

Doktori (PhD) értekezés

VARGA ZSÓFIA

BUDAPEST

2022



Magyar Agrár- és Élettudományi Egyetem

**A terepi távérzékelés és a roncsolásmentes növényvizsgálatok fejlesztési
lehetőségei**

DOI: 10.54598/003350

Varga Zsófia

Budapest

2022

A DOKTORI ISKOLA

Megnevezése: Kertészettudományi Doktori Iskola

Tudományága: Növénytermesztési és kertészeti tudományok

Vezetője: Zámboriné Dr. Németh Éva
egyetemi tanár, DSc
MATE, Kertészettudományi Intézet,
Gyógy- és Aromanövények Tanszék

Témavezető: Dr. Jung András
habilitált egyetemi docens, habil. PhD
ELTE IK Térképtudományi és Geoinformatikai Intézet

.....
Az iskolavezető jóváhagyása

.....
Témavezető jóváhagyása

TARTALOMJEGYZÉK

RÖVIDÍTÉSEK	VI
1 BEVEZETÉS.....	1
1.1 A téma aktualitása, jelentősége	1
1.2 Célkitűzések	2
2 IRODALMI ÁTTEKINTÉS	4
2.1 Terepi spektroszkópia	4
2.1.1 A távérzékelés és csoportosítása	5
2.1.2 A távérzékelési adatok tulajdonságai	7
2.2 A fény növényekre gyakorolt hatásai	10
2.2.1 Elektromágneses sugárzás és spektrum.....	11
2.2.2 A fény növényekre gyakorolt hatásai	13
2.2.3 A fény szabályozásának új irányai	18
2.2.3.1 A növénytermesztésen belül a fényszabályozás jövőbeli lehetőségei.....	21
2.2.4 A növényi fényvizsgálatokban leggyakrabban használt mértékegységek, spektrális mérőszámok	23
2.2.4.1 Radiometriai mérőszámok	23
2.2.4.2 Napsugárzást leíró és fotometriai mérőszámok.....	25
2.2.4.2.1 Napsugárzást leíró és fotometriai kvantumérésből adódó nehézségek	31
2.2.4.3 Spektrális mérőszámok.....	32
2.2.4.3.1 Klorofill indexek	33
2.2.4.3.2 Vízüindexek.....	34
2.2.4.3.3 Nitrogén-indexek.....	36
2.2.4.3.4 Kálium-, és foszfortartalommal összefüggést mutató spektrális indexek	38
2.2.4.3.5 Többváltozós és kombinált modellek.....	39
2.3 Roncsolásmentes növényvizsgálati módszerek és eszközök.....	41
2.3.1 Roncsolásmentes vizsgálatok múltja és jelene	43
2.3.2 A távérzékelés fontosabb eszközei.....	44
2.3.2.1 RGB fotográfia	44
2.3.2.2 Multi- és hiperspektrális reflexió érzékelők.....	45
2.3.2.3 Spektoradiométer	47
2.3.2.4 Termális kamerák	47
2.3.2.5 Fluoreszcens képalkotás	48
2.3.2.6 Szenzorok a növényi biomassza és a növényi szerkezetek értékeléséhez.....	48
2.3.2.7 Komplex terepi rendszerek	49
2.3.2.8 A terepi távérzékelés módszertani kérdései.....	50
3 ANYAG ÉS MÓDSZER.....	54
3.1 Passzív terepi spektoradiométerek terepi mérési módszertanának támogatása	54

