

**2025**



**Magyar Agrár- és Élettudományi Egyetem**  
**Szent István Campus**  
**Akvakultúra és Környezetbiztonsági Intézet**  
**Környezetgazdálkodási agrármérnök mesterképzési**  
**szak**

**Kukoricanemesítés hatékonyságának növelése: UAV**  
**kameraszenzor (LiDAR) technológia nyújtotta új módszer**  
**fejlesztése és felhasználása kisparcellás kísérleti állományokban**

**Belső konzulens:** Szemők Gabriella Erzsébet  
pHD hallgató

**Belső konzulens intézete:**  
Növénytermesztési-  
Tudományok Intézet

**Külső konzulens:** Szűcs Károly  
Bayer Hungária Kft

**Készítette:** Jóri Bertalan  
OLWDWH

**Gödöllő 2025**

## Tartalom

1.	Bevezetés és célkitűzés .....	3
2.	Szakirodalmi áttekintés .....	4
2.1	Európa és Magyarország klimatikus helyzete és agrárkockázatai .....	4
2.2	A kukorica, mint kultúrnövény: botanikai, élettani és agrotechnikai alapok .....	5
2.3.	Kukoricaneemesítés: modern kihívások és módszertani trendek (DH, genomika, HTP). 6	
2.4.	Drónok a mezőgazdaságban - rövid fejlődéstörténet és alkalmazási kör.....	8
2.4.1.	A UAV platformok és jellemző repülési paraméterek bemutatása .....	9
2.4.3.	Szabályozási keretek röviden (EU 2019/947; magyar sajátosságok).....	10
2.5.	Szenzortechnológiák bemutatása .....	10
2.5.1.	RGB, multispektrális, hiperspektrális és hőkamera: jellegzetes mutatók, előnyök és korlátok.....	11
2.5.2.	LiDAR szenzorok helyzete és léte a precíziós adatfelvételezés világában .....	12
2.6.	LiDAR technológia háttere: fizikai alapelvei, szenzorok típusai és az adatok előfeldolgozása.....	14
2.7.	A korai életképességi erély (early vigor) és felvételezése LiDAR-szezzorral .....	15
2.7.3	A mérés validációja kézi pontozással; ajánlott küszöbök ( $h_0$ ) és időzítés (V2–V6) 18	
2.7.4.	Kapcsolat a betakarítási adatokkal: hozam és befolyásoló tényezői (TKW, HLW) .....	18
3.	Alkalmazott módszerek.....	21
3.1.	A kísérleti terület leírása .....	21
3.3.	Felhasznált eszközök és gépek és módszerek .....	22
3.3.	Felvételezés leírása, lépései: .....	23
3.4.	Statisztikai módszerek bemutatása .....	24
3.4.1.	A LiDAR-modell és a manuális adatgyűjtés vizsgálata .....	24
3.4.2.	A LiDAR-sznzor által felmért vigor és a hozam kapcsolata .....	25
4.	Eredmények és értékelésük .....	26
4.1.	A korai életképesség erély és a LiDAR-szenzor adatainak összefüggés vizsgálata. 26	

4.2	A hozam és a szenzor adatok összehasonlítása .....	30
4.3	Hibrid-specifikus kapcsolatok (korreláció és lineáris regresszió).....	32
5.	Következtetések és javaslatok.....	35
5.1	A LiDAR adatfelvételezésének következtetései.....	35
5.2	A hibridspecifikus elemzés következtetései.....	36
6.	Összefoglalás.....	37
7.	Irodalomjegyzék.....	38
8.	Mellékletek.....	46
9.	Nyilatkozatok .....	69

## 1. Bevezetés és célkitűzés

A mezőgazdaság tartós fejlődése a társadalom alapvető feltétele. Napjainkban is jelentős erőfeszítések folynak a megfelelő minőségű és mennyiségű élelmiszer előállításáért.

Az ellátási lánc és a gazdasági ágazat szereplői több területen küzdenek kihívásokkal. Rendszeresen hallhatunk mezőgazdasági aszálykárokról, viharok okozta károkról, illetve a világban zajló konfliktusokból eredő agrárpiaci zavarokról. E kihívások innovációval és adaptációval mérsékelhetők vagy kezelhetők.

A kutatás-fejlesztésben végzett munka során a hatékonyságnövelő és innovatív megoldások kidolgozása áll a fókuszban. Munkahelyemen, a Bayer Hungária Kft.-nél testközelből tapasztalható, hogy a fenti kihívások milyen mértékben lassíthatják és befolyásolhatják a kísérleti területek működését. Az érintett nemesítőállomás kukorica- és repcevetőmag-kutatási és -fejlesztési kísérleteket valósít meg, és adatot szolgáltat az európai és globális nemesítési hálózat számára. Az ilyen irányú kutatás elengedhetetlen az állandó és biztonságos takarmányellátás támogatásához, a modern kukorica- és repcehibridek pedig ezt a célt szolgálják.

Az állomáson végzett munka teljes mértékben adatközpontú: az általunk előállított elsődleges érték a nyers adat. Az adatfelvétel jelenleg is folyamatos átalakuláson megy keresztül, amelynek eredményeként nő a mért adatok pontossága, és csökken az adatfelvételhez szükséges erőforrás-igény. A digitális módszerek fokozatosan kiváltják a manuális adatfelvételt. Különösen fontos szempont az adatok pontossága és egységes begyűjtése.

Diplomadolgozatomban a kisparcellás kukoricaállományok UAV (Unmanned Aerial Vehicle-Pilóta nélküli légi jármű) -alapú LiDAR(Light Detection And Ranging) -technikával végzett digitális adatfelvételének bemutatását és ezen technológia segítségével begyűjtött adat felhasználását tűzöm ki célul. Kutatásom feltárja, hogy a LiDAR-ból szenzor segítségével felvételezett nyers, majd feldolgozott adat (pl. korai növekedési erély, növényborítottság) mennyiben járulnak hozzá a hozamhoz kapcsolódó teljesítményindikátorok előrejelzéséhez, és milyen mértékben egészíthetik ki vagy akár válthatják le a hagyományos, manuális adatfelvételt a kisparcellás kísérleti hálózatokban.

## 2. Szakirodalmi áttekintés

### 2.1 Európa és Magyarország klimatikus helyzete és agrárkockázatai

Elsőként tegyük is tisztába, hogy mi az egyik legkomolyabb agrár kockázati tényező: az aszály. Az aszály tartós vízhiányos állapot, amely a szokásosnál alacsonyabb csapadék és vagy megnövekedett párolgási igény (hőmérséklet, szél) miatt alakul ki. (Barros et al., 2012) Ezért relatív fogalom, amit mindig a helyi klímához kell viszonyítani. Következménye a talajnedvesség és a felszín alatti vizek hiánya, valamint a mikro- és makroklímák teljes felborulása.

Az elmúlt évtizedben Európa a globális átlagnál is nagyobb mértékben melegedett, mindezek mellett az időjárás egyre szélsőségesebb. Ha az 1980-as klimatikus adatokat vesszük alapul napjainkra a melegedés mértéke kétszer akkora, ezzel párhuzamban nőtt a hóhullámokkal rendelkező napok száma is egy évben. Egyre gyakoribbak az intenzív, nagy mennyiségű csapadékkal lesújtó viharok is. A 2022-es év különösen súlyos, Európa-szintű aszályhelyzetet hozott, közvetlen mezőgazdasági és ökológiai következményekkel, ami ráirányította a figyelmet a klímaérzékeny ágazatok alkalmazkodási képességére. (ESOTC, 2022, 2023).

Magyarországon a 2022-es évben bekövetkezett aszály történelminek nevezhető mivel 1901 óta mért legszárazabb nyári félévet rögzítették a meteorológusok. A helyzetet különös nehézségét az jelentette, hogy a tenyészidőszak kritikus pontján, a kukorica növény virágzás időszakában gyakorolt nyomás a szántóföldi kultúrákra. A Központi Statisztikai Hivatal (KSH) adatai szerint az ebben az évben betakarított szántóföldi kultúrák hozamai kétszámjegyű visszaesést is mutattak: az őszi búza 21 %-kal csökkent a napraforgó 29 %-kal, a repcéé 31 %-kal. De mindezek mellett a kukorica, mint a leginkább vízigényes kultúra Magyarországon 57%-os hozam visszaesést mutatott (KSH, 2023).

Az ilyen és ehhez hasonló klimatikus trendek átírják a nemesítési- és termesztési technológia már jól kialakult prioritási listáját, amely előtérbe kizárólag a maximum hozamot helyezte, ezt felváltja az egyre magasabb stressz tűrés és a stabil terméshozam. Ilyen stressz tényezők a hó és aszály tűrés, törés vagy dőlés elleni ellenállóság esetleges koraiság. (Araus & Kefauver, 2018). Az ilyen mértékű szelekciós folyamat felgyorsulását kizárólag pontos és nagy számban ismételtető módszerek tudják követni. Ennek köszönhetően a pilóta nélküli légi járművek (UAV) igen meghatározó építőköve lett a mai nemesítési folyamatoknak, Mivel mindazok

mellett, hogy költséghatékony kifejezetten alkalmas kulcs fázisok sűrű mintavételezése. (Xie & Yang, 2020; Yang et al., 2017a)

## 2.2 A kukorica, mint kultúrnövény: botanikai, élettani és agrotechnikai alapok

A kukorica (*Zea mays* L.) melegkedvelő, C4-es fotoszintézisű egynyári pázsitfű. A C4-es anyagcsere miatt nagy fényintenzitás és magas hőmérséklet mellett is hatékony a szénmegkötése, ami magyarázza, hogy a faj széles éghajlati tartományban versenyképesen termesztendő kultúrnövény. A tenyészidő igen tág határok között változik: a rövid ( $\approx 90$  napos) és a hosszú ( $\geq 180$  napos) hibridek egyaránt elterjedtek esetekben akár 300 napos termesztési időről is beszélhetünk (FAO GAEZ, 2022). Csírázáshoz jellemzően  $\sim 10$  °C az alsó küszöb, az optimális talajhőmérséklet 18–20 °C körül van; fagyérzékenysége főként a korai fenofázisokban kritikus (Nleya Thandiwe Nleya et al., 2019). A C4-élettani előny ugyanakkor csak addig érvényesül, amíg a talajnedvesség nem válik limitálónak. (FAO GAEZ, 2022).

A kukorica növény fejlődés menete jól tagolható, két fő szakaszra bontható, vegetatív (Vn) és generatív (R) szakaszokra. A levelek és ezen levelek szárölelő gallérjainak megjelenése alapján jelölt V-stádiumokkal jellemzik a növekedést egészen a címerhányásig, majd az R1 jelzéssel a bibehányás („silking”) stádiuma követi. Ezután pedig a szemfejlődés különböző telítődés, száradás „blister–milk–dough–dent” (R2–R5) és egyéb állapotai határozzák meg (Steven W. Ritchie et al., 1993). Végül a fiziológiai érés (R6) zárják, amely 55-60 nappal a bibe virágzást követően történik. A V12–VT és különösen az R1 körüli, nagyjából kéthetes ablak a termésképzés „kritikus periódusa”: itt dől el a végső szemszám mivel a szembekötés ekkor zajlik le. Továbbá a sikeres szemmegkötést meg lehet figyelni az ASI (pollen- és bibehányás közti időközlönbség) hossza is jelez. Ezek a fenológiai fázisok kritikus döntéshozatali pontoka továbbiakban alkalmazandó agrotechnológiai beavatkozásokhoz esetleegs drasztikusabb döntésekhez (tápanyag-időzítés, növényvédelem, öntözés) (Nleya et al., 2019).

A hozam élettani oldalról a talajban feltárható és felvehető tápanyag források viszonyai, a nitrogénfelvétel és -hasznosítás (N-use efficiency) és az állománysűrűség–fényintercepció együttese határozza meg (Ciampitti & Vyn, 2012). A modern hibridek javulása részben a virágzaskori stressztűrés erősödéséből és a maradékasszimilációk nagyobb arányából ered, ami a sűrűbb állományokhoz való fiziológiai alkalmazkodással (állóképesség, levélállásszög, szemtelítődési hatásfok) áll összefüggésben (Tollenaar és Lee, 2006).

Állományszinten a hozamot nagyban befolyásolja a növény tényleges felépítése: a növénymagasság, a levélfelület-index (LAI), valamint a levélállás és -eloszlás együtt határozza meg a fényhasznosítást és a biomassa-felhalmozást. (Tollenaar & Lee, 2006) Ma már ezeket a tulajdonságokat nagy elemszámon, nem roncsolásos módon mérjük: fotogrammetriával előállított koronaszint-modellek, UAV-LiDAR pontfelhők és ferde/nadir képalkotásból becsült LAI-mutatók révén (Madec et al., 2017). Kukoricában bizonyított, hogy a magasság és a LAI idősoros UAV-követése jól visszaadja a fejlődési dinamikát és a hozamhoz kötődő mintázatokat. (Che et al., 2020)

A LiDAR egyik különleges erőssége, hogy növényenként, egyed szinten is képes pozíció- és magasságbecslésre, így az állomány vagy parcella finom térképezése megoldható. Az egyedek közti versengés és a mikrovariabilitás határozottabban kirajzolódik a pontfelhőből. (Gao et al., 2022) Ugyanez a pontosság a megdőlt (lodged) állományok diagnosztikájában és idősoros nyomon követésében kulcsfontosságú: a dőlés mértéke és lefolyása számszerűsíthető, ami közvetlen input a döntéstámogatásba (Zhou et al., 2020)

A nemesítési gyakorlatban ma már a genom-alapú szelekció, a nagy áteresztőképességű (HTP) szelekció és a „digitális termesztés” integrációja gyorsítja a döntéshozatali folyamatot (Araus & Kefauver, 2018b). A repüléssel alkalmazható szenzorok - köztük a LiDAR és a multispektrális kamerák - adatai a nemesítési döntéshozatal folyamatába építve gyorsítják és pontosítják a döntéshozatalt. A drónos távérzékelés agráralkalmazásairól szóló korai áttekintések jól mutatják a technológiai ívet (Zhang & Kovacs, 2012a), a „digitális nemesítés” pedig mára a szelekciós folyamatok szerves része ((Varshney et al., 2018)

### 2.3. Kukoricanevelés: modern kihívások és módszertani trendek (DH, genomika, HTP)

A modern kukorica nemesítés igen nehéz helyzetben van mivel 2 igen különböző fronton kell az igényeknek megfelelni. Egyrészt a klimatikus viszonyok miatt nő a hő- és vízstressz alatt okozott stressz tűrés iránti igény (Cairns et al., 2013), másrészt a termesztési technológia magasabb vetési tőszám és a zártabb állományszerkezet felé tolódnak. Ezek teremtik meg a kívánt hozam stabilitást, amelyet a piac igényel(Tollenaar & Lee, 2006). A modern hibridek ehhez erectofil lombarchitektúrával (felállóbb levélszög) alkalmazkodnak, ami csökkenti a felső lomb szintek önárnyékolását és mélyebbre engedi a fényt a zárt levélszerkezetben (Ciampitti & Vyn, 2012) - különösen nagy tőszámon. A kompaktabb címer kisebb vegetatív terhet ró a virágzáskori tápanyagfelhasználásra, miközben a rövidebb ASI kedvez a szem

bekötésnek még mérsékelt stressz alatt is (Bolaños & Edmeades, 1996). Ezzel párhuzamosan a kukorica növény száradási habitus 'stay green'- azaz a levélöregedés késleltetése - meghosszabbítja a nettó fotoszintézist a szemtelítődés kritikus szakaszában, ami telítődési hatásfok-javulást és hosszú távú szemstabilitást eredményez magas állománysűrűség mellett. A kép teljességéhez hozzátartozik a szárszilárdság és a gyökérarchitektúra javulása is, amely a szár bibe alatti megdőlésének 'lodging'- a kockázatát mérsékli, aminek eredménye nem csak egy sűrűbb és ellenállóbb állomány, hanem a betakarítási folyamatokat is megkönnyíti. (Ciampitti & Vyn, 2012; Tollenaar & Lee, 2006).

A genetikai előrehaladás felgyorsításának egyik építő- és alapköve a doubled haploid (DH) technológia, amely a haploid indukció és a kromoszóma-duplázás révén egy vegetációs ciklusra rövidíti az önmegetermékenyítési folyamatot, így rövidebb idő alatt áll rendelkezésre nagyszámú, genetikailag azonos és állandó vonal tesztkeresztezéshez és ezek értékeléshez; a DH ezért a nagy teljesítményű nemesítő cégcsoportok alapvető eszköze (Chaikam et al., 2019). A másik alappillér a genom szelekció (GS) (Crossa et al., 2017), amely genotípus-, fenotípus- és környezeti kovariánsokkal tanított algoritmusokkal és informatikai modellekkel előre jelzi a termesztési adatokat, hozamot. Ennek köszönhetően a korai nemzedékekben a jelöltek jelentős része terepi szelekció nélkül is megvizsgálható. A GS mára szervesen kapcsolódik a „digitális nemesítés” gyakorlatához, ahol a predikciókat HTP-fenotípusokkal és környezeti adatokkal egészítik ki a G×E (Genotípus x Környezet) - robusztusság növelése érdekében (Crossa et al., 2017)

A szántóföldi szelekció legszűkebb keresztmetszete - a nagy számú, ismételt és költség, valamint munkaigénye kicsi - ma UAV-alapú, multi szenzoros munkafolyamat modellekkel megoldható probléma. A fotogrammetriás eljárás nagy átfedésű RGB-képeiből előbb felszínmodell (DSM), majd talajmodell (DTM) számítunk, ebből a két adathalmazból kapjuk meg a lombkorona-magasság modellt (CHM = DSM–DTM), amely parcellaszinten magasságmutatókat szolgáltat (pl. H\_átlag, H\_95), és idősorba rendezve megbízhatóan visszaadja a parcellák aktuális állapotát magasság tekintetében a V-stádiumoktól a címerhányásig. A módszer előnye, hogy standardizált repülési és képfeldolgozási modellekkel nagy ismétlés számmal, összehasonlítható kész adatot szolgáltat sok kisparcella azonos időponti felmérése révén. (Madec et al., 2017). A szármegdőlés objektív, idősoros nyomon követése szintén megoldott UAV-technológiával LiDAR szenzorokkal (dőlés mértéke, lefolyása, önregeneráció), ami a nemesítők és döntés hozóknak kulcsfontosságú adatot szolgál a döntéshozatalhoz. (Zhou et al., 2020).

Az adathalmazok összekapcsolása (RGB + hő + LiDAR) és a gépi tanulás alkalmazása - különösen a mélytanulási architektúrák - jelentősen növeli a nemesítési szelekció pontosságát, különösen akkor, ha a képi textúra- és szerkezeti jellemzőket explicit módon integráljuk a modellbe (Nguyen et al., 2023) (2023). A többkörnyezetes tesztelés (MET – Multi Environment Testing) újragondolása pedig egy új innovatív irányba mutat, amelyben a modellek környezeti jellemzőket és adatokat (meteorológia adat, talaj összetétel) is figyelembe vesznek, így a G×E mintázatok korábban kirajzolódnak, és a szelekció célkörnyezetre (TPE) optimalizálható (Varshney et al., 2018).