3.1.1	Egy új mérőegység fejlesztése és prototípusa	55
3.1.1.1	Mérési „alátétek” alkalmazása.....	57
3.1.1.2	Spektroradiométer lehetséges csatlakoztatása Raspberry Pi-hez	58
3.1.1.3	Összehasonlítás <i>ASD FieldSpec Handheld 2</i> típusú spektroradiométerrel	58
3.1.2	Eltérő megvilágítási környezet mellett végzett vizsgálatok	59
3.1.2.1	Összehasonlító mérések Konica Minolta SPAD 502 mérőrendszerrel	60
3.1.2.2	A világítási rendszerek szabályozását és a spektrális adatokból kiinduló fényparaméterek megadását segítő vezérlőtábla létrehozása.....	62
3.1.2.3	Beltartalmi paraméterek összevetése a spektrális adatokkal	66
3.1.2.3.1	Növényi vízstressz spektroradiométeres detektálása.....	66
3.1.2.3.2	Nitrogén- és kálium tartalom meghatározása spektrális adatokból.....	66
3.1.2.4	A spektrális adatok kiértékelésének matematikai módszerei	68
3.2	Új eszközhordozó rendszereken (UAV) alkalmazott multispektrális érzékelők összehasonlítása és adatfeldolgozási oldalról történő vizsgálata	70
3.2.1	Drónokon alkalmazott multispektrális kamera mérési eredményének összehasonlítása a spektroradiométeres mérési eredményekkel	70
3.2.1.1	Összehasonlítása a műholdas távérzékelés mérési eredményeivel.....	72
3.2.1.2	Képfeldolgozási algoritmusok értékelése a közel valós idejű adatfeldolgozás szempontjából	73
3.2.1.2.1	Raszteres képi állományok spektrális vizsgálata.....	75
4	EREDMÉNYEK	77
4.1	Terepi alkalmazás fejlesztés eredménye és összehasonlító eredményei	77
4.1.1	Az elkészült prototípus végleges verziója	77
4.1.2	Csatlakoztatás Raspberry Pi mikroszámítógéppel	78
4.1.3	Összehasonlító mérések <i>ASD Fieldspec 2 Plant Probe</i> mérőrendszerrel.....	78
4.1.4	Eltérő megvilágítási környezetben végzett vizsgálatok eredményei.....	78
4.1.4.1	LED rendszerek és a HPS rendszer összehasonlítása.....	78
4.1.4.2	Fény jellemzésére alkalmazott mérőszámok megadása a spektrális adatok alapján ..	81
4.1.4.3	Konica Minolta SPAD 502 mérőrendszerrel végzett összehasonlító mérések eredményei.....	84
4.1.4.4	Beltartalmi paraméterek összevetése a távérzékelési adatokkal.....	85
4.1.4.4.1	Spektrális adatok kiértékelését segítő automata segédtableta eredményei	85
4.1.4.4.2	Vízstressz korrelációja a spektrális adatokkal	85
4.1.4.4.3	Nitrogén kezelések korrelációja a spektrális adatokkal.....	87
4.1.4.4.4	Kálium tartalom vizsgálatának eredményei	89
4.2	Drónok a terepi távérzékelés új eszközhordozóihoz kapcsolódó vizsgálatok eredményei	91
4.2.1	Terepi spektroszkópia és drónfelvételezés összevetése	91
4.2.2	Micasense Altum (UAV) kamera eredményeinek értékelése	95
4.2.2.1	Különböző csatornák eredményei	95
4.2.2.1.1	Valós színes kép és az egyes csatornák értékelése.....	95

4.2.2.1.2	Hamisszínes többszörös képek értékelése	98
4.2.2.2	Műholdképekkel történő összevetés	100
4.2.2.2.1	Sentinel-2 műholdképpel történő összevetés.....	100
4.2.2.3	Képosztályozási algoritmusok eredményei	105
4.2.2.3.1	Futtatási időre vonatkozó eredmények	105
4.2.2.3.2	Klaszterezés eredményei	105
4.2.2.3.3	Random Forest eredményei.....	106
4.2.2.3.4	Ellenőrzött képosztályozás eredményei	106
4.2.2.3.5	Főkomponens analízis (PCA) eredményei	110
4.2.2.3.6	A döntési fa eredményei	112
4.2.2.3.7	A vizsgált képi részterés állományok spektrális adatainak jellemzői	113
5	KÖVETKEZTETÉSEK, JAVASLATOK.....	116
5.1	Új és újszerű tudományos eredmények	120
6	ÖSSZEFOGLALÁS / SUMMARY	122
7	MELLÉKLETEK	125
M1	melléklet: Irodalomjegyzék	125
M2	melléklet: Ábrajegyzék	139
M3	melléklet: Táblázatok jegyzéke	143
M4	melléklet: Fénytani vezérlőtábla felépítése	145
M5	melléklet: A vizsgálatokba bevont spektrális indexek matematikai formulái.....	148
M6	melléklet: Spektrális indexek és a beltartalmi paraméterekkel szembeni korrelációjukat megadó számolótábla felépítése	150
M7	melléklet: Spektrális reflektancia mérési minták.....	152
M8	melléklet: A drónon alkalmazott multispektrális kamerájának feldolgozási munkamenete.....	154
M9	melléklet: Ellenőrzött osztályozási algoritmusok 6 osztályos területi eredményeinek összefoglaló táblázatai	154
M10	melléklet: Micasense Altum Tisza tavi felmérésének 6 osztályának spektrális adatainak spektrális távolság függvényeinek eredményei	155
M11	melléklet: Kódrészletek melléklete	156
8	KÖSZÖNETNYILVÁNÍTÁS	157