A gyakorlatban mindez egy egymásra szorosan épülő folyamat, rendszerre áll össze. Kiinduló pont a DH-előállítás – a beltenyésztési ciklus egy szezonra rövidítése és állandó genetikájú vonalak gyors előállítása (Chaikam et al., 2019) Ezt folytatja a korai GS-előszűrés (genotípus + minimális szelekció) a vizsgált hibridek gyors rangsorolására és a ciklusidő rövidítésére; (Crossa et al., 2017). A következő állomás a HTP-intenzív középciklus szántóföldi UAV-mérésekkel (fotogrammetriás CHM; LiDAR-pontfelhő a szerkezeti és dőlési kockázati mutatókhoz) (Madec et al., 2017; Walter et al., 2019; Zhou et al., 2020). Közelítve a komplex folyamat utolsó állomásait a MET + hozam és minőségi végértékelés következik. Itt több környezetben, a célkörnyezetre (TPE) kalibrált döntések születnek (Cooper & Messina, 2021). Az egész rendszert az újonnan feltörekvő agrár-UAV felvételek által megvalósítható technológiai áttörése tette lehetővé, amely a szenzortechnológiát termelési környezetben is reprodukálható és költséghatékony eszközzé alkotta (Zhang & Kovacs, 2012a), miközben a genom szelekció és adatalapú komponensek a laborból fokozatosan a rutin szelekciós döntéshozatali folyamatok szerves részévé váltak (He et al., 2024).

## 2.4. Drónok a mezőgazdaságban - rövid fejlődéstörténet és alkalmazási kör

A kis méretű, pilóta nélküli légi járművek agrár iparágban történő alkalmazása az elmúlt bő egy évtizedben a kutatás fejlesztési kísérletektől a rutinszerű üzemi bevonásig jutott. A technológia életkorát tekintve korai értekezésben Zhang és Kovács már 2012-ben felrajzolták a lehetséges fő alkalmazási ívet (állományfelmérés, növényegészségügy, változó dózisu input-kijuttatás, foltkezelés), összefoglalva kiemelt hangsúlyt helyeztek a költség-/időhatékony, nagyfelbontású adatszerzés lehetőségére. Az Élelmezésügyi és Mezőgazdasági Világszervezet (FAO) 2018-as összegzése ezt gyakorlati esettanulmányokkal támasztja alá (FAO, 2018). A technológia megismerése és elterjedése óta a témával foglalkozó szakmai tartalmak száma

drasztikusan megnőtt és tematikák, súlypontok is eltolódtak. Egyrészt nőtt a multiszenzoros (RGB, multispektrális, thermál, LiDAR) és idősoros megközelítések aránya (OECD, 2021), másrészt a permetező drónok biztonsági és hatékonysági vonatkozásai kerültek fókuszba (Guebsi et al., 2024).

#### 2.4.1. A UAV platformok és jellemző repülési paraméterek bemutatása

A drónokat lehet több különböző szempont szerint csoportokba sorolni. Egyik ilyen és igen elterjedt csoport elnevezése, a rotorok száma alapján kategorizált csoport. Ekkor multirotor platformokról beszélhetünk, ami lehet -quad -hex -okto propelleres. Ennek a csoportnak az előnye a jó lebegési tulajdonság és a precíz pozicionálás, ami a kisparcellás kísérletekben való alkalmazását és az alacsony magasságú, részletességet igénylő repüléseknél különösen értékes. Ugyanakkor a repülési idő az ilyen típusoknál rövidebb, ezért nagyobb területen való alkalmazása során több akkumulátorcserét és precíz szektor kialakítást követel meg a pilótától (Rejeb et al., 2022). A merevszárnyú (fixed-wing) rendszerek nagyobb területet fednek le egyetlen repüléssel. A rögzített szárnyú drónok, mint például a SenseFly eBee, előnye, hogy egy akkumulátor csomaggal hosszabb a repülési idejük, így amellet, hogy szignifikánsan gyorsabbak nagyobb területet is fednek le. Hátrányuk, hogy le- és felszálláshoz nagyobb helyre van szükségük, és irányításukhoz több rutin szükséges. Egy ilyen légi eszköz maximális sebessége akár 80 km/h-t is átlépheti. Ezért a fix szárnyú UAV-k ideálisak légi felmérésekhez, ahol csak a nagy felbontású légi felvételek készítésére van igény, mint például térképezéshez és földmérési feladatokhoz. A korlátozás a felszálláshoz és leszálláshoz szükséges kifutópálya követelményében rejlik. Ezzel szemben a többrotoros UAV-k alacsonyabb sebessége, és rövidebb repülési ideje ellenére is kedvezőbb döntés. Fürge manőverezésük, egy adott terület felett való lebegésük és szűk területeken való működésük okán ideálisak a mezőgazdasági célú felhasználásra (FAO, 2018).

A különböző csoportba tartozó drónok több egyedi cél és mutató származtatására lehetnek alkalmasak. Az RGB/multispektrális idősorokból származtatott indexek (NDVI - Normalizált vegetációs index, GNDVI - Zöld normalizált vegetációs index, NDRE - Normalized Difference Red EDGE) és szerkezeti jellemzők (pl. fotogrammetriás magasság) a növekedési dinamika és a stresszjelek korai detektálását támogatják; a LiDAR vagy a precíz, magas átfedésű fotogrammetria a parcellaszintű magasság/szerkezet megbízható jelzőszámát adják (Micheletto et al., 2023) Nagyobb méretű és teherbírású típusok lehetnek input-kijuttatási célra tervezve (permetezés, csomagszállítás). A permetező drónok erőssége a lehatárolt és pontszerű kezelések lehetősége, a kezelést végző személy kitétségeinek csökkentése és a nehezen megközelíthető

területek kezelése (pl. meredek, teraszos ültetvények). Ugyanakkor az elsodródás és a cseppméret kontrollja, a jogszabályi megfelelés, és az engedélyezés az alkalmazás előfeltétele. A gyakorlatban a permetező műveletek RTK-támogatással és szenzoros visszacsatolással (tank-szint, áramlás, cseppméret) valósulnak meg (García-Munguía et al., 2024).

Minden egyéb precíziós tevékenység és komoly szakmai feladat ellátásán túl megfigyelés és őrzési feladatokra is bevethető ez a technológia. A drónok alkalmasak kerítés- és felsővezeték monitoringra, öntöző- és csatornahálózat ellenőrzésre, valamint mezőgazdasági vonatkoztatásban kártevő-/betegség foltok gyors azonosítására. Ezeken a területeken a beavatkozás sebességét és az input-anyag költség drasztikus csökkentését eredményezheti a dróntechnológia (Samad et al., 2013)

#### 2.4.3. Szabályozási keretek röviden (EU 2019/947; magyar sajátosságok)

Az egységes uniós keretet a 2019/947/EU végrehajtási rendelet adja meg. Meghatározza a három fő jogosítványi kategóriát, amelyek az Open, Specific és Certified kategóriák. Az agrárcélú adatfeltáró és gyűjtő repülések többsége a repülő tárgy tömege, mérete és kockázati tényezői okán az Open kategória A1/A2/A3 alá esik, ezt az Európai Unió 2019/947 rendeletében meg is határozza. Hazánkban a gyakorlatban e szabályok nemzeti végrehajtási előírásokkal és légtérhasználati sajátosságokkal egészülnek ki. A MyDroneSpace rendszer (HungaroControl által fejlesztett) biztosít légtér-tájékoztatást és - helyenként - műveleti korlátozási információkat; a kijelölt „No Drone Zone” kivételével - 40 m AGL (Föld Szint Felett) -ig engedély nélkül lehetséges UAV repülés, de szigorú feltételekkel. A lakott területek feletti repülésekhez - a rendezvény- vagy városi repülések tipikus eseteiben - ideiglenesen kijelölt légtér igénylése lehet szükséges, amelyet előre benyújtott kérvénnyel kell az illetékes légiirányítási központ felé jelezni. (Hartmann et al., 2024)

#### 2.5. Szenzortechnológiák bemutatása

A terepi távérzékelésben néhány alapszabály szinte mindig igaz: minél gazdagabb a spektrum, annál több élettani jelenségről nyerünk közvetlen információt; minél jobb a geometria (irányítás, illesztés), annál megbízhatóbb a térbeli összehasonlítás; és minél egységesebb a radiometria, annál jobban működnek az ismétlések és a többhelyszínes összevetések (Tsouros et al., 2019)

### 2.5.1. RGB, multispektrális, hiperspektrális és hőkamera: jellegzetes mutatók, előnyök és korlátok

A szántóföldi UAV-alapú fenotipizálásban a passzív szenzorok együttes célja, hogy a növényállomány struktúrájára és fiziológiai állapotára egyszerre adjanak értelmezhető, időben összevethető jelzést; mindehhez egyrészt a fotogrammetria (RGB-ből számított felszín- és kanopimodellek (Yang et al., 2017)) (Madec et al., 2017) kínál robusztus geometriai leírást, másrészt a spektrális módok (multi-/hiperspektrális, termál) szolgáltatnak élettani információt - ám csak akkor, ha a terepi protokoll a megvilágítás, a radiometriai kalibráció és a szenzorgeometria ingadozásait megfelelően kontrollálja, különben a több helyszín–időpont közötti összevethetőség elvész (Aasen et al., 2018).

Az RGB a látható tartományú fényjeleket (3 sávós) rögzítő kamerák rövidítése. Az RGB-kamerák legnagyobb gyakorlati értéke abban rejlik, hogy magas térbeli felbontással és alacsony költséggel teszik lehetővé a parcellaszintű morfológiai és textúra-alapú elemzést - ideértve a fedettség és a sorköz-mintázat térképezését, valamint a fotogrammetriás CSM/CHM számítását (Madec et al., 2017), amely sok esetben jó helyettesítő mutatója a kézi magasságmérésnek és érdemi korrelációt mutat biomassa-mutatókkal, ezért a korai szelekcióban megbízható adatot szolgáltat a döntéshozó személyeknek (Bendig et al., 2015). Ugyanakkor nem szabad szem elől téveszteni azt a tulajdonságot, hogy az RGB spektrálisan szegény képet rögzít, így a nitrogénellátottság és a vízellátottság finom változásai tipikusan csak közvetett, megvilágítás- és árnyékviszonyokra érzékeny „zöldesség” indexekben (VARI, ExG) tükröződnek. Ezért a radiometriai, az egységes expozíció és mechanikus zár alkalmazása nem elegáns „extra”, hanem a reprodukálhatóság feltétele (Habib et al., 2016).

A multispektrális szenzorok a három alap (kék-zöld-vörös) sávon túl a red-edge és NIR sávok bevonásával már biokémiaileg értelmezhető indikátorokat adnak. A klasszikus NDVI a zöldtömeg és általános életerősség jó mérőszáma, míg a GNDVI és az NDRE érzékenyebben követi a klorofill/N-státusz finom elmozdulásait, s ráadásul a red-edge csatorna mérsékli az NDVI közismert szaturációját közepes–magas LAI mellett (Ge et al., 2025). mindez magyarázza, hogy a korai erély és az N-státusz-rangsorolás tipikusan ezen a modalitáson áll stabil lábakon (Yang és mtsai, 2017). A kompromisszum ára a protokoll pontos betartása. A paneles visszaverődés kalibráció, downwelling (napfény csökkenés) szenzor használata, valamint a repülési sávok precíz meghatározása és napszög/BRDF-korrekció szükséges ahhoz, hogy egy különböző napokon, változó égbolt mellett gyűjtött idősor ne váljon zajos és nehezen értelmezhető adathalmazzá (Zeng et al., 2017).

Hiperspektrálisnak nevezzük az olyan szenzort, amely több száz, nagyon keskeny spektrális sávban rögzíti az adatokat, így a hagyományos kameráknál sokkal részletesebb információt nyújt. A hiperspektrális képalkotás azzal teremt hozzáadott értéket, hogy szűksávú pigment- és red-edge indexek (pl. MTCI, TCARI/OSAVI, PRI) és spektrális ujjlenyomat-alapú kemometriai jellemzők révén nemcsak a zöld állapotot, hanem szubtilis fiziológiai állapotváltozásokat (pigmentek-átrendeződés, víz/szerkezeti jelek, Esetenként kórokozói jelzőket) is képes korán jelezni (Garzonio et al., 2017). Ennek ára a nagy adat- és kalibrációs igény, a spektrális-geometriai torzulások (smile/keystone) gondos korrekciója, és a módszertanilag fegyelmezett kiértékelés (dimenziócsökkentés, keresztvalidálás, helyszín-évek közötti adaptáció), amely nélkül a hiperspektrális előny könnyen elpárolog (Adão et al., 2017).

A termál modulok különleges értéke, hogy a lombhőmérsékleten és a levegőhöz viszonyított hőkülönbségen keresztül közvetlen fiziológiai kapu nyílik a sztómavezetés és a vízháztartás felé, ezért az aszály- és hőstressz térképezésében, illetve az öntözési döntéstámogatási rendszerekben kiemelt szerepet képvisel. Azonban a kibocsátás megválasztása, a háttérsugárzás és a mikroklíma (szél, páratartalom) korrekciója kritikus, továbbá a szenzorok natív térbeli felbontása alacsonyabb és elcsúszásra hajlamos, ami szigorú időzítési és kalibrációs rutint kíván (Santesteban et al., 2017; Berni et al., 2009).

Összegezve a fentebb jellemzett módszereket, ha a kutatási szempontból kérdés a struktúra-domináns (fedettség, magasság, sűrűség, sorközök, dőlés), az RGB + fotogrammetria az ideálisan választandó szenzortípus, amelyet, amennyiben a vertikális profil és az ismételhetségi komponens is kritikus akkor LiDAR-ral célszerű kiegészíteni (Madec et al., 2017). Amennyiben a klorofill/N-státusz vagy korai erély rangsora a megvizsgálni kívánt adat, a multispektrális red-edge kínálja a legjobb ár/érzékenység kompromisszumot (Yang et al., 2017). Ha szubtilis fiziológia (pigmentek, víz- és biokémiai jegyek, betegség-előjelek) a fókusz, a hiperspektrális modulok a számunkra nélkülözhetetlen eszközök (Aasen et al., 2018). Ha pedig vízháztartás/öntözési döntések vannak napirenden, a termál, lehetőleg VIS–NIR információval fuzionálva, kapjuk meg a kívánt adatot (Berni et al., 2009; Santesteban et al., 2017).

#### 2.5.2. LiDAR szenzorok helyzete és léte a precíziós adatfelvételezés világában

Amikor a növényállomány felszíne egynemű (pl. záródó kukorica, gyenge mintázatú lombzat), vagy a megvilágítás instabil (felhőátvonulás, alacsony napállás), a képalapú 3D-rekonstrukció a fotópontok kevés jellegzetessége és a BRDF-hatás miatt bizonytalanabb,

miközben a LiDAR a megvilágítástól függetlenül ugyanazon geometriai pontossággal mintázza végig a parcellákat; ilyen körülmények között a pontfelhő stabilabb magassági és sűrűségi mutatókat ad a struktúra időbeli követéséhez (Walter et al., 2019).

A többvisszaveréses LiDAR képes a sugár első–köztes–utolsó visszhangjain keresztül a lombkorona rétegezetségét és belső hézagstruktúráját megragadni; a magassági percentilisek ( $H_{10} \dots H_{95}$ ), a rétegzett pontarányok és a résarány (gap fraction) olyan információt hordoznak, amelyhez képalapú módszerekkel legfeljebb proxyként, erős feltételezések mellett lehet közelíteni (Mallet & Bretar, 2009; ten Harkel et al., 2020).

Szél- vagy csapadékesemények után a parcellák dőlése változó mértékű és térben foltos; a LiDAR-idősor a dőlésszög, a felszín-besüppedés és a post-lodging helyreállítás számszerűsítését is lehetővé teszi, így nemcsak az „igen-nem” típusú osztályozásra, hanem a dinamika vizsgálatára is alkalmas — ez szelekciós és agronómiai döntésekben közvetlen előnyt jelent (Zhou et al., 2020).

A kezdeti stádiumokban (V2–V4), amikor a növények ritkák és a talajtextúra dominál, az RGB-alapú CHM-ek a mozaikos textúra és a talaj-árnyék hatásai miatt könnyen torzulnak; normalizált LiDAR-pontfelhőből ezzel szemben alacsony küszöbmagasságok fölötti pontarányokkal (pl.  $z > 0,10 - 0,20$  m) robosztus fedettségű és korai magassági mutatók képezhetők (Madec et al., 2017; Harkel et al., 2020).

Nagy pontsűrűségnél a LiDAR — akár RGB-vel fuzionálva — egyedi növényhelyeket és csúcspozíciókat képes detektálni, ami a tőszám, a hiányok és a térállás-hibák parcellaszintű feltárására szolgál; ez különösen értékes a korai erély és a későbbi hozamstabilitás összekapcsolásában (Gao et al., 20

Mivel a LiDAR mérés radiometriafüggetlen (a fő kimenet a geometria), az egymás utáni felmérések összehasonlíthatóságát kevésbé befolyásolja a napszög, a felhőzet vagy az expozíciós beállítás; ez a növekedési ráta és a szerkezeti változások idősoros becsléséhez felülmúlja a kizárólag képalapú megoldások érzékenységét (Walter et al., 2019).

A modern LiDAR-ok visszhangszám- és intenzitás-adatai — megfelelő távolság-/szögkorrekcióval — a záródás, a levél-hézagrendszer és a felszínérdesség finom jellemzését teszik lehetővé; ezek a „nem magasság” alapú mutatók (pl. echo ratio, rumple/érdesség-index) több kultúrában biomassza- és nitrogénfelvétel-proxikkal is kapcsolatba hozhatók (Hütt et al., 2023).

A LiDAR előnyei csak akkor érvényesülnek maradéktalanul, ha a szenzor GNSS/INS-integrációja, a boresight kalibráció és a sávegyeztetés rendben van, a pontfelhő pedig DTM-kivonással normalizált; a pit-free CHM-képzés és a rétegzett, küszöb-alapú metrikaszámítás (pl. CC(h<sub>0</sub>), gap fraction, H-percentilisek) a kisparcellás környezetben bevált jó gyakorlat (Khosravipour et al., 2014; Micheletto et al., 2023; ten Harkel et al., 2020).