RÖVIDÍTÉSEK

GNSS	Global Navigational Satellite System, Globális navigációs műholdas rendszer
GIS	Geographic Information System, Földrajzi Információs Rendszer
RS	Remote Sensing, Távérzékelés
VIS	Visible Light, látható fény tartománya, az elektromágneses spektrum 380 nm – 760 nm közötti tartománya
PAR	Photosynthetically Active Radiation, fotoszintetikus aktív sugárzási tartomány, az elektromágneses spektrum 400 nm – 700 nm közötti tartománya
PPF	Photosynthetic Photon Flux, fotoszintetikus foton áram/fluxus
PPFD	Photosynthetic Photon Flux Density, fotoszintetikus foton áram sűrűség
DLI	Daily Light Integral, napi teljes megvilágítottság
SPD	Spectral Power Distribution, spektrális energia eloszlás
LED	Light emitting dioda – „fotont/fényt kisugárzó dióda”
PWM	impulzusszélesség-moduláció, egyfajta szabályozási megoldás, ahol a feszültség impulzusszélességének szabályozásával vezérlünk
HPS	High Pressure Sodium lamp, nagynyomású nátrium gőz lámpa
IPCC	Intergovernmental Panel on Climate Change, Éghajlatváltozási Kormányközi Testület
CIE	International Commission on Illumination, Nemzetközi Világítástechnikai Bizottság
NIR	közeli infravörös tartomány, az elektromágneses spektrum 800 nm – 1100 nm közötti tartománya
RedEdge	a 'vörös él' távérzékelési tartománya, az elektromágneses spektrum 690 nm – 720 nm közötti tartománya (legtágabban 700 – 800 nm közötti szakasz, szenzorspecifikus)
FR/FAR-RED	távoli vörös tartomány, az elektromágneses spektrum 700 nm – 750 nm közötti tartománya
R/RED	vörös tartomány, az elektromágneses spektrum 600 nm – 700 nm közötti tartománya
G/GREEN	zöld tartomány, az elektromágneses spektrum 500 nm – 600 nm közötti tartománya
B/BLUE	kék tartomány, az elektromágneses spektrum 400 nm – 500 nm közötti tartománya
LWIR	Long wave infrared, a termális infravörös spektrum tartománya
SPAD	Soil Plant Analysis Development, klorofill mérésének egyfajta kézi műszere
SDK	Software Developer Kit, szoftverfejlesztői forrásfájlok csomagja
UAV	Unmanned Aerial Vehicle, pilóta nélküli légi jármű

EXIF	digitális képkészítő által készített felvétel speciális információinak gyűjtőneve, mely beágyazva digitális formában, a képkészítés speciális információit, egyéb metaadatait tartalmazza a kép módosítása nélkül
GSD	Ground Sample Distance, digitális távérzékelte felvételek képi formátumának mérőszáma, mely megmutatja a pixelközéppontok valós felszínen megfeleltethető távolságát
SVM	Support Vector Machine, gépi tanulást megvalósító algoritmus
RF	Random Forest, gépi tanulást megvalósító algoritmus
ANN	Artificial Neural Network, mesterséges neurális háló, gépi tanulást megvalósító algoritmus
CNN	Convolution Neural Network, konvolúciós neurális háló, mély tanulást megvalósító modell
SR	Simple Ratio, a spektrális indexalkotás során összeadást, kivonást vagy osztást alkalmaz
RVI	Ratio Vegetation Index, hányados vegetációs index, a spektrális indexalkotás során osztást alkalmaz
ND	Normalized difference, a spektrális indexalkotás során a különbség és az összeg hányadosát képezi
RT	Radiative Transfer Models, sugárzási transzfer modellek
PLS-R	parciális legkisebb négyzet matematikai modellje, számos szakirodalom „Projection of Latent Structures” (Látens struktúrák vetítése) elnevezéssel alkalmazza

1 BEVEZETÉS

1.1 A téma aktualitása, jelentősége

A terepi távérzékelés módszerei napjaink legtöbb műszaki területét, így a mezőgazdaságot érintő fejlesztéseket is segíthetik. Mivel a növényi fotoszintézis fenntartásához, és a növények fejlődéséhez, növekedéséhez a fény az egyik legfontosabb klimatikus faktor, így vizsgálatához számos akár eltérő irány, illetve mérőrendszer kapcsolható. Mindezen vizsgálatok nem csak a szabadföldi termesztést befolyásolhatják, hanem ennél is hangsúlyosabb az üvegházi termesztő berendezések még hatékonyabb üzemeltetésének szempontjából. Ezen berendezésekben egyéb műszaki megoldásokkal tudjuk segíteni a termelékenység növelését és a hatékonyabb termesztés elérését.

Számos új műszaki megoldás fejlesztése indult meg, mely a fényhez köthető, ilyen irány például a szabályozható, nagyteljesítményű LED rendszerek terjedése, speciális fényreceptek fejlesztése, melyek célja a növényi beltartalmi paraméterek növelése kisebb környezetterhelés mellett. Az új világítástechnika megjelenésével emellett felborult a korábbiakban megszokott rendszer, mely a fényforrások gyakorlati oldal számára ismert paramétereit jelentette (például a teljesítmény (W)). A kertészeti világítástechnikai rendszereket gyártó és forgalmazó cégek nem nyújtanak megfelelő tájékoztatást a termelők részére, hogy a növények szempontjából optimális rendszereket telepítsenek termesztőberendezéseikbe. Adott esetben eltérő paraméterekkel jellemzik termékeiket, ami nehezíti az összehasonlíthatóságot és a vásárlói döntést.

Az előbbieket összefogja az egyre terjedő automatizáció, melynek lehet olyan célja, mely adott esetben méri a természetesen bejutó napfényt, és ennek függvényében szabályozza a világítási rendszert. Másik célja, hogy egyre inkább a növényi választ mérjük és ez szabályozza a környezeti paraméterek helyett az automatizált rendszereket. Ehhez egyre fontosabb a távérzékelési szenzorok és módszerek használata, melyek egyre kisebbek, és így számos hordozó eszközön elhelyezhetőek, akár önjárókon, robotkarokon, drónokon, de megtalálhatóak egyéb kézi eszközökön is.

A távérzékelési módszerek, mint roncsolásmentes vizsgálati lehetőségek tehát folyamatosan fejlődnek, mind a szenzorok használatának módszertanait tekintve, mind pedig modelljeik révén. Jelenleg a piacon azt tapasztalhatjuk, hogy számos irányból többféle szenzort és mérőrendszert alkalmaznak a gyakorlatban. Így egy terepi méréshez akár több szenzort kell magunkkal vinni, ezen rendszerek ára is lényegesen magas, és adott esetben az eltérő tudományterületek eltérő megközelítést (szenzort, mérőszámot) alkalmazhatnak, mely nehezíti akár az összehasonlítást, akár az egy rendszerbe történő integrációt.

Munkám során céлом volt igazolni, hogy kevesebb rendszerrel, csak a spektrális adatok felhasználásával is ki lehet váltani és el lehet látni a fontosabb fénytani és növénytani vizsgálatokat, melyek később egy automatizált rendszer alapját is jelenthetik.

1.2 Célkitűzések

Fő tudományos célkitűzésem:

- A terepi távérzékelés legtöbbször passzív szenzorokat használ mérései során. Ezért célul tűztem ki egy olyan új, alacsony költségű kiegészítő megoldás fejlesztését, mely a 3D nyomtatás révén számos spektrométerhez gyártható, és használatával a mérések gyorsíthatóak, mivel a szenzor aktív érzékelőként kevesebb kalibrációt igényel a mérés folyamán. Egyúttal összevettem a vizsgálataimhoz alkalmazott *Qmini* spektrométer a gyakorlatban nagyobb arányban használt *ASD Fieldspec* spektrométerrel, mellyel az általam használt szenzor pontosságát igazoltam.
- Másik célom az volt, hogy a fény leírására alkalmazott számos mérőrendszert összehasonlítsam, és bemutassam azon megoldást, mely révén egy eszközzel ki tudjuk váltani a többi érzékelőt. Egyúttal egy olyan modellt alakítottam ki, mely segíti a három legtöbbször alkalmazott paraméter (besugárzás, megvilágítás, fotonfluxus) megadását, átváltását. Ezen célt két irányból közelítettem meg:
 - Először bemutattam, hogy a fénytani mérések során alkalmazott mérőszámok, bizonyos esetekben miért pontatlanok, miért nehéz egymással összevetni őket, és bemutatok egy újfajta megközelítést, mely révén pontosabban mérhető a növényi fényreceptorok által hasznosítható fotonok száma. Ezen megközelítéssel jobban összehasonlíthatókká válnak a különböző, növénytermesztésben használt, mesterséges megvilágítási rendszerek is.
 - Ezen fénytani mérőszámok és megközelítések vizsgálata során egyúttal rávilágítok és bizonyítom, hogy nemcsak a mérőszámok, hanem adott mérési módszertan, mérési eszközrendszer is kiváltható-e, megfeleltethető-e az újfajta megközelítéssel, melynek révén többféle mérési rendszert kiválthat egyidőben a spektrométeres mérés.
- A növényi fejlődés szempontjából az egyik legfontosabb a klorofill-tartalom nyomon követése. Ehhez a gyakorlati oldalról általában SPAD mérőket alkalmaznak. Ezen szenzorral is összehasonlítottam a *Qmini* spektrométert, és mért adatait. Ehhez több spektrális klorofill indexet vettem össze a SPAD mérő mért adataival, illetve a klorofill tartalomra vonatkozó laboreredményekkel. Ezzel igazoltam, hogy egy spektrométerrel is meg lehet becsülni a növények klorofill tartalmát, így szintén ki tudunk vele váltani egy újabb szenzort.
- Mivel napjainkban a beltartalmi paraméterek roncsolásmentes mérése egyre fontosabb, ezért számos beltartalmi paramétert vettem össze a spektrális adatokkal, indexekkel, illetve az analitikai laboratóriumi mérések eredményeivel. A vizsgált indexek között megtalálhatóak voltak a fluoreszcens spektroszkópia által gyakran használt, növényi stresszt bemutató SR indexek is. Ezek esetében azt vizsgáltam, hogy a spektrométeres mérések eredményeként is mutatnak-

e összefüggést, mivel logikailag ebben az esetben is az élettani hatások révén változik a fény adott hullámhosszban történő elnyelésének, reflexiójának aránya.