## 2.6. LiDAR technológia háttere: fizikai alapelvei, szenzorok típusai és az adatok előfeldolgozása

A LiDAR lényege az, hogy lézer impulzusok kisugárzás és a visszaverődés idejéből meghatározza a szenzor és a célpont közötti távolságot; az impulzusok hullámhossza (UAV-n jellemzően 905 vagy 1064 nm) és a nyalábnyílás meghatározza a „lábnyomot”, a szkennelési geometria pedig a ponteloszlást a sávon belül (Wehr & Lohr, 1999). A rendszer a visszaverődő jel amplitúdóját/időbeli alakját is rögzítheti; diszkrét visszaverésnél csak a fő csúcs(ok) időpontjait tároljuk, full-waveform rendszerben viszont a teljes jelalak elérhető, ami bonyolultabb levélkorona-szerkezetek elemzését is támogatja (Mallet & Bretar, 2009). A mezőgazdasági területek esetében ezek a többszörös lézer sugár visszaverések a levelek/lombszintek résein áthatolva keletkeznek, így a pontfelhő a virágzat és zászlós levél csúcson túl az növények talajhoz közeli szerkezeti szintjeiről is információt gyűjt be (Micheletto et al., 2023b)

Az alacsony repülési magasságon történő adatfelvételező repülések napjainkban három különböző működésű LiDAR-megoldással jellemzőek. A mechanikus tükrös (forgó/poligon tükrökkel letapogató), a MEMS-alapú (mikrotükrös kitérítésű), illetve ritkábban a flash LiDAR (egyszerre megvilágított mező, kamerás detektálás). A tükrös rendszerek nagyobb mérési távolságot és stabil, jól kalibrálható letapogatósi geometriát adnak, míg a MEMS előnye a kisebb tömeg és energiaigény (UAV-SWaP), a flash pedig közel „pillanatfelvétel-szerű” 3D-s modellt kínál, de ennek hátránya a rövidebb hatótáv és érzékenyebb jel-/zaj viszonyok (Mallet & Bretar, 2009; Micheletto et al., 2023b; Wehr & Lohr, 1999). A mezőgazdasági állományoknál - kukoricában különösen - a többszörös visszaverés és a jelalak információja a kívánt felvételezendő adatforma, mert a lombkorona rétegzettsége és a levelek közötti rések a belső szerkezetet is mintázzák (Mallet & Bretar, 2009). A felvett adatot szükséges georeferálni. A pontos georeferálás előfeltétele a műholdas helymeghatározás (GNSS) és a tehetetlenségi szenzorcsomag (INS) egyesítése; ez ad folyamatos, nagy pontosságú repülési pályát (pozíció, sebesség, dőlés/irány) még gyengébb műholdjel vagy rövid kitakarások mellett is. A

gyakorlatban PPK/RTK megoldásokkal javítjuk a GNSS-pontosságot, a LiDAR-szkenner, az INS és a GNSS közötti hardveres idősinkron (PPS, event marker) pedig biztosítja, hogy minden mérési impulzushoz konzisztens időbélyeg tartozzon (Wehr & Lohr, 1999).

Az ilyen módon keletkezett adatnak szüksége van feldolgozásra. Ezen módon alakul az előfeldolgozási lánc kisparcellás kísérletek tekintetében. A jellemző folyamat felépítés tehát a következő módon alakul: (1) A repülési pálya meghatározása (GNSS/INS) és idősinkronizálás, (2) georeferálás, (3) repülési sávegyeztetés, (4) szélsőséges, kívül eső pontok és zaj eltávolítása, (5) adat osztályozás (talaj vagy nem-talaj), (6) a pontfelhő normalizálása - a talajfelszín (DTM) kivonása a pontmagasságokból, (7) CHM előállítás rácsszerkezetes kialakítással. A CHM-hez célszerű ún. pit-free eljárást használni, mert kevésbé lesz „lyukacsos” és konzervatívabban követi a növény csúcsot (Khosravipour et al., 2014). A fenti lépések már agrár környezetben és standardizáltan működnek, a folyamat pontossága és reprodukálhatósága biztosítja a pozícióját kutatás-fejlesztési szegmensekben (Micheletto et al., 2023)

## 2.7. A korai életképességi erély (early vigor) és felvételezése LiDAR-szezzorral

A „korai erély” alatt azt a fenológiai fázishoz kötött teljesítőképességet értjük, amelyben az állomány gyors levélfelület-képzéssel, záródási sebességgel és biomassza-akkumulációval reagál a környezeti feltételekre; ez az időszak (különösen V2–V6) a későbbi fényintercepció, talajpárolgás-csökkentés, gyomelnyomás és a forrás–nyelő viszonyok beállása szempontjából meghatározó, ezért a nemesítői értékelésben és az agrotechnikai döntéshozatalban is kiemelt célpont. Míg a klasszikus megközelítések a korai erélyt többnyire spektrális (NDVI/NDRE, textúra) indikátorokkal mérik, a LiDAR az aktív, geometria vezérelt mérés előnyeivel egészíti ki a képalapú módszereket (Wahab et al., 2018). A pontfelhőből közvetlenül rekonstruálható a vertikális lombkorona-profil, a rétegezettség és a belső heterogenitás, ami korai fenofázisokban, alacsony kontrasztú felszíneken különösen robusztus jelzést ad (Walter et al., 2019).

### 2.7.1. Definíció meghatározása és kézi értékelése, megbízhatósága

A vigor vagy vetőmag-erő úgy definiálható, mint „a vetőmag olyan tulajdonságai, amelyek meghatározzák a palánták gyors és egyenletes kelésének lehetőségét és fejlődését széleskörű terepi körülmények között (AOSA, 2002). Általánosságban elmondható, hogy az alacsony csírázási sebesség, a magok és palánták stresszel szembeni nagy érzékenysége a csírázási folyamat során, valamint a lassú, alacsony és szabálytalan növekedésű vagy kevésbé fejlett gyökérzetű növények tipikus jellemzői az alacsony fiziológiai potenciállal rendelkező

magoknak (Marcos Filho, 2015). Hampton és Hill, (2002) szerint a vigor nagy hatással van a növények kezdeti populációjának sikerére, valamint azok megfelelő fejlődésére, ami befolyásolja a terméshozamot.

A kézi pontozás a szántóföldi nemesítési gyakorlat klasszikus, gyors módszere, amelynél a felvételezést végző szakember egy rögzített skálán (általában 1–9-ig) értékeli a céltulajdonság súlyosságát vagy fejlettségét; a skála középpontja (5) a „közepes” kategóriát jelöli, a szélek (1, ill. 9) pedig a legkedvezőbb, illetve leggyengébb állapotot rögzítik. A módszer előnye a sebesség és a költséghatékonyság, korlátja viszont a megfigyelői objektivitása, így torzítása és a köztes kategóriák következtelen használata, ami növelheti a zajszintet és csökkentheti az összehasonlíthatóságot több helyszín és időpont között. A LiDAR-alapú parcellaszintű mérések az adatgyűjtési működéséből adódóan alkalmasak a kézi skála külső referencia-rendszerének megteremtésére (pl. fedettséggel szemben a pontok aránya egy küszöb felett; az állomány sűrűsége ↔ vertikális sűrűségprofil), így kialakítható egy olyan procedúra, aminek a megbízhatósága és reprodukálhatósága állandó értéként jelenik meg több repülés és felvételezést végző személy között is. Ezt a gyakorlatot a modern LiDAR-szenzor alapú adatgyűjtésről szóló tanulmányok is szorgalmazzák, különösen ott, ahol a belső lombkorona-szerkezet és a heterogenitás a mérés tárgya olvashatjuk Su et al. (2019) értekezésben.

2.7.2. LiDAR-alapú nem magasság-alapú mérhető adatok: fedettségi hányad, kanopitérfogat-index, résarány, pontsűrűség-küszöbök, visszhangarányok

A LiDAR, mint azt korábban megvizsgáltam, aktív szenzortechnológia, ezért nemcsak „felszínmagasságot”, hanem a visszavert impulzusok eloszlásából a lombkorona belső struktúráját is képes megragadni; ennek megfelelően a parcellaszintű, nem magasság-alapú jellemzők több csoportba sorolhatók.

Első ilyen csoportnak tekinthetjük a fedettségi hányadot ( $CC(h_0)$ ). Ez a normalizált pontfelhő azon pontjainak aránya, amelyek egy adott alsó küszöbmagasság ( $h_0$ ) felett vannak. Ez a mutató számszerűsíti a lombkorona záródásának ütemét és a korai hézagkitöltést, vagyis azt, milyen gyorsan fedi be a növényzet a talajt. Számos növénykultúrában a  $CC(h_0)$  stabilan együtt változik a parcellaszintű biomasszával és a korai vegetatív eréllyel (Walter et al., 2019), ezért korai zöldtömeg-indikátorként is használható.

Folytatásul a csoportba vonható még a kanopitérfogat-index (CVI) is. A pontfelhő rétegzett (voxelalapú) térbeli sűrűségeloszlásából számított térfogatarányos mutató. A CVI egyszerre érzékeny a lombtakaró tömörségére és rétegzettségére, mivel figyelembe veszi a kanopi belső

szerkezetét is. Ennek köszönhetően a CVI sok esetben szoros kapcsolatot mutat a biomassza-jellemzőkkel, például a mért felszín-feletti biomassza (AGB – Above Ground Biomass) értékekkel (Walter et al., 2019). Ebből levonható a következtetés, hogy a nagyobb és sűrűbb lombtömeg magasabb CVI-t eredményez, ami jól korrelálhat a tényleges biomasszával.

A csoport tagja, mint lehetséges adatforrás a résarány (gap fraction). A kifejezés jelentése szó szerint értendő. A lombkoronán áthatoló üres terek arányát határozza meg, azaz azon sugarak hányada, amelyek akadálytalanul eléri a talajt (vagy ennek megfelelően az üres voxelek aránya a kanopiban). A résarány a felső lombszint nyitottságát és a fényáteresztést jellemzi. Ez a mérés a növényállomány-szerkezeti irodalomban megalapozott fogalom, és LiDAR-adatokból is megbízhatóan becsülhető azáltal, hogy a lézersugarak behatolnak a lombkoronába (Hütt et al., 2023). Alacsony résarány sűrű, zárt lombkoronára utal, míg a magas résarány nyíltabb állományt jelez.

Pontsűrűség-küszöbök és magassági változók pedig a vertikális ponteloszlás egyszerű, de informatív leírására szolgáló mérési metodika. A pontsűrűség-küszöb mutatók azt jelzik, hány pont esik bizonyos magassági szintek fölé, míg a magassági percentilisek (pl.  $H_{10}$ ,  $H_{50}$ ,  $H_{90}$ ) azt az adatot tárják fel számunkra milyen százalékban, melyik magassági kategóriában tartozik az állomány. Ezek a jellemzők jól leírják a növényállomány vertikális profilját, és különösen a betakarítás előtti vegetatív fázisban szolgálnak jó tulajdonságként a genotípusok rangsorolásához. Például a magasabb percentilis értékek jellemzően nagyobb növénymagasságot vagy sűrűbb felső lombszintet jeleznek, ami korrelálhat a korai fejlődési előnnyel (Hütt et al., 2023).

Végül, de nem utolsó sorban a visszhangarányok és intenzitás-származékot kell megemlíteni. A LiDAR mérések egyes pontjaihoz tartozhat több visszaverődés is (első, középső, utolsó visszhang), illetve intenzitásérték. E visszhangarányok a lombkorona zártságának, a levél-hézag rendszernek (porozitásnak) és a felszín érdességének finom jelzői. Például sok *first return* és kevés *last return* viszonylag zárt, homogén lombot jelezhet. Agrár-kísérletekben kimutatták, hogy bizonyos visszhang- és intenzitás-mérések korrelációban állnak a növények nitrogén-felvételével és biomassza mennyiségével (Hütt et al., 2023). Ugyanakkor az intenzitásalapú mutatók által begyűjtött nyers adatból származtatott értékek erősen függenek a szenzor – célpont távolságától és szögétől; ezért az intenzitási adatokból származtatott mutatók használata előtt radiometriai korrekció szükséges a távolság- és szögműködés kiegyenlítésére (Kashani et al., 2015).

### 2.7.3 A mérés validációja kézi pontozással; ajánlott küszöbök ( $h_0$ ) és időzítés (V2–V6)

A LiDAR-mérések kézi felvételezéssel történő validációja ajánlott a felvétel készítésével azonos időpontban. További biztonsági lépcső két szakképzett személy bevonása, így nő a szubjektivitás. Statisztikai számításokkal is érdemes validálni az adatokat egyezés- és ismételhetőség-mutatók számításával (pl. ICC Intra class correlation, Cohen-kappa) (Panigrahi et al., 2025). A két külön módon kapott adatfelhőket (LiDAR - kézi gyűjtés) pedig Spearman/Pearson korrelációval és rangstabilitással (Kendall- $\tau$ ) célszerű ellenőrizni (Madec et al., 2017).

A küszöbmagasság ( $h_0$ ) megválasztása az állomány fejlettségétől függ. Amennyiben az állomány V2–V4 közötti a 0,10–0,20 m tartomány különíti el jól a kezdeti hajtásokat a talajtól, míg V5–V6 körül a 0,20–0,30 m sáv ad jobb jel-zaj arányt a fedettség- és résarány-becsléshez. Minden esetben a DTM-kivont (normalizált) pontfelhő használata ajánlott (ten Harkel et al., 2020). A validáció pontosságát növeli, ha a rétegzett mutatókat (pl. CC( $h_0$ ), CC( $h_1$ )) és a percentilis-profil együttesen illesztjük az általunk készített kézi skálára. A korai fenofázisban pedig a térállás-hibák és hiányok feltárása céljából az egyedi növényhely-detektálás is bevonható (LiDAR+RGB fúzióval), ami visszaigazolja a kézi sűrűség-/fedettség-pontokat (Gao et al., 2022; Walter et al., 2019)

### 2.7.4. Kapcsolat a betakarítási adatokkal: hozam és befolyásoló tényezői (TKW, HLW)

Eddigiekben sokat volt szó a magasság és ebből származtatott adatokról. Azonban fontos megemlíteni a nem magasság-alapú szerkezeti mutatókat. Fedettségi hányad, résarány, vertikális sűrűségprofil, visszhangarányok, amely több kísérletben szorosán együtt mozognak a parcellaszintű biomassza-jelzésekkel, s előrejelzésként szolgálhatnak a hozamsorrendhez (Li et al., 2020; Wang et al., 2024).

A szemtermés minőségi és mennyiségi jellemzőit, mint például az ezerszemtömeg (TKW) és a hektolitertömeg (HLW), jelentősen befolyásolja, milyen hatékony volt a szemek töltődése és mennyire volt stabil a növényállomány (történt-e megdőlést okozó stressz). Egy erőteljes, jól záródó állomány jobban tudja asszimilálni rendelkezésre álló tápanyagot a szemekbe, míg a megdőlt vagy megritkult állományokban a fotoszintézis és tápanyagáramlás sérül. LiDAR-mérésekkel kimutatható, ha a lombkorona szerkezete a kritikus fenológiai fázisokban (például a virágzás környékén, R1 fázisban) fellazul, nő a résarány vagy csökken a felső lombsűrűség. Az ilyen szerkezetváltozás gyakran előre jelzi a kötődési problémákat (kevesebb szem képződik vagy telítődik be) és a későbbi hozamvesztést (Zhou et al., 2020) Például, ha a virágzás

idején viharok okozta sérülést következtében részlegesen megdőlt a kukorica állomány és a LiDAR szerint megnőnek a légrések a parcellákon belül, akkor várható, hogy az ezerszemtömeg csökkeni fog, mivel a növény már nem képes optimálisan telíteni a szemeket (Wen et al., 2019). Mérések igazolják, hogy a megdőlés mértéke és időzítése hatással van a szemek fejlődésére: enyhe dőlés ~12%-os, míg súlyos dőlés akár >75%-os termés kiesést is okozhat (ENNOS et al., 1993).

Az ilyen jellegű dőlés (lodging) utóhatása is ismétlődő LiDAR felméréssel számszerűsíthető. A megdőlés mértéke és a növényállomány utána bekövetkező regenerációjára fókuszálva. A LiDAR-pontfelhőkből nyert növénymagasság-profil időközök során követve megállapítható, milyen arányban állt helyre a magasság a dőlési esemény után. Kísérletek szerint genotípusonként eltérő a helyreállási mértéke. Egyes hibridek gyorsan és nagy arányban kiemelik a megdőlt szárazakat, míg más genetikájú növények tartósan alacsonyabbra törnek a szezon hátralevő részében. Ezek a különbségek természetesen a végső hozamban is megmutatkoznak (Hu et al., 2021). A jobb helyreálló képességű genotípusok általában kisebb hozamvesztést szenvednek. Továbbá a szemnedvesség tekintetében is különbségek adódnak. A jobban regenerálódó állományok szemei egyenletesebben és szárazabban érnek be, míg a megdőlt maradó állományokban gyakran több a nedves, éretlen szem betakarításkor (amit a HLW is ront) (Lauer, 2008). Hu et al., (2021) és Zhou et al., (2020) vizsgálatai alapján a LiDAR-ral mért magasságcsökkenés és -visszanyerés idősorai jól jelzik előre a hozamcsökkenés mértékét, illetve rámutatnak, hogy a genotípusok közötti különbségek tekintetben szignifikánsan összefüggenek a betakarításkori nedvességtartalommal is. Más szóval, a szilárd szárú, gyorsan regenerálódó genotípusok nemcsak többet teremnek, de szemtermésük szárazabb, könnyebben kezelhető a betakarítás után.

A hozamelőrejelzésben is alkalmazható a multiszenzoros eszközök összevonása. Ha a LiDAR mellett rendelkezésre állnak képalkotó (RGB vagy multispektrális) adatok is, érdemes a kétféle információt kombinálni a hozam előrejelzéséhez. A szerkezeti jegyek (pl. magasság, fedettség, rétegeltség a LiDAR alapján) és a spektrális jellemzők (pl. red-edge vagy NIR sávok indexei, illetve egyszerű RGB-ből számolt vegetációs indexek) együttes felhasználása bizonyítottan növeli az előrejelzés pontosságát. Különösen a szezon közepén, a vegetatív-generatív átmenet (R1) táján gyűjtött adatok integrálása hasznos: ekkor a növények szerkezete már kellően fejlett, és a spektrális különbségek is erőteljesen jelentkeznek a genotípusok vagy kezelések között. Egy friss vizsgálatban például a LiDAR és multispektrális (MSI) adatokból együttesen betáplált gépi tanulási modell sokkal pontosabban jelezte előre a száraz magtermést, mint bármelyik

adatforrás külön-külön (egy Gradient Boosting regresszorral  $R^2 \approx 0,64$  érhető el, szemben az egyedi adatokkal kapott gyengébb illeszkedéssel)(Panigrahi et al., 2025). Hasonló eredményre jutott Walter et al. (2019) és Madec et al. (2017) is több szenzor összevetésével: a LiDAR strukturális mutatóinak kiegészítése a spektrális indexekkel szignifikánsan javította a parcella szintű hozamrangsor előrejelzését már a tenyészidőszak közepén. A gyakorlati tanulság tehát az, hogy a többféle szenzoradat integrálása – a 3D szerkezet és a 2D spektrális információk ötvözése – a precíziós növénynevelés és termésbecslés terén a legjobb eredményekhez vezet.

### 3. Alkalmazott módszerek

#### 3.1. A kísérleti terület leírása

A diplomadolgozatom témájának szellemi alapját és a kivitelezéséhez szükséges eszközöket egy növénynemesítő vállalat biztosította az itt végzett munkámnak köszönhetően. A vizsgált szántóföldi kísérleti terület Tolna-mözs mellett volt elhelyezve egy mezőgazdasági termelő céggel kötött partnerkapcsolat révén. A kapcsolat több éves múltra tekint vissza és a megfelelő környezeti adottságokon túl a mezőgazdasági folyamatokban tanúsított szakértelem végett esett a választás erre a területre. A méréseket és az adatgyűjtést 2024 évi tenyészidőszakban végeztem.



1. ábra A kísérleti terület (saját kép)

A kísérleti terület a Dél-Mezőföld kistájhoz tartozik, amelynek teljes területe 503 km<sup>2</sup>. Eloszlás szempontjából mezőgazdasági termelés ennek a 61%-án történik, jelentősebb területi megoszlással erdők vannak jelen 24,4 %-kal valamint kis mennyiségű (2%) szőlő is jellemzi a kistájat. Éghajlatát tekintve mérsékelt meleg időjárás jellemző száraz meleg nyarakkal és száraz mérsékelt telekkel. 2050 az éves napsütéses órák száma, a középhőmérséklet éves átlaga 10,2-10,3 °C. Csapadék szempontjából 560-570 mm a jellemző a területre azonban ez évről évre csökken, így ez a fő mezőgazdasági limitáló tényező.

Talajvizsgálati adatok a területről a rendelkezésemre álltak. A talaj iszapos vályog, a laboratóriumi analizálást követően a jellemző struktúra 7,2 pH értékkel. Százalékos talajösszetétel pedig a következő képen épül fel a kísérleti területen: agyagtartalma 19%, homoktartalma 20%, iszaptartalma 46%, humusztartalma pedig 3,6% a laboratóriumi vizsgálat alapján.

A kukorica nemesítés által használt kísérleti felépítés tartamkísérletekben a következőképp alakul. A terület a teljes kísérleti teret magában foglalja és ezen belül a nagyobb egységtől a kisebb felé haladva így következnek: site, sub-site, planting session, set, plot. Tehát egy táblán belül több kisebb egység van, amely egy vetésként van kezelve (planting session) és egy ilyen egységet set-ek töltenek fel ez maga az egymással összehasonlításra kerülő anyagok. A legkisebb egység a plot más szóval parcella, amely 2 vagy 4 soros felépítésben van jelen. Horizontálisan oszlopok vertikálisan pedig range-ek határozzák meg a pozíciót. A kis parcellák közti út 70 cm az átjárhatóság és elhatárolás céljából A sortávolság 75 cm, tőszám 82 000 ebből adódóan egy parcella egy sorának a tőszáma 36-40 db kukorica növény között alakul.

### 3.3. Felhasznált eszközök és gépek és módszerek

A kísérletek vetése, ápolása, adatfelvételezése és betakarítása a kísérletet végző csapat feladata. A mezőgazdasági vállalkozó kizárólag a szükséges talajmunkákat végzi el.

Elővetemény a területen őszi búza volt melyet betakarítást követően őszi talajmunka során műveltek meg. A művelés 40 cm mélyen történő lazítással kezdték meg majd grubberrel zárták vissza a megbolygatott talajt, valamint 300 kg/ha NPK (8-21-21) komplex műtrágya inhibitorral került kijuttatásra. Tavasszal a vetést megelőzően az ideális magágy meglétének céljából kompakkal művelték meg.

A parcellák vetéséhez cégen belül fejlesztett kazettás vetőgépet alkalmazunk, amely egy Case IH Maxxum 150 traktorhoz van kapcsolva. A technológia vákumos szemenkénti vetőgép alapokon nyugszik és előre betöltött kazettákkal végzi a parcellánkénti mag elhelyezést így biztosítja a kiemelkedő pontosságot és precizitást. A megnevezett kísérlet 2024. április 30.-án került vetésre. A vetés során a magágyba Force 1.5g került kijuttatásra 10 kg/ha mennyiségben. A terület mechanikus gyomszabályozáson esett át május 29-én, amelyhez rendelkezésünkre állt egy Kongsklide vibro crop 4 soros kultivátor. Mivel a területen a kultivátorozást magunk végeztük az esedékes műtrágya kijuttatás is itt történt egy menetben, amely 150 kg/ha mennyiség volt. Ezt megelőzte a partner által végzett herbicid kijuttatás szintén gyomszabályozás céljából. Ennek oka, hogy a kísérleti terület teljesen gyommentes legyen a drónos adatfelvételezéshez. Kifejezett rovarnyomás vagy kórokozó jelenléte nem volt észlelhető a földön így további kezelésre nem szorult a tábla.

Növényápoláson túl az adatfelvételezéshez is különböző eszközöket veszünk igénybe. Az adat központi tárolása és feldolgozása a Cég által fejlesztett saját fejlesztésű szoftveren keresztül történik. A manuális adatfelvételhez különböző applikációk van kifejlesztve, amely lehet a

parcellához adatot társítani vagy a területről általánosan bejegyzést, feljegyzést készíteni. Az utóbbi pontok és egyéb georeferáláshoz szükséges polygonok flevételezésére alkalmas, valamint navigálásra. A betakarítást Wintersteiger Split iker parcella kombájnnal végezzük. Az ilyen arató cséplőgépek a parcella betakarításra vannak kifejlesztve. A gép a vertikális vonala mentén két elszigetelt félre van osztva és emellett fel van szerelve egy speciális mérleg és nedvesség mérő rendszerrel, amely egy HarvesMaster H2. Ez az egység betakarított parcella tömegét, hektoliter tömegét és nedvességét képes megmérni. Az iker kifejezés pedig azt jelenti, hogy két parcellát magkeverés nélkül tud csépelni és lemérni. Ezt a technológiát hasznosítva egy parcella 25-30 másodperc időtartam betakarítani.

Manuális adatfelvételezés során felvételre kerül a kelési értékelés, korai életképesség erély (early vigor V2-V3), tényleges kikelt tőszám, életképességi erély (vigor V5-V6), zöld szártörés vagy dőlés, növény magasság, bibe magasság, parcella egységesség és állapot, 50% bibe és címer virágzás, szár törés vagy dőlés, zölden maradás és a szár épsége aratás előtt. Továbbá különleges esetekben kár- és kórokozó terhelést is tudunk rögzíteni.

Bizonyos esetekben a felvételezés automatizált és az adatok kiértékelését algoritmusok, modellek végzik. Ilyen esetekben egy DJI Matrice 300 RTK drónt használunk egy Sentera 6x multispectral szenzorral. Ezzel a felszereléssel tőszámolás, fedettség és parcella egységességre vonatkozó adatokat tudunk rögzíteni. Növénymagasságot pedig Phoenix LiDAR System Recon XT LiDAR szenzorral felszerelve és pontos GPS alapú repülési útvonal rögzítésének érdekében DJI D-RTK 2 GNSS állomással egészítjük ki a repülést.

A kísérlet során mivel ez egy fejlesztés alatt álló modell, úgynevezett POC (Proof Of Concept) projekt a DJI Matrice 300 drónt a LiDAR lézeres távolságmérővel felszerelve használtam.

### 3.3. Felvételezés leírása, lépései:

Manuális felvételezés közvetlen a repülés előtt szükséges elvégezni. 2024.06.06-án a bejárás megtörtént és az adatgyűjtés manuális fázisa készen lett. Az early vigor (V5-V6) egyéni döntéshozatalon alapuló tulajdonság. Feltétele a megfelelő érettségi stádium, ami az Iowa skálán V5-V6, másszóval 8 látható levél (az Arvalis skála szerint) van jelen. A korai fejlődési erély értékelésével leírhatjuk a kelés utáni fejlődésben lévő kukorica növények erejét és a vegetatív hozamát. A kukoricánál ez a tulajdonságot tehát csírázási és korai fejlődés összegzésével kapjuk meg még a szár extrém megnyúlása előtt. Az adatgyűjtést csak akkor szabad elkezdni, ha legalább 3 különböző értéket meg tudunk állapítani. Javasolt 1-3-5-7-9 skálát alkalmazni. Adatgyűjtés, mivel set-en belül egymáshoz viszonyított adatról beszélünk

egy terület bejárással kell kezdeni és az adott set-ben levetett minta parcellához kell viszonyítani.

Amennyiben a manuális adatgyűjtés megtörtént a UAV és egyéb kiegészítő eszköz összeszerelése és ellenőrzőlisták kitöltése után megkezdjük az adatgyűjtés előkészítését. A repülések automatizált és külső irányítást csak a szenzor kinetikus kalibrációs repülések során (repülés megkezdése előtt és után is) és a le- fel szálláskor alkalmazok. A repülés 22 percet vett igényben ezen a területen és 20 m történt 6 m/s sebességgel. Az átfedés oldal irányban 50% volt. Az irányító pontok 100 m helyközökkel szerepelt és a magasság tartás érdekében magasságkorrekció is bele van építve a programba.

### 3.4. Statisztikai módszerek bemutatása

A statisztikai elemzés során IBM SPSS Statistic26-os verzióját használtam, az adatok elemzése és vizualizálása céljából. A statisztikai elemzés két fő részre bontható. A két mérési módszer összehasonlítása, valamint a LiDAR szenzor által felmért vigor és a terméshozam kapcsolata.

#### 3.4.1. A LiDAR-modell és a manuális adatgyűjtés vizsgálata

Leíróstatistika és alapvető statisztikai ellenőrzések alá vettem az adatsorom és eloszlást, középértékeket és terjedelmet vizsgáltam meg. A függő változók normalitását hisztogrammal és normalitásplotokkal ellenőriztem. Ezt kiegészítve Shapiro–Wilk és Kolmogorov–Smirnov próbákkal is teszteltem. A PV\_Manual kategóriák szerinti eloszlás és szóródás szemléltetésére dobozdiagrammot készítettem, amely a mediánokat, interkvartilis terjedelmeket (IQR) és az esetleges kiugrókat mutatja.

Fő hatásvizsgálatot a többszörös lineáris regresszió (OLS) felhasználva végeztem. A Lidar\_Volume kimenetet a PV\_Manual és a CCVR\_PCT prediktorokkal modelleztem. A modell specifikációja:

$$Lidar\_Volume = \beta_0 + \beta_1 \cdot PV\_Manual + \beta_2 \cdot CCVR\_PCT + \varepsilon.$$

A jelentésben a nem standardizált ( $B$ ) és a standardizált ( $\beta$ ) együtthatókat, a 95%-os konfidenciaintervallumokat (CI), a modellilleszkedési mutatókat ( $R$ ,  $R^2$ , korrigált  $R^2$ ) és az ANOVA F-próbát adtam meg. A hierarchikus (hibridenkénti) megközelítést is alkalmaztam az inkrementális magyarázóerő vizsgálatára és jelentettem az  $R^2$ -változó és az ahhoz tartozó F-változó értékeit. A szignifikanciaszint  $\alpha = 0,05$  (kétoldali) volt.

A feltétel-ellenőrzés elvégzésére a lineáris regresszió feltételeit grafikus és numerikus eszközökkel vizsgáltam. A normalitást a regressziós standardizált maradékok hisztogramjával és a Normal P–P plottal ellenőriztem. A homoszkedaszticitást a ZRESID–ZPRED szórásdiagramon vizsgáltam (tölcsermentességet keresve). A multikollinearitást a VIF és Tolerance mutatókkal, valamint a condition index értékeivel ellenőriztem (Collinearity diagnostics). A befolyásos eseteket és a „szélen lévő” megfigyeléseket Cook’s distance, leverage és (studentizált/standardizált) maradékok alapján azonosítottam. > 3 szabály szerint alkalmaztam. A mentett változókat (becsült értékek, maradékok, Cook’s D, leverage).

Az egyes ábrák a szöveg megfelelő elemzési résznél, valamint a mellékletben találhatóak.

### 3.4.2. A LiDAR-szszor által felmért vigor és a hozam kapcsolata

Adatok és változók a következő módon lettek meghatározva. A Hozam (qa/ha, 0% nedvességre korrigálva) mint függő változó; Lidar\_Volume (volumetrikus érték) mint fő magyarázó és a különböző hibridek, mint csoportfaktor.

Mindent megelőzően egy leíró statisztikai elemzést alkalmaztam az adatok gyors vizuális elemzése végett. A vizsgálni kívánt tulajdonságok között kapcsolatvizsgálat futtattam le. Hibridenként lefuttattam Pearson-korrelációt (lineáris kapcsolat vizsgálata) és Spearman-féle rangkorrelációt (monoton kapcsolat vizsgálata mert kívül eső értékekre robusztusabb). Elemeztem továbbá a szignifikanciaszintet is ( $\alpha = 0,05$ , kétoldali próbák). Végül egy lineáris regresszió hajtottam végre hibridenként, amelynek a modell leírása a következő:


$$GYLD_i = \beta_0 + \beta_1 \cdot Lidar\_Volume_i + \varepsilon_i$$

Becslését OLS módszerrel hajtottam végre és így alakultak ki a jelentett mutatók:  $\beta_1$ , 95% CI,  $R^2$ , p-érték. Értelmezéshez a  $\beta_1$  gyakorlati nagyságát 0,1 Lidar-egységre is megadtam.

Az egyes ábrák a szöveg megfelelő elemzési résznél, valamint a mellékletben találhatóak.

## 4. Eredmények és értékelésük

### 4.1. A korai életképesség erély és a LiDAR-szenzor adatainak összefüggés vizsgálata



2. ábra A felvett adatok összehasonlítása - alapeloszlása

A kettes számú ábra, amely ábrázolja a szenzorral felvett majd feldolgozott adatok előfordulást a manuális adatfelvételezéshez viszonyítva. A LiDAR által felvett adatnak mértékegysége nincs, mint a manuális értékelésnek sem. A számok sakála szerűen állapotot, afféle értékelésként szolgál. A diagramm értelmezéséhez szükséges tisztázni, hogy a LiDAR szenzor adatai a Lidar\_volumen jelzővel találhatóak, míg a korai életképesség erélyt jelentő adatok a PV\_manual elnevezést kapták. Így az a változó elemek jelentése

- Lidar\_Volume – LiDAR szenzor adatfelhőjéből származtatott térfogat alapú metrika, amely függő változó.
- PV\_Manual - manuális korai életképességi erély érték, amely magyarázó változó rangsorolt skálával valójában intervallumskála
- CCVR\_PCT - képelemzésből számított százalékos mutató, amely kovariánsként szerepel amellet. hogy magyarázó szerepe van.

A teljes mintát tekintve a Lidar\_Volume N=776 megfigyelésből áll. Az egész halmaz átlaga 2,0275, a szórása 0,105, ami elemzést követően levonható, hogy szűk a szórása, miközben a

normalitás-ellenőrzések közül a Shapiro-Wilk-próba  $p=0,393$  értéke nem utasítja el a normális eloszlás feltételezését, a Kolmogorov-Smirnov-próba  $p=0,024$  eredménye pedig a nagy elemszám miatt várható módon túlszenzitív, ezért önmagában nem tekinthető döntő erejű megfigyelésnek az eltérés mellett.

A PV\_Manual változó eloszlása az adatfelvételezés jellege miatt kifejezetten egyenetlen görbét mutat. Az 5-ös kategória 563 esettel dominál. Ezzel szemben az 1-esből 16, a 3-asból 32, a 7-esből 159, a 9-esből pedig mindössze 5 megfigyelés áll rendelkezésre, ami azt jelenti, hogy a csoportok közötti különbségek grafikus vagy klasszikus varianciaanalízis-alapú összevetése a ritka kategóriákban nagy bizonytalansággal terhelt, és a mintavételi zaj könnyen túl- vagy alábecsülheti a tényleges hatásokat.

Ennek következtében a további elemzések során regresszió analízist alkalmazta.

A modell függő változója a Lidar\_Volume, magyarázó változói a PV\_Manual és a CCVR\_PCT\_ImageAnalysisGenerated, amely a borítottság leírásával pontosította az adataim. A statisztikai elemzést követően megállapítható, hogy a többszörös korrelációs együttható (röviden  $R$ ) = 0,584, a determinációs együttható (magyarázott variancia aránya) (röviden  $R^2$ ) = 0,341 (ig.  $R^2 = 0,340$ ), a becslés szórása  $SEE = 0,08554$ ; az ANOVA (varianciaanalízis-tábla) táblában  $F(2, 772) = 199,927$ , a szignifikancia szint, avagy  $p < 0,001$ , ami szignifikáns és gyakorlati értelemben közepes erősségű illeszkedést jelez.

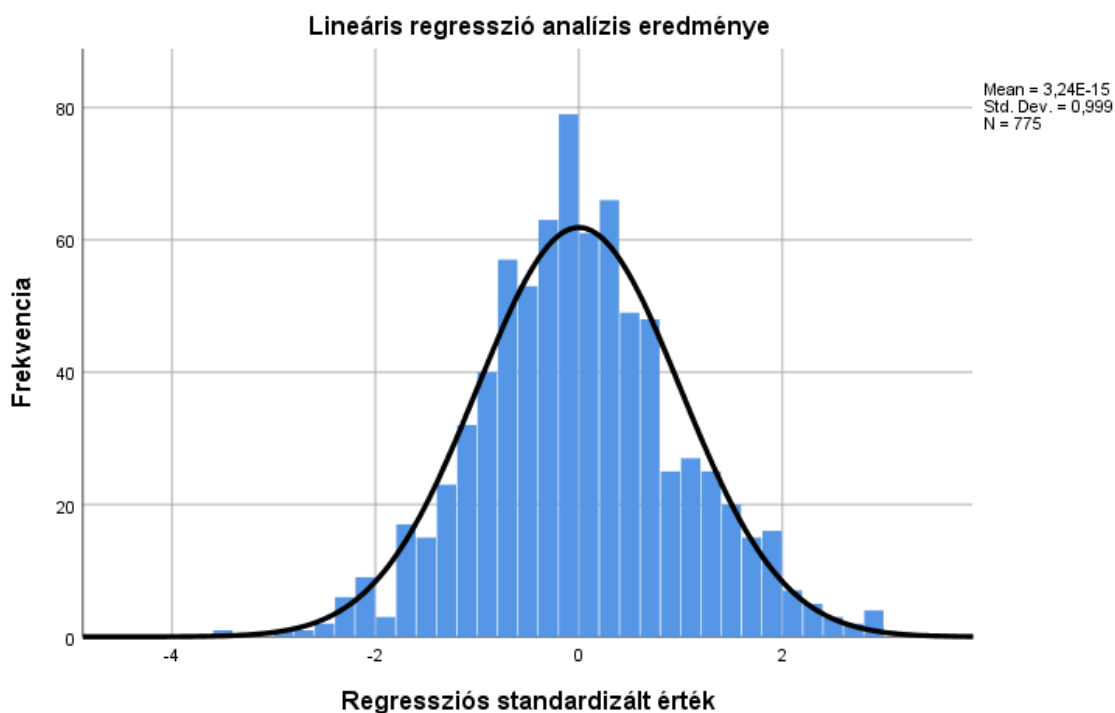
Az együtthatók szerint az állandó tag 1,865 ( $SE = 0,024$ ). A PV\_Manual hatása negatív és kicsi:  $B$  (nem standardizált regressziós együttható) = -0,009 ( $SE = 0,003$ ),  $\beta$  (standardizált együttható) = -0,105,  $t = -3,272$ ; a CCVR\_PCT hatása pozitív és erős:  $B = 0,023$  ( $SE = 0,001$ ),  $\beta = 0,534$ ,  $t = 16,716$ . Ez azt jelenti, hogy a PV\_Manual emelkedésével - a CCVR kontrollja mellett - a Lidar\_Volume enyhén csökken, míg a CCVR növekedése számottevően együtt jár a LiDAR-térfogathatás emelkedésével. A nulladrendű korrelációk mintázata ezt alátámasztja  $r$  (Person féle korrelációs együttható) (Lidar, PV) = -0,321,  $r$  (Lidar, CCVR) = 0,576,  $r$  (PV, CCVR) = -0,405.