- Ehhez nagyteljesítményű LED rendszer és HPS rendszer alatt beállított termesztési kísérlet során vizsgáltam a növényi növekedést. Egyúttal a két világítási rendszer előnyeit és hátrányait vizsgáltam.
- Mivel a nap sugárzását jellemző paraméterek mind a növényházi termesztés, mind pedig az egyre jobban terjedő agrofotovoltaikus rendszerek kettős hasznosítását befolyásolja, így célom volt kialakítani egy növényérzékelés központú, fényparaméterek optimalizálásához felhasználható, az adatvezérelt programozást támogató vezérlőtáblát.
- A terepi távérzékelési szinthez tartozó másik, nagymértékben fejlődő irány a drónokkal történő felvételezés. A drónokat jelen munkámban, mint távérzékelési eszközhordozó rendszernek tekintetem, melyek használati tapasztalatai nagymértékben tudják segíteni az automata beavatkozás további fejlesztéseit. Ezen célból összehasonlítottam a drónokon alkalmazott multispektrális kamerák eredményeinek spektrális pontosságát és napszakon belüli eltéréseit a spektroradiométerrel mért eredmények spektrális pontosságával és napszakon belüli eltéréseivel. Összehasonlítottam a drónokon alkalmazott multispektrális kamerák eredményeinek spektrális pontosságát a műholdas távérzékelés spektrális pontosságával. Illetve megvizsgáltam a spektrális képi adatfeldolgozás algoritmusainak pontosságát, illetve futtatási idejét a közel valós idejű adatfeldolgozás szempontjából.

A fentiek révén a terepi távérzékelés módszertani fejlesztésének céljából két fő területet vizsgáltam, összevetve a jelenleg használt megoldásokkal. A spektroradiométer alkalmazásával történő összehasonlító elemzések révén bizonyítottam, hogy egyszerűbben alkalmazható, és akár egy rendszer révén ki tud váltani számos eltérő szenzort, adott idő után a kémiai nagylabort. Illetve rávilágítottam, hogy a távérzékelésen belül napjaink legjobban fejlődő területei mind a terepi távérzékeléshez tartoznak (spektroradiométerek, drónokkal hordozható távérzékelési eszközpark), melyek egyre sokoldalúbban összeköthetők a valós idejű automatizált rendszerekkel, így a precíziós mezőgazdaság jövőbeni gyakorlati alkalmazásai számára kiemelten fontos.

2 IRODALMI ÁTTEKINTÉS

Az informatikai technológiák hatalmas fejlődése révén az olyan lehetőségek, mint a globális helymeghatározás (GNSS), a térinformatika (GIS), a távérzékelés (RS), mindennapi életünk szerves részévé váltak. A „hétköznapi” felhasználásokon túl a tudomány számos területén is alkalmazzuk, ezen belül a mezőgazdasági felhasználások fejlesztése is egyre nagyobb hangsúlyt kap. Az előbbieken említett három terület óriási lehetőségeket jelent egy fenntarthatóbb, a környezet terhelését csökkentő, jóval hatékonyabb precíziós technikák kialakítására, elterjedésére. Segítségükkel a földfelszín élő- és élettelen részeit gyorsan, pontosan, olcsón és nagy területeken tudjuk vizsgálni, ráadásul roncsolásmentes vizsgálati módszerek tudnak általuk kifejlődni (Burai, 2007). Ezen technológiák egyre inkább egységes rendszerbe, egymást kiegészítve, integrált módon jelennek meg és rohamosan fejlődnek a precíziós alkalmazások területén, mind az eszközök, mérőműszerek, mind a módszertanok esetén. A precíziós gazdálkodási formák magába foglalják a termőhelyhez alkalmazkodó termesztést, a táblán belüli változó technológiát, az integrált növényvédelmet, a geostatistikát, a növénytermesztés gépesítésének változását és az információs technológia vívmányainak térhódítása a növénytermesztésben, agrotechnikai gyakorlatban (Györffy, 2000). Azaz a cél, hogy időben és térben az aktuális növényi igényekhez igazítsuk gazdálkodásunkat és beavatkozásainkat.

Az agroökológiai tényezők és az alkalmazott kertészeti termesztéstechnológia következményei a hatótényezők táblán belüli tér- és időbeli mintázatát alakítják ki. Ezek az ökológia hatótényezők – és az általuk befolyásolt vegetatív és generatív jellemzők – helyhez kötött adatok, melyek feldolgozása GIS környezetben végezhető el (Szabó et al., 2007).

A termőhely-specifikus mezőgazdasági gyakorlat célja a profit növelése (hatékonyság növelésével, a minőségi paraméterek javításával), a környezetet terhelő káros hatások csökkentése (Watkins et al., 1998), miközben fenntartja a környezet minőségét (Sági, 1996; Srinivasan, 2008). Ezeket a célokat a termőhely alapos megismerésével – mint minden mezőgazdasági beavatkozás elengedhetetlen feltételeként – lehet hatékonyan elérni, teljesíteni (Tamás, 2001). A szántóföldi és kertészeti növénytermesztési gyakorlatban régóta ismert tény a mezőgazdasági táblákon, illetve kertészeti ültetvényekben a talajtani heterogenitás (fizikai féleség, tápanyag-ellátottság, mikrodomborzat stb.) (Várallyay, 2002), valamint a kártevők, a kórokozók foltszerű megjelenése (Nagy, 2004). Sági (1996) hangsúlyozza, hogy minél változatosabb valamely földterületen belül a talajszerkezet, vagy a növények fejlődése, annál nagyobb a precíziós gazdálkodás hatékonysága.