A maradékdiagnosztika alapján a standardizált maradékok eloszlása jól közelít normálishoz: a hisztogramon a normálgörbe megfelelően fekszik a sávokra, amely a hármas számú ábrán látható. A Normal P-P plot pontjai szorosan a 45°-os referenciaegyenes mentén helyezkednek el, csak a szélső értékeknél tapasztalható enyhe eltérés. Ezen adat a négyes számú ábrán látható. A maradék-statisztikák szerint a Std. maradék tartománya -4,055...3,370, az átlag 0, a szórás  $\approx 1$ , ami összhangban van az ábrákkal.

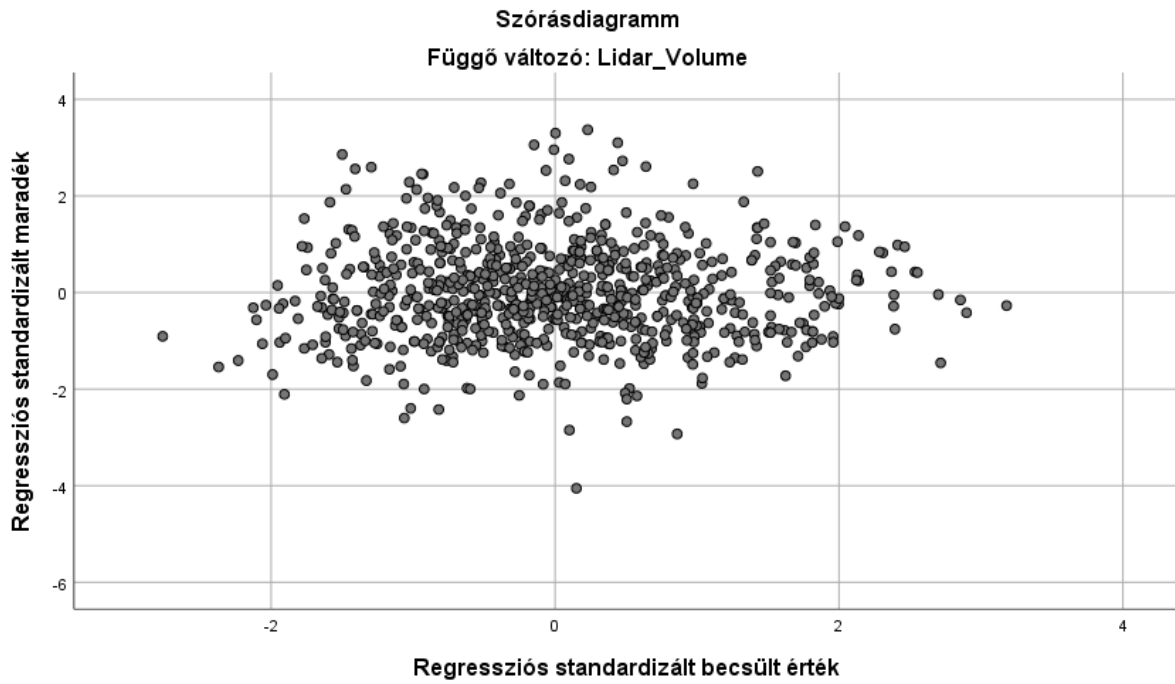
Homoszkedaszticitás tehát az azonos szórás feltétele és hatások esetek leírásával haladtam tovább. A mentett ZRESID–ZPRED (regressziós standardizált maradék - regressziós standardizált becült érték) szórásdiagram vizuálisan a szisztematikus tölcsermentességet ellenőrizhetővé teszi (ötös számú ábra) a számok oldaláról a befolyásosságra utal, hogy a Cook's D (befolyásossági mutató) maximum = 0,015, ami bőven elmarad az elfogadott riasztási küszöböknek, miközben a szélre esése maximum = 0,027 az átlagos 0,003 fölött van ugyan, de nem extrém; összességében nem látszik domináns kiugró vagy erősen hatásos megfigyelés.

A kollinearitási diagnosztika kondíció index értékei 1,00; 6,09; 16,24, a variancia-arányok eloszlása nem jelez súlyos problémát (nincs 30 fölötti index), ami konzisztens a közepes PV–CCVR korrelációval (–0,405); a regressziós becslések emiatt stabilnak tekinthetők.

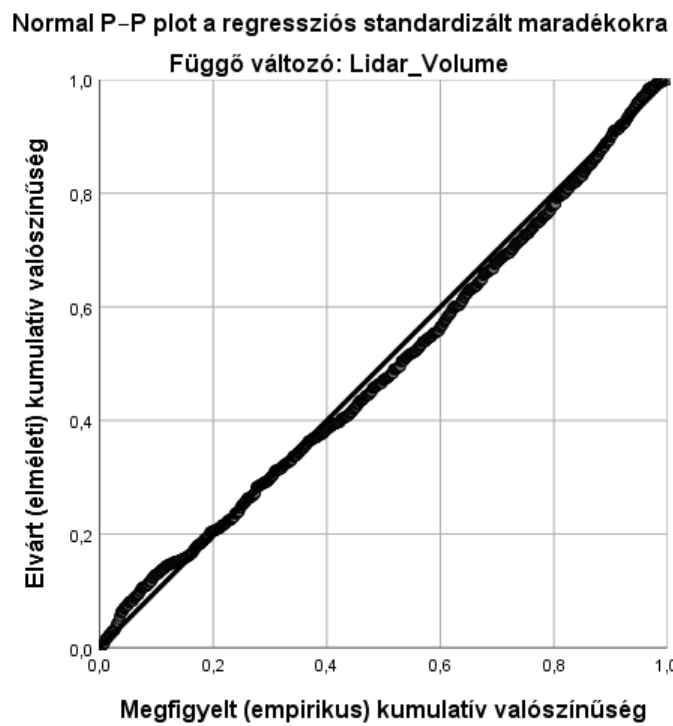
A vizsgálatok rámutattak arra a jelenségre, hogy szignifikáns és pozitív prediktor a CCVR\_PCT. Amikor a CCVR\_PCT nő, a Lidar\_Volume várható értéke is nő, és ez a kapcsolat statisztikailag nem magyarázható pusztán véletlenül (p-érték kicsi). Ebből az az állítás vonható le, hogy gyakorlatilag: a CCVR\_PCT a fő magyarázó tényező. Ez magyarázható azzal, ha két eset azonos CCVR\_PCT mellett csak a PV\_Manual tér el, akkor a nagyobb PV\_Manual kicsit alacsonyabb Lidar\_Volume-mal jár együtt; a hatás kicsi, de megbízhatóan kimutatható (p kicsi). Vagyis a PV\_Manual önálló, gyenge vizsgálati alaptényező.



*5. ábra Lineáris regresszió eredménye*



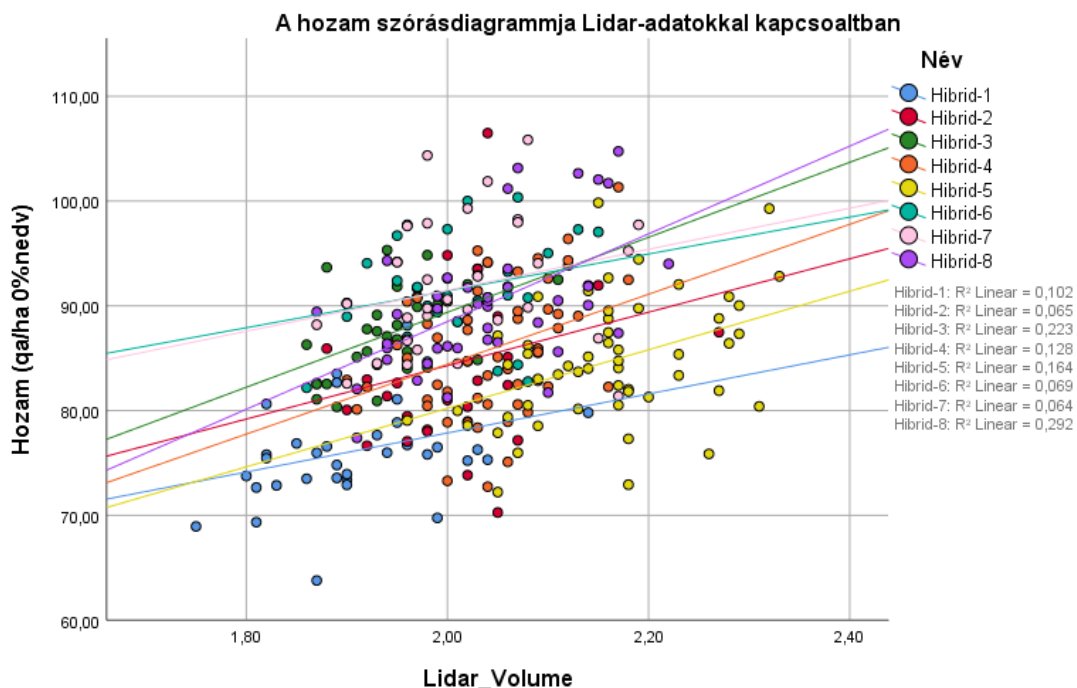
5. ábra Regressziós maradék szórásdiagramm



4. ábra Normal P-P plot a regressziós standardizált maradékokra

## 4.2A hozam és a szenzor adatok összehasonlítása

A hatos ábra, amely ábrázolja a hozam és a LiDAR értékek szórását egy általános áttekintést kapjunk az adatösszesről. A nyolc vizsgált hibrid (H1-H8) kiválasztása a minta nagyságának érdekében történt. Így nyolc különféle hibridet vizsgáltam meg 30-59 közötti adatpont intervallummal. A hibridek GYLD adatának szórása csoportonként változik azonban ez agronómiai behatásból adódó tény és releváns a szántóföldi kísérleteknél. A Hozam - Lidar\_Volume szórásdiagram összképe enyhén emelkedő mintázatot mutat; az ábrán jól leolvasható, hogy a csoportok nem azonos szinteken helyezkednek el, és a lejtők meredeksége

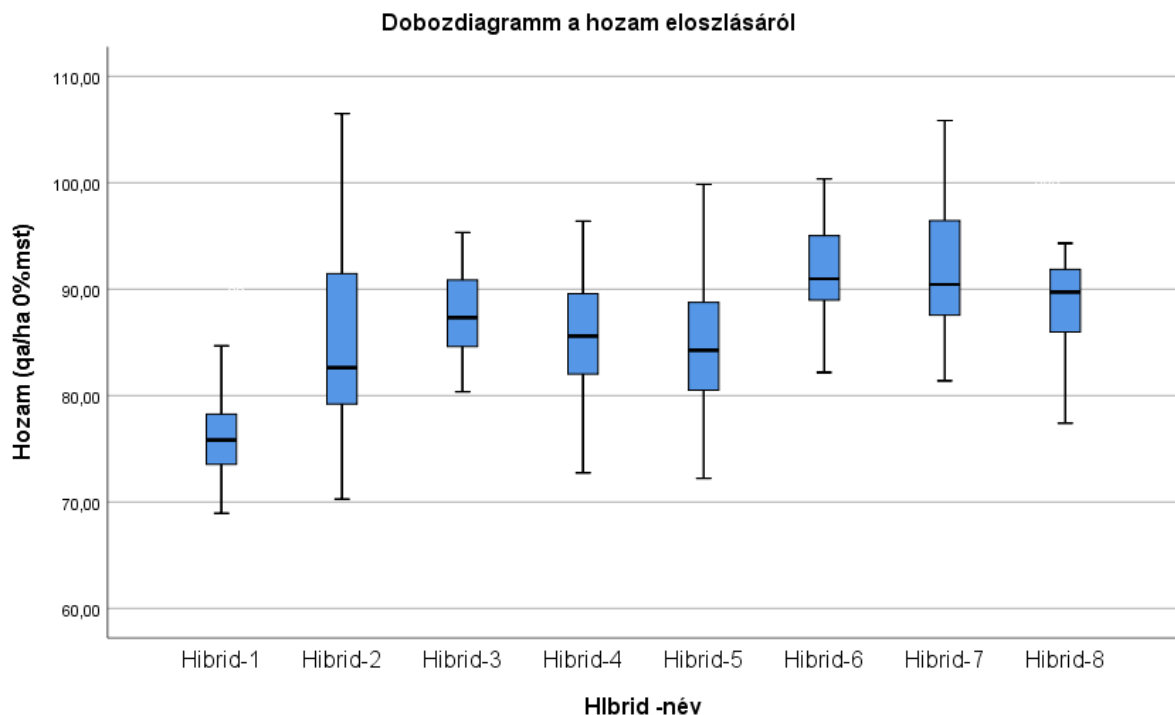


6. ábra Szórásdiagramm, az összes hibrid együttese trendvonallal

is eltérhet. Ez egyik indokot adja, hogy hibridenkénti vizsgálatokkal folytassam.

A Lidár-adatok jellegéből adódóan kis intervallumban mozognak ( $\approx 1,95-2,16$ ). Az adat  $SD=0,0857$  és a kicsi terjedelemből ( $0,21$ ) értékéből arra következtethetünk, hogy a mérés stabil és szórásuk kicsi a hibridek közt. Ez a volumetrikus mérés konzisztenciáját és stabilitást támasztja alá. A különbségek nem kiugróak, inkább finom eltolódások, ami jó alapot ad a hozam előre jelzésnek.

Hozamot tekintve a legcsekélyebb a H1 volt,  $63,78$  qa/ha. Minden hozammal kapcsolatos adat mázsa/hektár mértékegységben értendő és  $0\%$  nedvességtartalomra van korrigálva. Legnagyobb hozamot a H2 érte el  $106,49$  qa/ha  $0\%$  nedv. értékkel.

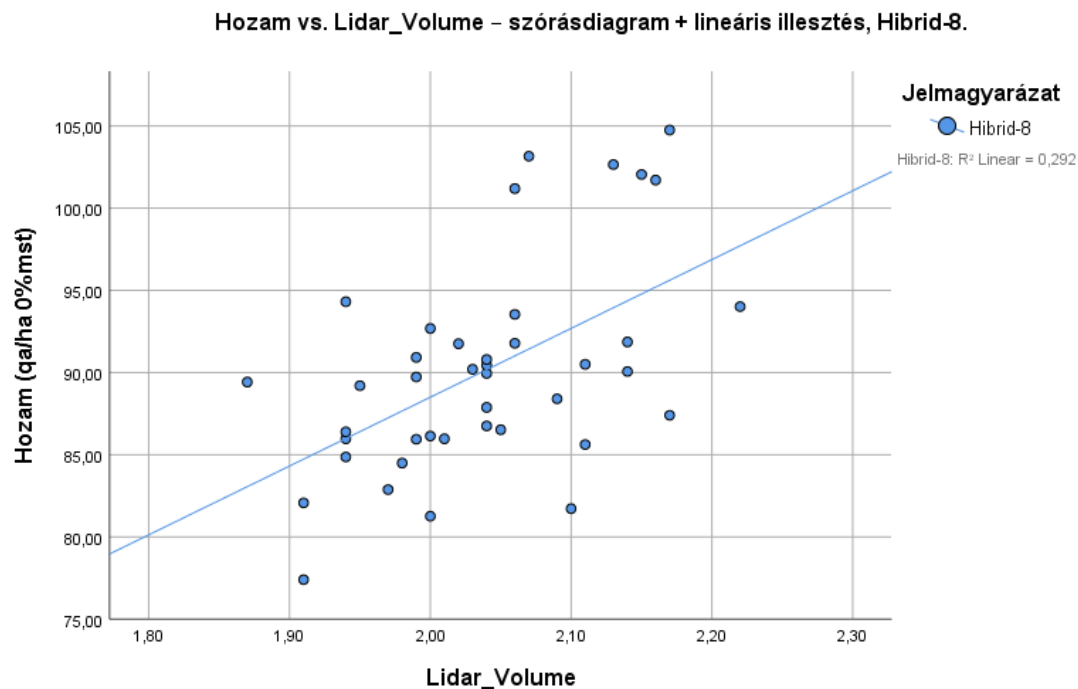


*7. ábra A hozam eloszlása hibridcsoportonként*

Ha medián értékeket figyeljük a Hibrid-6 (90,98 qa/ha 0% nedv.) és a Hibrid-7 (90,44 qa/ha 0% nedv.) a két legmagasabb érték, szorosan mögöttük a Hibrid-8 (89,73 qa/ha 0% nedv.); az összehasonlításban középértékeket képvisel a Hibrid-3–5 trió (mindhárom 87.32), míg a legalacsonyabb medián a Hibrid-1-nél (75,82 qa/ha 0% nedv.) látszik. A szélső mediánok közötti különbség nagyságrendileg 15–16 q/ha ami agronómiai szempontból is jelentős eltérés.

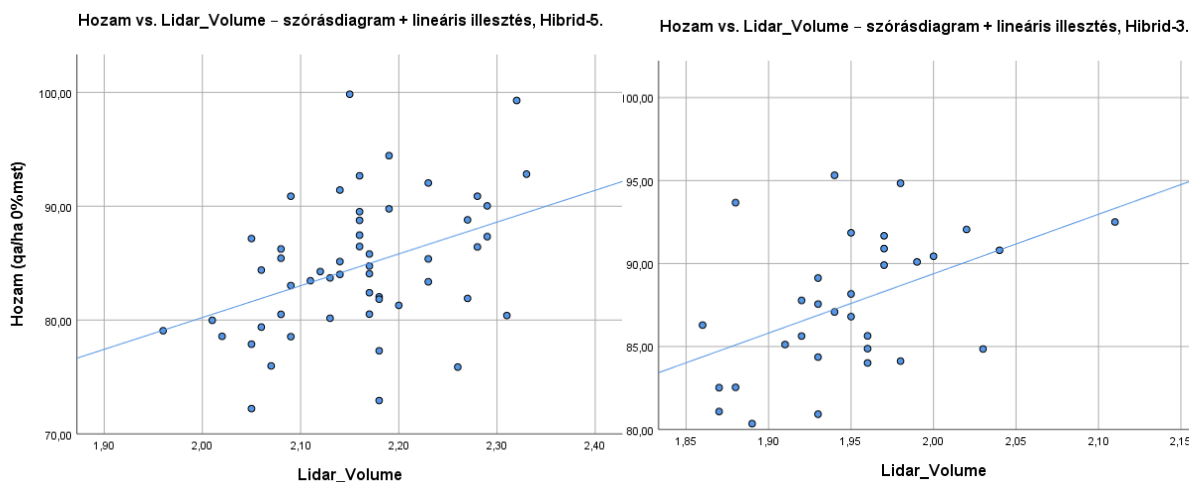
A csoporton belüli ingadozás (dobozmagasság = IQR, illetve a „bajuszok” hossza) hibridenként eltérő. A Hibrid-2 doboza és bajuszai feltűnően nagyok, ami tág eloszlást és potenciális pozitív ferdeséget jelez (gyakori középértékek mellett több magasabb hozamú eset). Ezzel szemben a Hibrid-3 kompakt, alacsony IQR-ral és rövidebb bajuszokkal inkább stabil hozamot sugall. A Hibrid-6–7 magas szint mellett közepes szóródásuk, míg a Hibrid-1 alacsony szint mellett feszebb eloszlású. Ez a minta összességében arra utal, hogy a hozam variabilitása érdemben hibridfüggő. Tehát van, ahol a hozamszint magas és viszonylag egyenletes (H6–H7), máshol mérsékelt szint nagyobb szórással társul (H2).

### 4.3 Hibrid-specifikus kapcsolatok (korreláció és lineáris regresszió).



8. ábra Hozam vs. Lidar\_Volume – szórásdiagram + lineáris illesztés, Hibrid-8.

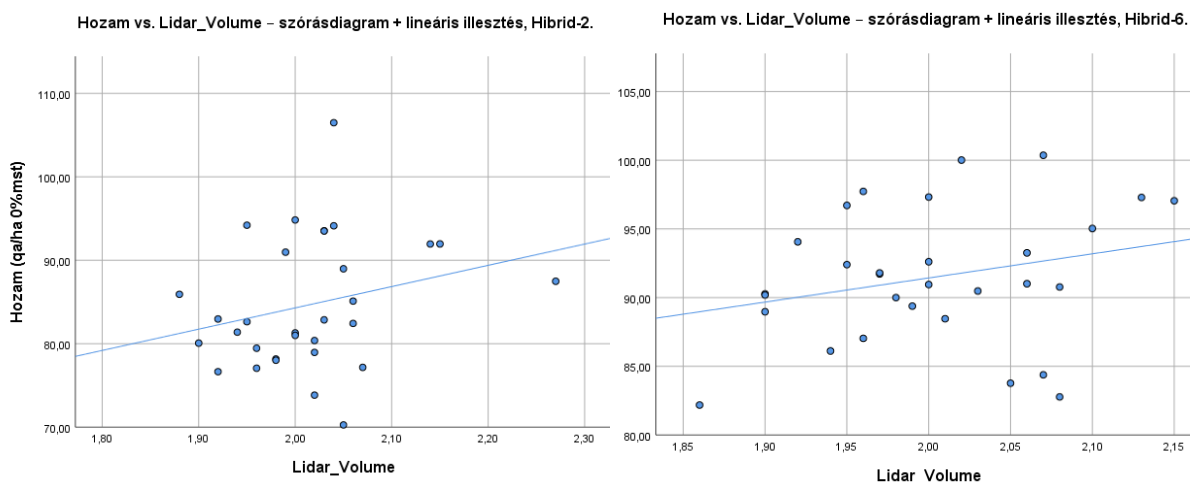
Hibridenkénti specifikus elemzés során végzett analízisek eredményeképpen a H8 hibrid adatain akadt meg a tekintetem. A vizsgálat során erős korrelációs eredményeket kaptam, mivel egy megbízható pozitív kapcsolatot ír le. A lineáris regresszió meredeksége (nyolcas ábra)  $\beta_1 \approx 41,9$  (95% CI  $\approx 20,8-63,0$ ), vagyis a Lidar\_Volume-skálán 0,1 egység növekedéshez átlagosan  $\approx 4,2$  egység GYLD-többlet társul (a skála 1,0 egységnyi eltolódása  $\approx 41,9$  qa/ha 0% nedv.növekményt jelez). Az intervallum teljes egészében pozitív, tehát a hatás statisztikailag és irányában is stabil. A vizsgált csoport statisztikai ingadozása ( $SD \approx 0,082$ ) mellett ez  $\approx 3,4$  egységnyi várható hozamkülönbséget jelent  $\pm 1$  SD-re, ami agronómiai szempontból is elismerendő adat. A kapcsolat vizuálisan tiszta, kevés szórással a regressziós egyenes körül; a maradékok azonos szórásnégyzetűek és közel normálisak a befolyásos pontok/leverage értékek nem torzítják a becslést. A Lidar\_Volume jelentős, pozitív jelmagyarázó erővel bír ebben a hibridben.



9. ábra Hozam vs. Lidar\_Volume – szórásdiagram + lineáris illesztés, Hibrid-3 és Hibrid-5

H3 és H5 diagramok tüzetes vizsgálata során megállapítható közepes erősségű, konzisztens pozitív kapcsolat.

Ezt támasztja alá Pearson  $r \approx 0,36-0,47$  ( $p < 0,01$ ) ami leírja a korábban tett következtetés levonást. Más szóval a nagyobb volumen értékhez nagyobb hozam társul és mindezt minimális véletlen zaj mellett produkálja.,  $R^2 \approx 0,13-0,22$  a Lidar\_Volume önmagában összvarianciájának 13–22%-át magyarázza meg a lineáris modell. A lineáris regresszió becsült meredeksége  $\beta_1 \approx 28-36$ , a 95% CI végig pozitív, ezért a hatás iránya stabil. Elmondható, hogy a Lidar\_Volume-skálán 0,1 egység növekedés átlagosan  $\approx 2,8-3,6$  egység hozam-többlettel társul. A csoporton belüli tipikus Lidar\_Volume-érték ingadozás ( $\approx 0,05-0,09$ ) mellett egy  $\pm 1$  SD eltolódás várhatóan  $\approx +2$  egység körüli hozamkülönbséget jelent, ami agronómiai szempontból érzékelhető, de nem kizárólagos és egyértelmű eredmény. A tipikus előrejelzési hiba (RMSE) ezekben a csoportokban H3= 3,6, H5=5,4 Ez azt mutatja, hogy bár a kapcsolat szignifikáns és hasznos, a lineáris egyváltozós modellnek még jelentős maradéka marad.



10. ábra GYLD vs. Lidar\_Volume – szórásdiagram + lineáris illesztés, Hibrid-2 és Hibrid-6.

A vizsgálat során nem minden eredmény támasztotta alá a vizsgálati célokat. Ilyen esetek példaként a H2 és a H6 hibrideket elemzem ki.

H2 és H6: a lineáris kapcsolat gyenge és nem szignifikáns. A 2-es hibridben a Lidar\_Volume és a hozam közötti linearitás gyenge ( $r \approx 0,26$ ;  $R^2 \approx 0,065$ ), vagyis a hozam teljes varianciájának mintegy 6,5%-át magyarázza meg önmagában ez a mutató a 31 megfigyelés alapján, miközben a becsült meredekség  $\beta_1 = 25,50$  meglehetősen nagy bizonytalansággal jár ( $SE = 17,92$ ), ezért a t-statisztika alacsony és a próba nem szignifikáns ( $p = 0,166$ ). Másként fogalmazva: a 95%-os konfidenciaintervallum tág és a nullát is tartalmazza így hiába pozitív az irány és 0,1 Lidar-egység elméletileg  $\approx 2,55$  hozam-egység többlettel társulna, a hatásbecslés pontatlansága miatt nem állítható megbízhatóan, hogy ez a kapcsolat valóban fennáll. H6-esetében is hasonló eredményt figyeltem meg. A linearitás gyenge ( $r \approx 0,26$ ;  $R^2 \approx 0,069$ ) a rendelkezésre álló 30 vizsgált egységből. A becsült meredekség  $\beta_1 = 17,60$  jelentős bizonytalansággal társul ( $SE = 12,24$ ), ezért a próbastatisztika nem éri el a szignifikanciaszintet ( $p = 0,162$ ), a 95%-os konfidenciaintervallum pedig tág és a nullát is tartalmazza, ami azt jelenti, hogy bár az irány pozitív és 0,1 Lidar-egység elméletileg  $\approx 1,76$  hozam-egység többlettel járna, a hatásbecslés pontatlansága miatt nem kijelenthető ebben az esetben a szisztematikus kapcsolatot. Mindkét esetben a nem állítható magabiztosan, hogy a volumetrikus növekedés közvetlen hozzájárulna a hibrid végső hozam értékéhez.

## 5. Következtetések és javaslatok

### 5.1 A LiDAR adatfelvételezésének következtetései

Az adatok megvizsgálást követően megállapítható, hogy a korai életképességi erély LiDAR szenzorral való felvétele azontúl, hogy az emberi tényező bizonytalanságát és hibalehetőségét teljes mértékben kivonja, egy alternatív lehetőséget biztosít a hatékonyabb és modernebb adatfelvételezéshez. Az fő Lidar\_volumen adathalmaz 776 adatpontból álló csoport megvizsgálásával szűk szórást állapítottam meg. A manuálisan obszervációval felvételezett adathalmaz változó eloszlást bizonyított, de ez a felvételezés jellege és az agronómiai feltételek is befolyásolták erre Walter et. al. 2019 es tanulmányában is olvashatunk.

A korai életképesség akkor van megfelelően rögzítve, ha a gyenge és a kiugróan erős parcellákat begyűjtjük. Így bár a statisztikai elemzés alapján rossz az eloszlás a szakma ezt tekinti jó eredménynek. Itt jön szerepbe a LiDAR adta lehetőség, mivel egy szenzor és az adatfeldolgozó algoritmus nem hibázik és objektív módon hozza meg a döntést.

A regressziós analízis lefuttatását követően közepes erősségű illeszkedés eredményét kaptam meg amely meglepő eredményként értékelek. Ami arra a következtetésre juttatott, hogy a manuálisan gyűjtött adat mellett a CCVRCV értéket is be kell vonni min kovariáns. Ez abból fakad, hogy a parcella manuális értékelése során az személy egy-egy kisebb hiányosságra eltérésre nem von le pontot míg a modell igen. A CCVRCV a parcella állapotát, teljességét esteleges tőszám hiányát jellemzi. Így megállapítható, hogy egy komplex modell kiépítésével a megfelelő mellékadatokkal és kovariánsokkal a LiDAR szenzor, mint vigor értékelő kiválthatja az emberi felvételezést. Hasonló eredményre jutott Micheletto er al. 2023-as tanulmánya is. Az adatok alátámasztották, hogy a kísérlet, mivel egy kutatás fejlesztési kísérletnek a parcelláiról készült a felvétel, hibridspecifikusan lenne szükséges megvizsgálni ezért így tettem.

Azonban vizsgálat elvégzésének pontosítására és további fejlesztésére a javaslatom a morfológiai tényezők és az állományszintű környezeti változók bevonása. Emellett egy érzékenységi vizsgálatot is javasolt a jövőben lefuttatni.

## 5.2A hibridspecifikus elemzés következtetései

A diplomamunkám másik fő kérdésfeltevése az volt, hogy LiDAR-szenzor által felvett korai életképességi mutatóval lehetséges-e hozam előrejelzést végezni. A kérdés megválaszolása érdekében megvizsgáltam, hogy összefüggésbe hozható-e ez a két adat.

A specifikusan hibrid csoportonkénti elemzés három fő eredménycsoportba osztottam.

Első az állítást alátámasztó stabil kapcsolatot mutató H8-as adatsorozat, amely hozama egyenes és egyértelmű korrelációt ( $r \approx 0,54$  ( $p < 0,001$ );  $R^2 \approx 0,29$ ;  $\beta_1 \approx 41,9$  (CI  $\approx 20-63$ )) alakít a volumenértékkel. Közepes, de pozitív eredményt kaptam a H3 és H5 csoportoknál is ( $r \approx 0,36-0,47$ ;  $R^2 \approx 0,13-0,22$ ;  $\beta_1 \approx 28-36$  CI végig pozitív), Ezeknél az eseteknél megállapítható, hogy egy volumen érték mekkora hozamnövekedésre realizálható. Azonban volt eset, amelyek a vizsgálatok során nem volt összefüggésbe hozható. Mivel a vizsgálatba bevont adatsorok mennyisége nem teszi lehetővé, hogy egyértelmű kijelentést tegyek az alábbi a konklúzióm.

Míg összefüggés egyértelműen van a korai életképesség erély értékkel a hozam tekintetében a környezeti behatások és az agronómiai technológiák eltérése miatt a kevés mintával rendelkező kísérletem nem teljes biztonsággal vetíti előre a hozam mennyiségét. Azonban mindenképpen elmondható, és egyetértek Su et al. 2019 szakkikijének a kijelentésével, hogy a modern kukorica termesztés és nemesítés számára hasznos folyamatokat alakíthatunk ki

Javaslatom statisztikailag érdemes lehet egy érzékenységi tesztet elvégezni, valamint nemlinearitási tesztet is. A technológia fejlesztésére egy teljes prediktív modell kialakítása, amely belevonja a fedettség, a tőszám, virágzási idő, hőösszeg és egyéb környezeti és fenológiai mutatókat (Li et al., 2020), hogy komplex és megbízható adatot szolgáltatson.

A kapott eredmények meglepő következtetéseket rajzoltak le. A vizsgálat véleményem pozitív eredményt hozott, de nem minden esetben. Egyéb kutatások is A kísérlet folytatásául növelni fogom a vizsgálatba bevont hibridek számát és a csoportokon belüli adatmennyiséget.

## 6. Összefoglalás

Ahogy a kukorica termesztés globális és magyarországi helyzete egyre kritikusabbá és kihívásokkal tüzdeltebbé válik az alkalmazott módszereknek és technológiáknak lépést kell tartaniuk a fejlődésben. Így alakul ez a nemesítési ágazatban is, ahol az egyre növekvő környezeti szempontból strapabíró és stabilan termő kukorica hibrideket kell kinemesíteni.

A nemesítési folyamatok első döntéshozatali szempontja az adat. Minden igény felméréséhez és a döntések meghozatalához is óriási mennyiségű és különböző forrású adatra van szüksége ennek a komplex iparágnak. Ennek egyik kiszolgálási formája a már tesztelési stádiumban lévő fejlesztés alatt álló kukorica hibridek tartam kísérleti. Ezekben az egységekben a nemesítői igényeknek megfelelő mennyiségű és minőségű adatot kell szolgáltatni, amelyben az emberi tényező mindig kritikus. A UAV-szenzoros adatfelvétel ezt szolgálja továbbfejleszteni és eleget tenni az igen határozott igényeknek.

Kutatásom célja egy fejlesztés alatt álló modellből származó volumen érték és a manuális emberi felvételezés által gyűjtött intervallumskála összehasonlítása és értékelése volt. Ezt követően megvizsgáltam, hogy van-e hibridspecifikusan statisztikailag bebizonyítható kapcsolat a hozam és a korai életképesség LiDAR-ral felvételezett értéke között.

A munkám 2024 tavaszán korai fejlődési fázisban kezdődött, ahol megtörtént a manuális és UAV-LiDAR adatfelvételezés. Vetésen és a betakarításon kívül a mechanikai gyomszabályozást (összevonva a tápanyag utánpótlással) végezte el a területen az engem is alkalmazó kutató fejlesztő cég. Betakarítást követően rendelkezésemre állt minden szükséges adat

Megállapítható, hogy a LiDAR felvételezésből származó adat a megfelelő kiegészítő borítottság indexel kiválóan elvégzi a manuális felvételezési munkát. Azonban az adat megbízhatóságára agronómiai feltételeknek teljesülni kell és elkülöníthető egyednek kell szerepelni a felvételezésben.

A hibridspecifikus hozam kapcsolati elemzés során a jól kirajzolódott különbségek fogadtak. Három fő határt tudtam megszabni, amely a biztos korrelálást, a valószínű és a bizonytalan eseteket állapította meg. Konklúzióként levontam, hogy a módszer alkalmas a predikcióra, de finomhangolást igényel.

Fontosnak tartom az állandó fejlődést és a technológiai vívmányok bevonását a mindennapi munkánk megkönnyítésére, így a kísérletet motiváltan folytatom tovább.

## 7. Irodalomjegyzék

- Aasen, H., Honkavaara, E., Lucieer, A., & Zarco-Tejada, P. J. (2018). Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: A review of sensor technology, measurement procedures, and data correction workflows. In *Remote Sensing* (Vol. 10, Issue 7). MDPI AG. <https://doi.org/10.3390/rs10071091>
- Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R., & Sousa, J. (2017). Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. *Remote Sensing*, 9(11), 1110. <https://doi.org/10.3390/rs9111110>
- Araus, J. L., & Kefauver, S. C. (2018a). Breeding to adapt agriculture to climate change: affordable phenotyping solutions. *Current Opinion in Plant Biology*, 45, 237–247. <https://doi.org/10.1016/J.PBI.2018.05.003>
- Araus, J. L., & Kefauver, S. C. (2018b). Breeding to adapt agriculture to climate change: affordable phenotyping solutions. *Current Opinion in Plant Biology*, 45, 237–247. <https://doi.org/10.1016/J.PBI.2018.05.003>
- Barros, V., Stocker, T., Qin, D., Dokken, D., Ebi, K., Mach, K., Plattner, G., Allen, S., Tignor, M., & Midgley, P. (2012). *Glossary of Terms II ANNEX*.
- Bendig, J. V., Bareth, G., & Schneider, K. (2015). *Unmanned aerial vehicles (UAVs) for multi-temporal crop surface modelling*.
- Berni, J. A. J., Zarco-Tejada, P. J., Suarez, 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>
- Bolaños, J., & Edmeades, G. O. (1996). The importance of the anthesis-silking interval in breeding for drought tolerance in tropical maize. *Field Crops Research*, 48(1), 65–80. [https://doi.org/10.1016/0378-4290\(96\)00036-6](https://doi.org/10.1016/0378-4290(96)00036-6)
- Cairns, J. E., Crossa, J., Zaidi, P. H., Grudloyma, P., Sanchez, C., Luis Araus, J., Thaitad, S., Makumbi, D., Magorokosho, C., Bänziger, M., Menkir, A., Hearne, S., & Atlin, G. N. (2013). Identification of drought, heat, and combined drought and heat tolerant donors in maize. *Crop Science*, 53(4), 1335–1346. <https://doi.org/10.2135/cropsci2012.09.0545>

- Chaikam, V., Molenaar, W., Melchinger, A. E., & Boddupalli, P. M. (2019). Doubled haploid technology for line development in maize: technical advances and prospects. In *Theoretical and Applied Genetics* (Vol. 132, Issue 12, pp. 3227–3243). Springer Verlag. <https://doi.org/10.1007/s00122-019-03433-x>
- Che, Y., Wang, Q., Xie, Z., Zhou, L., Li, S., Hui, F., Wang, X., Li, B., & Ma, Y. (2020). Estimation of maize plant height and leaf area index dynamics using an unmanned aerial vehicle with oblique and nadir photography. *Annals of Botany*, *126*(4), 765–773. <https://doi.org/10.1093/aob/mcaa097>
- Ciampitti, I. A., & Vyn, T. J. (2012). Physiological perspectives of changes over time in maize yield dependency on nitrogen uptake and associated nitrogen efficiencies: A review. *Field Crops Research*, *133*, 48–67. <https://doi.org/10.1016/J.FCR.2012.03.008>
- Ciampitti, I. A., & Vyn, T. J. (2013). Grain nitrogen source changes over time in maize: A review. In *Crop Science* (Vol. 53, Issue 2, pp. 366–377). <https://doi.org/10.2135/cropsci2012.07.0439>
- Cooper, M., & Messina, C. D. (2021). Can We Harness “Enviromics” to Accelerate Crop Improvement by Integrating Breeding and Agronomy? *Frontiers in Plant Science*, *12*. <https://doi.org/10.3389/fpls.2021.735143>
- Crossa, J., Pérez-Rodríguez, P., Cuevas, J., Montesinos-López, O., Jarquín, D., de los Campos, G., Burgueño, J., González-Camacho, J. M., Pérez-Elizalde, S., Beyene, Y., Dreisigacker, S., Singh, R., Zhang, X., Gowda, M., Roorkiwal, M., Rutkoski, J., & Varshney, R. K. (2017). Genomic Selection in Plant Breeding: Methods, Models, and Perspectives. *Trends in Plant Science*, *22*(11), 961–975. <https://doi.org/10.1016/j.tplants.2017.08.011>
- ENNOS, A. R., CROOK, M. J., & GRIMSHAW, C. (1993). The Anchorage Mechanics of Maize, *Zea mays*. *Journal of Experimental Botany*, *44*(1), 147–153. <https://doi.org/10.1093/jxb/44.1.147>
- ESOTC. (2022). *STATE OF THE CLIMATE 2022*. <https://climate.copernicus.eu/esotc/2022>
- ESOTC. (2023). *EUROPEAN STATE OF THE CLIMATE SUMMARY 2022*.
- FAO GAEZ. (2022). *THE GLOBAL AGRO-ECOLOGICAL ZONING version 4 Crop profile: Maize GENERAL DESCRIPTION*. <http://www.fao.org/faostat/en/#data/QC>