2.1 Terepi spektroszkópia

A terepi spektroszkópiai vizsgálatok alkalmazási területe meglehetősen széles. A gyors analízisek esetén különös jelentőséggel bírnak, mivel mobilizálhatóak, a mérések rövid időt vesznek igénybe, és roncsolásmentes eljárások, azaz a minta-előkészítés is úgyszólván elmarad, így költségeik lényegesen

alacsonyabbak a laborvizsgálatokéhoz képest, ráadásul a minták vizsgálata nem befolyásolja így az „élő folyamatokat”.

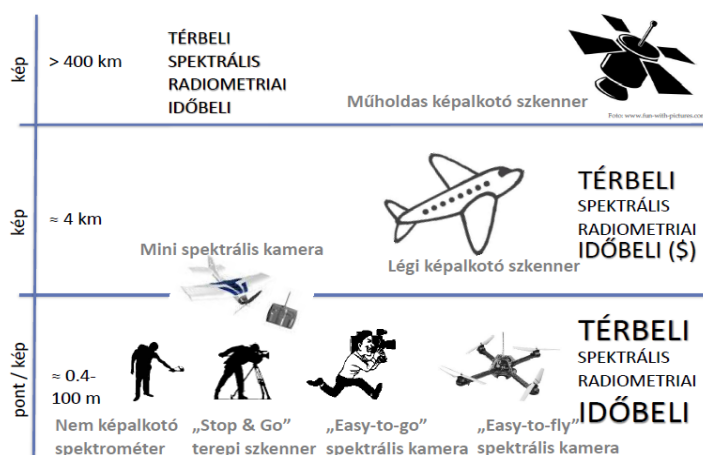
2.1.1 A távérzékelés és csoportosítása

A távérzékelés egy sajátos adatnyerési eljárás, amelynek során a földfelszín vagy földfelszíni objektumok bizonyos sajátosságairól (pl. méret, anyagi összetétel stb.) anélkül jutunk adatokhoz, hogy a vizsgált tárgyval közvetlen fizikai kapcsolatba kerülnénk.

Az adatgyűjtés általában elektromágneses hullámok segítségével történik. Ez az eljárás két alapvető folyamatot foglal magában. Az egyik az objektumról az elektromágneses hullámok által közvetített adatok valamilyen távolságból történő érzékelése, a másik pedig az észlelt és rögzített adatok feldolgozása, értelmezése. Azokat a módszereket jelöljük tehát a távérzékelés fogalmával, melyek oly módon szereznek információt számunkra a megfigyelni, megvizsgálni kívánt objektumokról, hogy nem lépnek közvetlen kapcsolatba azokkal, hanem a különböző szenzorok segítségével az objektumok által kibocsátott vagy visszavert sugárzást detektálják. A távérzékelte adatok tárolása, elemzése és kiértékelése fejlett számítógépes módszerekkel és modellekkel történik. Ennek köszönhetően más adatokkal együtt felhasználható az új adatbázis felépítéséhez vagy a már meglévő adatbázisokba könnyedén integrálhatók.

A távérzékelés által olyan objektumokról és területekről is szerezhetünk információkat, melyeknek a megközelítése nagyon költséges, túlságosan veszélyes vagy nehezen elérhető. Ilyen területek például a katonai konfliktus területei, nagy kiterjedésű erdők vagy szántóföldek, óceánok, aktív vulkánok, extrém klímájú vagy radioaktív területek. A fentiekén túl a távérzékeléssel lehetőségünk nyílik a hagyományos pontszerű földi mintavételi adatok mellett (helyett) nagy területekről egyidejűleg információt nyerni. Ez utóbbit segítik a különböző eszközhordozó rendszerek fejlesztése (robotok, drónok).

A távérzékelést többféleképpen csoportosíthatjuk. Egyik lehetőségként a megfigyelés távolsága alapján megkülönböztetünk terepi (földi), légi-, és űreszközökből álló távérzékelési rendszereket (1. ábra).



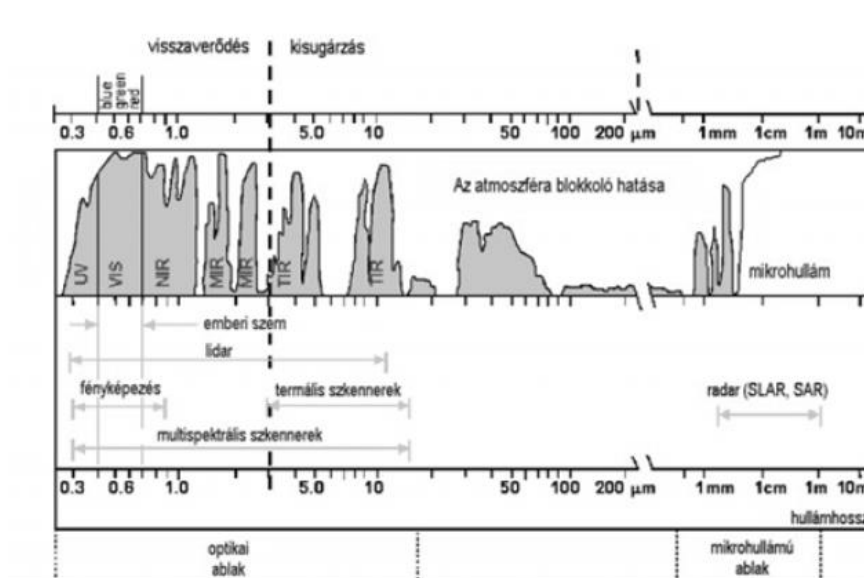
1. ábra - A távérzékelés térbeli felosztása (Forrás: Jung, 2011)

Másik lehetőségként az érzékelési mód alapján történő felosztás. Ezen belül megkülönböztetünk passzív és aktív szenzorokat. Passzív érzékelőről akkor beszélünk, ha az elektromágneses sugárzás forrása természetes, tehát a sugárzás forrása a Nap által sugárzott és a felszínről visszavert elektromágneses energia vagy a vizsgált objektum által kibocsátott sugárzás. Ehhez a típushoz sorolhatjuk a fényképezőgépeket, a multi- és hiperspektrális, illetve a termális szkennereket.

Ezzel szemben az aktív érzékelők nem a természetes forrású elektromágneses sugárzásokat érzékelik, hanem saját sugárforrással rendelkeznek, mind az érzékelő, mind a sugárforrás egy repülőgépen, műholdon vagy valamilyen más közös platformon helyezkedik el, és a saját maga által kibocsátott elektromágneses sugárzásból a megfigyelt objektumok által visszavert sugárzást detektálják. Az aktív érzékelőhöz tartoznak a radarok, illetve a LiDAR rendszerek.

Azaz a távérzékelési rendszerek reflektált, és emittált energiát mérnek, és míg az aktív rendszerek a saját sugárforrásuk révén az időjárástól és napszaktól függetlenül képesek dolgozni, addig a passzív rendszereket folyamatos kalibráció jellemzi.

A szenzorok hullámhossz szerinti érzékenység alapján is feloszthatóak. A három legnagyobb csoport eszerint az ún. optikai szenzorok (hullámhossz szerinti érzékenységük általában 200 nm – 2500 nm), a termális érzékelők (hullámhossz szerinti érzékenységük a termális infravörös tartományba esik, 7000 nm – 8000 nm), illetve az aktív rendszerek (radar – mikrohullámú jel; LiDAR – optikai hullámhossztartományú jel). (2. ábra)



2. ábra - Távérzékelési szenzorok hullámhossz szerinti érzékenysége (Forrás: Balázsik, V. Fotogrammetria I. (2010))

A felvételeket csoportosíthatjuk a csatorna számuk alapján. Eszerint megkülönböztetünk pankromatikus, multispektrális és hiperspektrális szenzorokat. A pankromatikus érzékelők egy csatornát tartalmazó felvételeket készítenek, tehát a fényerősséget érzékelik egy bizonyos hullámsávban és fekete-fehér, azaz szürkeárnyalatos képet készítenek. Használatuknak előnye általában, hogy az elkészült kép térbeli felbontása magasabb értékeket tud elérni a többi érzékelővel szemben, így ez utóbbiak

képminőségének javítását segíthetik. A multispektrális szenzorok felvételezése több mint egy, általában négy vagy több, aránylag széles sávon történik, az infravörös és a láthatófény tartományán, általuk a képadatok egyidejű vagy sorozatos érzékelésére van lehetőség. A hiperspektrális érzékelők esetén több mint húsz, általában több mint száz, keskeny sávban történik a detektálás.

A szenzorok működési elve szerint megkülönböztetünk mérőkamerás szenzorokat (framing), itt a fényképező rendszerek analóg vagy digitális képeket készítenek, illetve a pásztázó szkennereket (scanning). A kamerás műszerekről elmondhatjuk, hogy az általunk vizsgálni kívánt egész területről egyszerre készítenek felvételt. A szkennerek, a kamera rendszerekkel szemben, a felszínről sugárzott vagy visszavert elektromágneses sugárzást, egyszerre a terület csak egy vékony sávjáról érzékelik mindig párhuzamos irányban.

A távérzékelte felvételeket geometriai felbontásuk alapján is osztályozhatjuk, eszerint kis-, közepes- és nagy geometriai felbontású képeket készítő távérzékelő rendszereket különböztethetünk meg. A nagy felbontású felvételek esetén az egyes képpontok (pixelek) a valóságban 1 m-nél kisebb területnek felelnek meg, melyeknek régebben csak katonai felhasználásuk volt, de mára már a polgári használatban is elterjedtek és számos kutatási területet segítenek köztük a növényvédelmi területeket. A közepes felbontásba az 1 és 100 m közötti felvételeket soroljuk, ezeket főképpen a természeti erőforrás kutatásban alkalmazzák. A kis felbontású, 100 m-nél nagyobb, képeket készítenek például a meteorológiai műholdak.