- Food and Agriculture Organization of the United Nations (FAO). (2018). *E-Agriculture in action: drones for agriculture* (Gerard Sylvester, Ed.). Food and Agriculture Organization of the United Nations (FAO).
- Gao, M., Yang, F., Wei, H., & Liu, X. (2022). Individual Maize Location and Height Estimation in Field from UAV-Borne LiDAR and RGB Images. *Remote Sensing*, *14*(10). <https://doi.org/10.3390/rs14102292>
- García-Munguía, A., Guerra-Ávila, P. L., Islas-Ojeda, E., Flores-Sánchez, J. L., Vázquez-Martínez, O., García-Munguía, A. M., & García-Munguía, O. (2024). A Review of Drone Technology and Operation Processes in Agricultural Crop Spraying. In *Drones* (Vol. 8, Issue 11). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/drones8110674>
- Garzonio, R., di Mauro, B., Colombo, R., & Cogliati, S. (2017). Surface reflectance and sun-induced fluorescence spectroscopy measurements using a small hyperspectral UAS. *Remote Sensing*, *9*(5). <https://doi.org/10.3390/rs9050472>
- Ge, H., Zhang, Q., Shen, M., Qin, Y., Wang, L., & Yuan, C. (2025). Enhancing yield prediction in maize breeding using UAV-derived RGB imagery: a novel classification-integrated regression approach. *Frontiers in Plant Science*, *16*. <https://doi.org/10.3389/fpls.2025.1511871>
- Guebsi, R., Mami, S., & Chokmani, K. (2024). Drones in Precision Agriculture: A Comprehensive Review of Applications, Technologies, and Challenges. In *Drones* (Vol. 8, Issue 11). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/drones8110686>
- Habib, A., Han, Y., Xiong, W., He, F., Zhang, Z., & Crawford, M. (2016). Automated orthorectification of UAV-based hyperspectral data over an agricultural field using frame RGB imagery. *Remote Sensing*, *8*(10). <https://doi.org/10.3390/rs8100796>
- Hampton, J. G., & Hill, M. J. (2002). Seed quality and New Zealand's native plants: An unexplored relationship? *New Zealand Journal of Botany*, *40*(3), 357–364. <https://doi.org/10.1080/0028825X.2002.9512796>
- Hartmann, Jacques., Scott, B. I. ., Truxal, Steven., Bertolini, Andrea., & Masutti, Anna. (2024). *Civil regulation of autonomous unmanned aircraft systems in Europe*. Edward Elgar Publishing.

- He, B., Pan, S., Zhao, J., Zou, X., Liu, X., & Wu, S. (2024). Maize Improvement Based on Modern Breeding Strategies: Progress and Perspective. *ACS Agricultural Science & Technology*, 4(3), 274–282. <https://doi.org/10.1021/acsagscitech.3c00427>
- Hu, X., Sun, L., Gu, X., Sun, Q., Wei, Z., Pan, Y., & Chen, L. (2021). Assessing the self-recovery ability of maize after lodging using uav-lidar data. *Remote Sensing*, 13(12). <https://doi.org/10.3390/rs13122270>
- Hütt, C., Bolten, A., Hüging, H., & Bareth, G. (2023). UAV LiDAR Metrics for Monitoring Crop Height, Biomass and Nitrogen Uptake: A Case Study on a Winter Wheat Field Trial. *PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 91(2), 65–76. <https://doi.org/10.1007/s41064-022-00228-6>
- Kashani, A. G., Olsen, M. J., Parrish, C. E., & Wilson, N. (2015). A review of LIDAR radiometric processing: From ad hoc intensity correction to rigorous radiometric calibration. In *Sensors (Switzerland)* (Vol. 15, Issue 11, pp. 28099–28128). MDPI AG. <https://doi.org/10.3390/s151128099>
- Khosravipour, A., Skidmore, A. K., Isenburg, M., Wang, T., & Hussin, Y. A. (2014). Generating Pit-free Canopy Height Models from Airborne Lidar. *Photogrammetric Engineering & Remote Sensing*, 80(9), 863–872. <https://doi.org/10.14358/PERS.80.9.863>
- KSH. (2023). *Agrárium, 2023, előzetes adatok.*
- Lauer, J. (2008). *Mid-and Late-Season Yield Enhancing Management Practices for Corn* (Vol. 28).
- Li, F., Piasecki, C., Millwood, R. J., Wolfe, B., Mazarei, M., & Stewart, C. N. (2020). High-Throughput Switchgrass Phenotyping and Biomass Modeling by UAV. *Frontiers in Plant Science*, 11. <https://doi.org/10.3389/fpls.2020.574073>
- Madec, S., Baret, F., De Solan, B., Thomas, S., Dutartre, D., Jezequel, S., Hemmerlé, M., Colombeau, G., & Comar, A. (2017). High-throughput phenotyping of plant height: Comparing unmanned aerial vehicles and ground lidar estimates. *Frontiers in Plant Science*, 8. <https://doi.org/10.3389/fpls.2017.02002>
- Mallet, C., & Bretar, F. (2009). Full-waveform topographic lidar: State-of-the-art. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(1), 1–16. <https://doi.org/10.1016/J.ISPRSJPRS.2008.09.007>

- Marcos Filho, J. (2015). *Fisiologia de sementes de plantas cultivadas*. Abrates.
- Micheletto, M. J., Chesñevar, C. I., & Santos, R. (2023a). Methods and Applications of 3D Ground Crop Analysis Using LiDAR Technology: A Survey. In *Sensors* (Vol. 23, Issue 16). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/s23167212>
- Micheletto, M. J., Chesñevar, C. I., & Santos, R. (2023b). Methods and Applications of 3D Ground Crop Analysis Using LiDAR Technology: A Survey. In *Sensors* (Vol. 23, Issue 16). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/s23167212>
- Nguyen, C., Sagan, V., Bhadra, S., & Moose, S. (2023). UAV Multisensory Data Fusion and Multi-Task Deep Learning for High-Throughput Maize Phenotyping. *Sensors*, 23(4). <https://doi.org/10.3390/s23041827>
- Nleya ThandiweNleya, T., Chungu chungu, C., & Kleinjan JonathanKleinjan, J. (2019). *Chapter 5: Corn Growth and Development*.
- Panigrahi, S. S., Singh, K. D., Balasubramanian, P., Wang, H., Natarajan, M., & Ravichandran, P. (2025). UAV-Based LiDAR and Multispectral Imaging for Estimating Dry Bean Plant Height, Lodging and Seed Yield. *Sensors*, 25(11), 3535. <https://doi.org/10.3390/s25113535>
- Rejeb, A., Abdollahi, A., Rejeb, K., & Treiblmaier, H. (2022). Drones in agriculture: A review and bibliometric analysis. *Computers and Electronics in Agriculture*, 198, 107017. <https://doi.org/https://doi.org/10.1016/j.compag.2022.107017>
- Report on the State of the Knowledge – Literature Review on Unmanned Aerial Spray Systems in Agriculture*. (2021). [www.oecd.org/chemicalsafety/](http://www.oecd.org/chemicalsafety/)
- Samad, Abd. M., Kamarulzaman, N., Hamdani, M. A., Mastor, T. A., & Hashim, K. A. (2013). The potential of Unmanned Aerial Vehicle (UAV) for civilian and mapping application. *2013 IEEE 3rd International Conference on System Engineering and Technology*, 313–318. <https://doi.org/10.1109/ICSEngT.2013.6650191>
- Santesteban, L. G., Di Gennaro, S. F., Herrero-Langreo, A., Miranda, C., Royo, J. B., & Matese, A. (2017). High-resolution UAV-based thermal imaging to estimate the instantaneous and

- seasonal variability of plant water status within a vineyard. *Agricultural Water Management*, 183, 49–59. <https://doi.org/10.1016/j.agwat.2016.08.026>
- Spears, J. (2002). Seed vigor testing handbook. *Association of Official Seed Analysts, USA*.
- Steven W. Ritchie, John J. Hanway, Garren O. Benson, J. Clayton Herman, Steven J. Lupkes, Ricardo J. Salvador, Robert Satter, William Miller, & Aaron Kitzman. (1993). *How a Corn Plant Develops (Special Report 48)*. <https://www-archiv.fdm.uni-hamburg.de/b-online/library/maize/www.ag.iastate.edu/departments/agronomy/corngrows.html>
- Su, W., Zhang, M., Bian, D., Liu, Z., Huang, J., Wang, W., Wu, J., & Guo, H. (2019). Phenotyping of corn plants using unmanned aerial vehicle (UAV) images. *Remote Sensing*, 11(17). <https://doi.org/10.3390/rs11172021>
- ten Harkel, J., Bartholomeus, H., & Kooistra, L. (2020). Biomass and crop height estimation of different crops using UAV-based LiDAR. *Remote Sensing*, 12(1). <https://doi.org/10.3390/RS12010017>
- Tollenaar, M., & Lee, E. (2006). *Physiological dissection of grain yield in maize by examining genetic improvement and heterosis SEE PROFILE*. <https://www.researchgate.net/publication/234392331>
- Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A review on UAV-based applications for precision agriculture. In *Information (Switzerland)* (Vol. 10, Issue 11). MDPI AG. <https://doi.org/10.3390/info10110349>
- Varshney, R. K., Singh, V. K., Kumar, A., Powell, W., & Sorrells, M. E. (2018). Can genomics deliver climate-change ready crops? In *Current Opinion in Plant Biology* (Vol. 45, pp. 205–211). Elsevier Ltd. <https://doi.org/10.1016/j.pbi.2018.03.007>
- Wahab, I., Hall, O., & Jirstrom, M. (2018). Remote sensing of yields: Application of UAV imagery-derived ndvi for estimating maize vigor and yields in complex farming systems in Sub-Saharan Africa. *Drones*, 2(3), 1–16. <https://doi.org/10.3390/drones2030028>
- Walter, J. D. C., Edwards, J., McDonald, G., & Kuchel, H. (2019). Estimating Biomass and Canopy Height With LiDAR for Field Crop Breeding. *Frontiers in Plant Science*, 10. <https://doi.org/10.3389/fpls.2019.01145>

- Wang, H., Singh, K. D., Poudel, H. P., Natarajan, M., Ravichandran, P., & Eisenreich, B. (2024). Forage Height and Above-Ground Biomass Estimation by Comparing UAV-Based Multispectral and RGB Imagery. *Sensors*, 24(17). <https://doi.org/10.3390/s24175794>
- Wehr, A., & Lohr, U. (1999). Airborne laser scanning—an introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2–3), 68–82. [https://doi.org/10.1016/S0924-2716\(99\)00011-8](https://doi.org/10.1016/S0924-2716(99)00011-8)
- Wen, W., Gu, S., Xiao, B., Wang, C., Wang, J., Ma, L., Wang, Y., Lu, X., Yu, Z., Zhang, Y., Du, J., & Guo, X. (2019). In situ evaluation of stalk lodging resistance for different maize (*Zea mays* L.) cultivars using a mobile wind machine. *Plant Methods*, 15(1). <https://doi.org/10.1186/s13007-019-0481-1>
- Xie, C., & Yang, C. (2020). A review on plant high-throughput phenotyping traits using UAV-based sensors. *Computers and Electronics in Agriculture*, 178, 105731. <https://doi.org/10.1016/J.COMPAG.2020.105731>
- Yang, G., Liu, J., Zhao, C., Li, Z., Huang, Y., Yu, H., Xu, B., Yang, X., Zhu, D., Zhang, X., Zhang, R., Feng, H., Zhao, X., Li, Z., Li, H., & Yang, H. (2017a). Unmanned aerial vehicle remote sensing for field-based crop phenotyping: Current status and perspectives. In *Frontiers in Plant Science* (Vol. 8). Frontiers Media S.A. <https://doi.org/10.3389/fpls.2017.01111>
- Yang, G., Liu, J., Zhao, C., Li, Z., Huang, Y., Yu, H., Xu, B., Yang, X., Zhu, D., Zhang, X., Zhang, R., Feng, H., Zhao, X., Li, Z., Li, H., & Yang, H. (2017b). Unmanned aerial vehicle remote sensing for field-based crop phenotyping: Current status and perspectives. In *Frontiers in Plant Science* (Vol. 8). Frontiers Media S.A. <https://doi.org/10.3389/fpls.2017.01111>
- Zeng, C., King, D. J., Richardson, M., & Shan, B. (2017). Fusion of multispectral imagery and spectrometer data in UAV remote sensing. *Remote Sensing*, 9(7). <https://doi.org/10.3390/rs9070696>
- Zhang, C., & Kovacs, J. M. (2012a). The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*, 13(6), 693–712. <https://doi.org/10.1007/s11119-012-9274-5>

Zhang, C., & Kovacs, J. M. (2012b). The application of small unmanned aerial systems for precision agriculture: A review. In *Precision Agriculture* (Vol. 13, Issue 6, pp. 693–712). <https://doi.org/10.1007/s11119-012-9274-5>

Zhou, L., Gu, X., Cheng, S., Yang, G., Shu, M., & Sun, Q. (2020). Analysis of plant height changes of lodged maize using UAV-LiDAR data. *Agriculture (Switzerland)*, *10*(5). <https://doi.org/10.3390/agriculture10050146>

## 8. Mellékletek

### Case Processing Summary

	Cases					
	Valid		Missing		Total	
	N	Percent	N	Percent	N	Percent
Lidar_Volume	776	100,0%	0	0,0%	776	100,0%

### Descriptives

		Statistic	Std. Error
Lidar_Volume	Mean	2,0275	,00378
	95% Confidence Interval for Mean		
	Lower Bound	2,0201	
	Upper Bound	2,0349	
	5% Trimmed Mean	2,0273	
	Median	2,0300	
	Variance	,011	
	Std. Deviation	,10521	
	Minimum	1,69	
	Maximum	2,33	
	Range	,64	
	Interquartile Range	,13	
	Skewness	,028	,088
	Kurtosis	,064	,175

### Tests of Normality

	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
Lidar_Volume	,035	776	,024	,998	776	,393

a. Lilliefors Significance Correction

## Lidar\_Volume

## Explore

### Notes

Output Created	08-NOV-2025 20:16:48	
Comments		
Input	Active Dataset	DataSet3
	Filter	<none>
	Weight	<none>
	Split File	<none>
	N of Rows in Working Data File	776
Missing Value Handling	Definition of Missing	User-defined missing values for dependent variables are treated as missing.
	Cases Used	Statistics are based on cases with no missing values for any dependent variable or factor used.

Syntax		EXAMINE VARIABLES=PV_Manual  /PLOT           BOXPLOT STEMLEAF    HISTOGRAM NPLOT  /COMPARE GROUPS  /STATISTICS DESCRIPTIVES  /CINTERVAL 95  /MISSING LISTWISE  /NOTOTAL.
Resources	Processor Time	00:00:00,31
	Elapsed Time	00:00:00,30

### Case Processing Summary

	Cases					
	Valid		Missing		Total	
	N	Percent	N	Percent	N	Percent
PV_Manual	775	99,9%	1	0,1%	776	100,0%

### Descriptives

		Statistic	Std. Error
PV_Manual	Mean	5,27	,042
	95% Confidence Interval for Lower Bound Mean		5,19
	Upper Bound		5,35
	5% Trimmed Mean		5,33
	Median		5,00

Variance	1,348	
Std. Deviation	1,161	
Minimum	1	
Maximum	9	
Range	8	
Interquartile Range	0	
Skewness	-,456	,088
Kurtosis	3,129	,175

### Tests of Normality

	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
PV_Manual	,381	775	,000	,683	775	,000

a. Lilliefors Significance Correction

## PV\_Manual

### Regression 1

#### Descriptive Statistics

	Mean	Std. Deviation	N
Lidar_Volume	2,0276	,10525	775
PV_Manual	5,27	1,161	775
CCVR_PCT_Image Analysis Generated	9,1527	2,42006	775

### Correlations

		Lidar_Volume	PV_Manual	CCVR_PCT_Im age Analysis Generated
Pearson Correlation	Lidar_Volume	1,000	-,321	,576
	PV_Manual	-,321	1,000	-,405
	CCVR_PCT_Image Analysis Generated	,576	-,405	1,000
Sig. (1-tailed)	Lidar_Volume	.	,000	,000
	PV_Manual	,000	.	,000
	CCVR_PCT_Image Analysis Generated	,000	,000	.
N	Lidar_Volume	775	775	775
	PV_Manual	775	775	775
	CCVR_PCT_Image Analysis Generated	775	775	775

### Variables Entered/Removed<sup>a</sup>

Model	Variables Entered	Variables Removed	Method
1	CCVR_PCT_Im age Analysis Generated, PV_Manual <sup>b</sup>	.	Enter

a. Dependent Variable: Lidar\_Volume

b. All requested variables entered.

**Model Summary<sup>b</sup>**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics				
					R Square Change	F Change			
1	,584 <sup>a</sup>	,341	,340	,08554	,341	199,927			

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2,926	2	1,463	199,927	,000 <sup>b</sup>
	Residual	5,649	772	,007		
	Total	8,574	774			

a. Dependent Variable: Lidar\_Volume

b. Predictors: (Constant), CCVR\_PCT\_Image Analysis Generated, PV\_Manual

**Coefficients<sup>a</sup>**

Model		Unstandardized Coefficients		Standardized Coefficients	t							
		B	Std. Error									
1	(Constant)	1,865	,024		78,723							

PV_Manual	-,009	,003	-,105	- 3,2 72								
CCVR_PCT _Image Analysis Generated	,023	,001	,534	16, 716								

### Collinearity Diagnostics<sup>a</sup>

Model	Dimension	Eigenvalue	Condition Index	Variance Proportions		
				(Constant)	PV_Manual	CCVR_PCT_Im age Analysis Generated
1	1	2,910	1,000	,00	,00	,01
	2	,078	6,090	,00	,22	,38
	3	,011	16,235	1,00	,78	,61

a. Dependent Variable: Lidar\_Volume

### Residuals Statistics<sup>a</sup>

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	1,8577	2,2232	2,0276	,06148	775
Std. Predicted Value	-2,764	3,181	,000	1,000	775
Standard Error of Predicted Value	,003	,015	,005	,002	775
Adjusted Predicted Value	1,8585	2,2237	2,0276	,06146	775
Residual	-,34685	,28827	,00000	,08543	775
Std. Residual	-4,055	3,370	,000	,999	775

Stud. Residual	-4,058	3,372	,000	1,000	775
Deleted Residual	-,34733	,28867	-,00001	,08573	775
Stud. Deleted Residual	-4,099	3,395	,000	1,002	775
Mahal. Distance	,054	21,245	1,997	2,646	775
Cook's Distance	,000	,015	,001	,002	775
Centered Leverage Value	,000	,027	,003	,003	775

a. Dependent Variable: Lidar\_Volume

## Regression 2

COO_2	Cook's Distance
LEV_2	Centered Leverage Value

### Descriptive Statistics

	Mean	Std. Deviation	N
Lidar_Volume	2,0276	,10525	775
PV_Manual	5,27	1,161	775

### Correlations

		Lidar_Volume	PV_Manual
Pearson Correlation	Lidar_Volume	1,000	-,321
	PV_Manual	-,321	1,000
Sig. (1-tailed)	Lidar_Volume	.	,000
	PV_Manual	,000	.
N	Lidar_Volume	775	775
	PV_Manual	775	775

### Variables Entered/Removed<sup>a</sup>

Model	Variables Entered	Variables Removed	Method
1	PV_Manual <sup>b</sup>	.	Enter

a. Dependent Variable: Lidar\_Volume

b. All requested variables entered.

### Model Summary<sup>b</sup>

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics				
					R Square Change	F Change			
1	,321 <sup>a</sup>	,103	,102	,09976	,103	88,546			

### ANOVA<sup>a</sup>

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,881	1	,881	88,546	,000 <sup>b</sup>
	Residual	7,693	773	,010		
	Total	8,574	774			

a. Dependent Variable: Lidar\_Volume

b. Predictors: (Constant), PV\_Manual

### Coefficients<sup>a</sup>

Model	Unstandardized Coefficients	Standardized Coefficients	t	Sig.						

		B	Std. Error	Beta								
1	(Constant)	2,181	,017		130,814	,000						
	PV_Manual	-,029	,003	-,321	-9,410	,000						

### Collinearity Diagnostics<sup>a</sup>

Model	Dimension	Eigenvalue	Condition Index	Variance Proportions	
				(Constant)	PV_Manual
1	1	1,977	1,000	,01	,01
	2	,023	9,196	,99	,99

a. Dependent Variable: Lidar\_Volume

### Residuals Statistics<sup>a</sup>

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	1,9192	2,1518	2,0276	,03374	775
Std. Predicted Value	-3,212	3,679	,000	1,000	775
Standard Error of Predicted Value	,004	,014	,005	,002	775
Adjusted Predicted Value	1,9192	2,1560	2,0276	,03377	775
Residual	-,34549	,29451	,00000	,09970	775
Std. Residual	-3,463	2,952	,000	,999	775
Stud. Residual	-3,465	2,954	,000	1,001	775
Deleted Residual	-,34596	,29491	-,00001	,09995	775

Stud. Deleted Residual	-3,490	2,969	,000	1,002	775
Mahal. Distance	,054	13,535	,999	2,257	775
Cook's Distance	,000	,048	,001	,003	775
Centered Leverage Value	,000	,017	,001	,003	775

a. Dependent Variable: Lidar\_Volume

## Charts

## Lidar Volume graph

## Explore

## PV\_Manual

### Case Processing Summary

	PV_Manual	Cases					
		Valid		Missing		Total	
		N	Percent	N	Percent	N	Percent
Lidar_Volume	1	16	100,0%	0	0,0%	16	100,0%
	3	32	100,0%	0	0,0%	32	100,0%
	5	563	100,0%	0	0,0%	563	100,0%
	7	159	100,0%	0	0,0%	159	100,0%
	9	5	100,0%	0	0,0%	5	100,0%

# Hibrid 1

## Case Processing Summary<sup>a</sup>

	Név	Cases				Total N	
		Valid		Missing			
		N	Percent	N	Percent		
Lidar_Volume	Hibrid-1	35	100,0%	0	0,0%	35	
GYLD (qa/ha 0% <sup>mst</sup> )	Hibrid-1	35	100,0%	0	0,0%	35	

## Descriptives<sup>a</sup>

	Név		Statistic	Std. Error
Lidar_Volume	Hibrid-1	Mean	1,9080	,01391
		95% Confidence Interval for Mean		
		Lower Bound	1,8797	
		Upper Bound	1,9363	
		5% Trimmed Mean	1,9051	
		Median	1,8900	
		Variance	,007	
		Std. Deviation	,08231	
		Minimum	1,75	
		Maximum	2,14	
		Range	,39	
		Interquartile Range	,11	
		Skewness	,571	,398

		Kurtosis	,485	,778	
GYLD (qa/ha 0% <i>mst</i> )	Hibrid-1	Mean	76,1537	,81247	
		95% Confidence Interval for Mean	Lower Bound	74,5026	
			Upper Bound	77,8049	
		5% Trimmed Mean	76,1347		
		Median	75,8200		
		Variance	23,104		
		Std. Deviation	4,80666		
		Minimum	63,78		
		Maximum	88,15		
		Range	24,37		
		Interquartile Range	5,36		
		Skewness	,148	,398	
		Kurtosis	,941	,778	

a. Név = Hibrid-1

### Tests of Normality<sup>a</sup>

	Név	Kolmogorov-Smirnov <sup>b</sup>			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	
Lidar_Volume	Hibrid-1	,139	35	,086	,970	35	
GYLD (qa/ha 0% <i>mst</i> )	Hibrid-1	,155	35	,033	,967	35	

Hibrid 2

### Case Processing Summary<sup>a</sup>

	Név	Cases				Total N	
		Valid		Missing			
		N	Percent	N	Percent		
Lidar_Volume	Hibrid-2	31	100,0%	0	0,0%	31	
GYLD (qa/ha 0% <i>mst</i> )	Hibrid-2	31	100,0%	0	0,0%	31	

### Descriptives<sup>a</sup>

	Név		Statistic	Std. Error	
Lidar_Volume	Hibrid-2	Mean	2,0132	,01405	
		95% Confidence Interval for Mean	Lower Bound	1,9845	
			Upper Bound	2,0419	
		5% Trimmed Mean	2,0083		
		Median	2,0200		
		Variance	,006		
		Std. Deviation	,07825		
		Minimum	1,88		
		Maximum	2,27		
		Range	,39		
		Interquartile Range	,09		
		Skewness	1,141	,421	
		Kurtosis	2,857	,821	
		GYLD (qa/ha 0% <i>mst</i> )	Hibrid-2	Mean	84,6342

95% Confidence Interval for Mean	Lower Bound	81,7689	
	Upper Bound	87,4995	
5% Trimmed Mean		84,3775	
Median		82,6300	
Variance		61,022	
Std. Deviation		7,81165	
Minimum		70,27	
Maximum		106,49	
Range		36,22	
Interquartile Range		12,99	
Skewness		,673	,421
Kurtosis		,492	,821

a. Név = Hibrid-2

### Tests of Normality<sup>a</sup>

	Név	Kolmogorov-Smirnov <sup>b</sup>			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	
Lidar_Volume	Hibrid-2	,146	31	,091	,923	31	
GYLD (qa/ha 0% <i>mst</i> )	Hibrid-2	,165	31	,030	,948	31	

Hibrid 3

### Case Processing Summary<sup>a</sup>

	Név	Cases				Total N	
		Valid		Missing			
		N	Percent	N	Percent		
Lidar_Volume	Hibrid-3	32	100,0%	0	0,0%	32	
GYLD (qa/ha 0% <i>mst</i> )	Hibrid-3	32	100,0%	0	0,0%	32	

### Descriptives<sup>a</sup>

	Név		Statistic	Std. Error	
Lidar_Volume	Hibrid-3	Mean	1,9497	,00962	
		95% Confidence Interval for Mean	Lower Bound	1,9301	
			Upper Bound	1,9693	
		5% Trimmed Mean	1,9470		
		Median	1,9500		
		Variance	,003		
		Std. Deviation	,05445		
		Minimum	1,86		
		Maximum	2,11		
		Range	,25		
		Interquartile Range	,06		
		Skewness	,688	,414	
		Kurtosis	1,205	,809	
GYLD (qa/ha 0% <i>mst</i> )	Hibrid-3	Mean	87,5897	,73018	
		95% Confidence Interval for Mean	Lower Bound	86,1005	
			Upper Bound	89,0789	

5% Trimmed Mean	87,5606	
Median	87,3200	
Variance	17,061	
Std. Deviation	4,13051	
Minimum	80,35	
Maximum	95,32	
Range	14,97	
Interquartile Range	6,39	
Skewness	,068	,414
Kurtosis	-,881	,809

a. Név = Hibrid-3

### Tests of Normality<sup>a</sup>

	Név	Kolmogorov-Smirnov <sup>b</sup>			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	
Lidar_Volume	Hibrid-3	,105	32	,200 <sup>*</sup>	,957	32	
GYLD (qa/ha 0% <sup>mst</sup> )	Hibrid-3	,088	32	,200 <sup>*</sup>	,973	32	

Hibrid 4

### Case Processing Summary<sup>a</sup>

Név	Cases			Total
	Valid	Missing		

		N	Percent	N	Percent	N	
Lidar_Volume	Hibrid-4	59	100,0%	0	0,0%	59	
GYLD (qa/ha 0% <i>mst</i> )	Hibrid-4	59	100,0%	0	0,0%	59	

### Descriptives<sup>a</sup>

	Név		Statistic	Std. Error	
Lidar_Volume	Hibrid-4	Mean	2,0432	,00820	
		95% Confidence Interval for Mean	Lower Bound	2,0268	
			Upper Bound	2,0596	
		5% Trimmed Mean	2,0436		
		Median	2,0400		
		Variance	,004		
		Std. Deviation	,06298		
		Minimum	1,90		
		Maximum	2,18		
		Range	,28		
		Interquartile Range	,09		
		Skewness	-,110	,311	
		Kurtosis	-,295	,613	
		GYLD (qa/ha 0% <i>mst</i> )	Hibrid-4	Mean	85,8795
95% Confidence Interval for Mean	Lower Bound			84,3505	
	Upper Bound			87,4085	
5% Trimmed Mean	85,9002				

Median	85,5900	
Variance	34,424	
Std. Deviation	5,86719	
Minimum	72,74	
Maximum	101,33	
Range	28,59	
Interquartile Range	7,85	
Skewness	,113	,311
Kurtosis	-,060	,613

a. Név = Hibrid-4

### Tests of Normality<sup>a</sup>

	Név	Kolmogorov-Smirnov <sup>b</sup>			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	
Lidar_Volume	Hibrid-4	,076	59	,200*	,988	59	
GYLD (qa/ha 0% <i>mst</i> )	Hibrid-4	,066	59	,200*	,990	59	

Hibrid 5

### Case Processing Summary<sup>a</sup>

	Név	Cases				Total N	
		Valid		Missing			
		N	Percent	N	Percent		
Lidar_Volume	Hibrid-5	53	100,0%	0	0,0%	53	

GYLD (qa/ha 0% <i>mst</i> ) Hibrid-5	53	100,0%	0	0,0%	53	
--------------------------------------	----	--------	---	------	----	--

### Descriptives<sup>a</sup>

	Név		Statistic	Std. Error	
Lidar_Volume	Hibrid-5	Mean	2,1592	,01177	
		95% Confidence Interval for Mean	Lower Bound	2,1356	
			Upper Bound	2,1829	
		5% Trimmed Mean	2,1594		
		Median	2,1600		
		Variance	,007		
		Std. Deviation	,08566		
		Minimum	1,96		
		Maximum	2,33		
		Range	,37		
		Interquartile Range	,13		
		Skewness	,072	,327	
		Kurtosis	-,432	,644	
		GYLD (qa/ha 0% <i>mst</i> )	Hibrid-5	Mean	84,6742
95% Confidence Interval for Mean	Lower Bound			83,0461	
	Upper Bound			86,3022	
5% Trimmed Mean	84,5440				
Median	84,2600				
Variance	34,886				

	Std. Deviation	5,90645	
	Minimum	72,22	
	Maximum	99,84	
	Range	27,62	
	Interquartile Range	8,33	
	Skewness	,335	,327
	Kurtosis	,252	,644

a. Név = Hibrid-5

### Tests of Normality<sup>a</sup>

	Név	Kolmogorov-Smirnov <sup>b</sup>			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	
Lidar_Volume	Hibrid-5	,102	53	,200 <sup>*</sup>	,977	53	
GYLD (qa/ha 0% <sup>mst</sup> )	Hibrid-5	,060	53	,200 <sup>*</sup>	,986	53	

Hibrid 6

### Descriptive Statistics<sup>a</sup>

	Mean	Std. Deviation	N
Lidar_Volume	2,0020	,07265	30
GYLD (qa/ha 0% <sup>mst</sup> )	91,4693	4,87612	30

a. Név = Hibrid-6

### Correlations<sup>a</sup>

		Lidar_Volume	GYLD (qa/ha 0% <i>mst</i> )
Lidar_Volume	Pearson Correlation	1	,262
	Sig. (2-tailed)		,162
	N	30	30
GYLD (qa/ha 0% <i>mst</i> )	Pearson Correlation	,262	1
	Sig. (2-tailed)	,162	
	N	30	30

a. Név = Hibrid-6

### Hibrid 7

### Descriptive Statistics<sup>a</sup>

	Mean	Std. Deviation	N
Lidar_Volume	2,0160	,07807	35
GYLD (qa/ha 0% <i>mst</i> )	91,8046	6,05872	35

a. Név = Hibrid-7

### Correlations<sup>a</sup>

		Lidar_Volume	GYLD (qa/ha 0% <i>mst</i> )
Lidar_Volume	Pearson Correlation	1	,252
	Sig. (2-tailed)		,144
	N	35	35

GYLD (qa/ha 0% <i>mst</i> )	Pearson Correlation	,252	1
	Sig. (2-tailed)	,144	
	N	35	35

a. Név = Hibrid-7

## Hibrid 8

### Descriptive Statistics<sup>a</sup>

	Mean	Std. Deviation	N
Lidar_Volume	2,0383	,08243	41
GYLD (qa/ha 0% <i>mst</i> )	90,1051	6,38663	41

a. Név = Hibrid-8

### Correlations<sup>a</sup>

		Lidar_Volume	GYLD (qa/ha 0% <i>mst</i> )
Lidar_Volume	Pearson Correlation	1	,540**
	Sig. (2-tailed)		,000
	N	41	41
GYLD (qa/ha 0% <i>mst</i> )	Pearson Correlation	,540**	1
	Sig. (2-tailed)	,000	
	N	41	41

\*\* . Correlation is significant at the 0.01 level (2-tailed).

## 9. Nyilatkozatok

### NYILATKOZAT

#### a diplomadolgozat<sup>1</sup> nyilvános hozzáféréseről és eredetiségéről

A hallgató neve:

Jóri Bertalan

A Hallgató Neptun kódja:

DLWDWH

A dolgozat címe:

Kuboricané mesítőgép hatékonyságának növelése: UAV  
inert szenzor (lidar) technológián alapuló új módszer

A megjelenés éve:

2025

Építészeti alkalmazás kiépítés  
kísérleti állományokban

A konzulens intézetének neve:

Növénytermesztési Tudományok Intézete

A konzulens tanszékének a neve:

Kijelentem, hogy az általam benyújtott záródolgozat/szakdolgozat/diplomadolgozat/portfólió<sup>2</sup> egyéni, eredeti jellegű, saját szellemi alkotásom. Azon részeket, melyeket más szerzők munkájából vettem át, egyértelműen megjelöltem, és az irodalomjegyzékben szerepeltettem. Továbbá kijelentem, hogy a dolgozat elkészítése során alkalmazott mesterséges intelligencia-eszközök (pl. szöveggenerálás, nyelvi javítás, fordítás, adatelemzés) használata nem helyettesítette a saját kutatási és alkotói munkámat, azok alkalmazását a források között vagy a módszertani részben feltüntettem, és a szakmai-etikai elvárásoknak megfelelően jártam el.

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

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

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

Tudomásul veszem, hogy dolgozatom elektronikus változata feltöltésre kerül a Magyar Agrár- és Élettudományi Egyetem könyvtári repozitori rendszerébe. Tudomásul veszem, hogy a megvédett és

- nem titkosított dolgozat a védést követően
- titkosításra engedélyezett dolgozat a benyújtásától számított 5 év eltelte után nyilvánosan elérhető és kereshető lesz az Egyetem könyvtári repozitori rendszerében.

Kelt: 2025 év 11 hó 10 nap

  
Hallgató aláírása

<sup>1</sup> A megfelelő dolgozattípus meghagyása mellett a többi típus törlendő.

<sup>2</sup> A megfelelő dolgozattípus meghagyása mellett a többi típus törlendő.

## NYILATKOZAT

Jóri Bertalan (név) (hallgató Neptun azonosítója: OLWDWH)  
konzulenseként nyilatkozom arról, hogy a  
záródolgozatot/szakdolgozatot/diplomadolgozatot/portfóliót<sup>1</sup> áttekintettem, a hallgatót az  
irodalmi források korrekt kezelésének követelményeiről, jogi és etikai szabályairól  
tájékoztattam.

A záródolgozatot/szakdolgozatot/diplomadolgozatot/portfóliót a záróvizsgán történő  
védésre javaslom / nem javaslom<sup>2</sup>.

A dolgozat állam- vagy szolgálati titkot tartalmaz: igen nem<sup>3</sup>

Kelt: 2025 év 11 hó 10 nap



belső konzulens

<sup>1</sup> A megfelelő dolgozattípus meghagyása mellett a többi típus törölendő.

<sup>2</sup> A megfelelő aláhúzendó.

<sup>3</sup> A megfelelő aláhúzendó.

## Hallgatók, doktoranduszok nyilatkozata mesterséges intelligencia (MI) alkalmazásáról

### 1. Általános adatok

Hallgató neve:	Jóki Bertalan
Neptun-kódja:	OLKDVKI
Képzési szint (a megfelelőt jelölje X-szel):	<input type="checkbox"/> BSc/BA <input checked="" type="checkbox"/> MSc/MA <input type="checkbox"/> Doktori (PhD) <input type="checkbox"/> Egyéb: .....
Tantárgy neve/kódja*:	Diplomadolgozat II. (AKVKB06N)
A munka címe:	Kulturális nemzeti katekizációk szerepe és hatása az azarctudományok zoológia nyelvészet és filozófiájában és felhasználása a köznevelés körében a 19. században.

\* doktori értekezés esetén nem kitöltendő

### 2. Nyilatkozat az MI használatáról

Alulírott, etikai felelősségem teljes tudatában az alábbi nyilatkozatot teszem:

(Kérjük, válasszon egyet az alábbi lehetőségek közül!)

- A) Nem alkalmaztam mesterséges intelligencia rendszert vagy szolgáltatást.  
(Amennyiben ezt jelölte, a további táblázatok kitöltése nem szükséges.)
- B) Alkalmaztam mesterséges intelligencia rendszert vagy szolgáltatást.  
(Kérjük, töltsse ki a vonatkozó táblázatokat!)

### 3. A mesterséges intelligencia használatának részletezése

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

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

A felhasználás célja	Alkalmazott MI-eszköz neve és verziója	Érintett rész (ha nem a szöveg egészére vonatkozik)
Asszisztensi feladatok elvégzése és nyelvhelyesség ellenőrzés	ChatGPT 5 Thinking Examini Pro	—

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

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

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

--	--	--	--

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

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

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

Oktató vagy témavezető által előírt szabályok:

.....  
.....  
.....  
.....

**4. Minden hallgatóra vonatkozó nyilatkozat:**

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

Kelt: ..... 2025 ..... 11 ..... hó ..... 10 ..... nap

.....  


Hallgató aláírása

.....  


Konzulens/Témavezető aláírása