A távérzékelési rendszerek időbelisége azt jelenti, milyen gyakran képes az adott rendszer újra elkészíteni a felvételt. Például egy *Landsat* műhold 14 napos visszatéréssel dolgozik, míg egy drónnal olyan gyakorisággal szállunk fel, amilyennel csak akarunk.

2.1.2 A távérzékelési adatok tulajdonságai

A távérzékelésben a felszínek, objektumok, anyagok által visszavert energia szolgáltatja a legtöbb információt, így ez a jelenség az egyik legfontosabb (2.1).

$$E_b(\lambda) = E_r(\lambda) + E_a(\lambda) + E_t(\lambda) \quad (2.1)$$

ahol:

E_b = a beérkező energiamennyiség,

E_r = a reflektált energia,

E_a = az abszorbeált energia,

E_t = a transzmittált energia,

a λ hullámhossz függvényében

Az $E_r(\lambda)$, $E_a(\lambda)$, $E_t(\lambda)$ mennyiségének értéke mindig az adott mérendő objektum fizikai jellemzőitől és kémiai összetételétől függ. Ezen összefüggést a Lambert-Beer törvény is alkalmazza, mely

a kémiai analízisek egyik legfontosabb összefüggése. És összefüggést teremt a mért transzmittancia, (vagy átalakítható abszorbanciára is), illetve adott anyag koncentráció között.

$$T = \frac{I}{I_0} = e^{-\sigma \cdot l \cdot N} = 10^{-\varepsilon \cdot l \cdot c} \quad (2.2)$$

Az egyenletben szereplő ε a vizsgált közeg moláris abszorpciós együtthatója, míg a c a moláris koncentráció, a σ pedig az abszorpciós keresztmetszet. Az abszorpció és a koncentráció között tehát lineáris kapcsolatot feltételezünk.

A távérzékelési eszközök legtöbbször az $E_r(\lambda)$ értékét mérik. A különböző felszínrészek és objektumok tehát különböző anyagi tulajdonságokkal rendelkeznek, így ha eltérő hullámhossztartományokban mérjük őket, akkor másképp reflektálják vissza az energiát.

Az $E_r(\lambda)$ mennyiség az objektum által bizonyos irányban, bizonyos besugárzási körülmények között visszavert sugárzás mennyiségét jelenti, egy ideális, fehér, szórt fényt visszaverő (Lambert) felület pontosan ugyanilyen körülmények között mért radianciájához képest. Ez által a mért objektum visszaverő képességét százalékban (reflektancia-százalék, vagy spektrális reflektancia) fejezzük ki, mely kifejezi a beérkező (E_b) és visszavert energia (E_r) nagyságának arányát (2.18).

$$\rho(\lambda) = \frac{E_r(\lambda)}{E_b(\lambda)} \cdot 100 \quad (2.3)$$


ahol:

$\rho(\lambda)$ = a vizsgált anyagra jellemző reflektancia érték százalékban kifejezve, vagy spektrális reflektancia a hullámhossz függvényében (továbbiakban: reflektancia).

Azt fontos kiemelni, hogy passzív érzékelők esetén, melyek csak a visszavert sugárzást mérik, a besugárzás pontos értéke ismeretlen. Emiatt nagyon fontos a kalibráció minden mérés előtt, mely során a teljes sötétséget, illetve a természetes fényviszonyokat egy Lambert-féle felszínről visszaverve felvételezzük, figyelve arra, hogy közel ugyanolyan távolságban és szögben végezzük a kalibrációt, mint a mérést (ezt tökéletesen nem lehet kivitelezni az optika látószöge és a referenciapanel mérete miatt).


Ezeket a visszavert elektromágneses sugárzás egy úgynevezett spektrális reflektancia görbén ábrázolhatjuk, amely megmutatja a spektrális információt, mely anyagi tulajdonságokat tartalmaz (minőségi és mennyiségi információ). Az adatok feldolgozása során pedig azt is megmutatja, hogy mely hullámhossztartományban vizsgálható részletesen egy bizonyos tulajdonság. Ezen jellegzetes lefutású reflektancia görbék információt adnak az anyagi minőségről. A különböző felszín borításnak sajátos optikai tulajdonságai vannak és reflektancia görbéi nagymértékben különböznek. Ezt a gyakorlatban spektrális ujjlenyomatnak is nevezzük. A reflektancia görbék eltéréséből például információt kaphatunk a felszínborításon túl, az anyagi minőségről (fizikai, kémiai jellemzőiről), növényzet esetén fajról, fiziológiai állapotról, esetleg különböző struktúrákról stb. (3. ábra). Jelenleg folyamatosan bővülnek az

úgynevezett spektrális könyvtárak, melyek fejlődése és minél pontosabb elemzése folyamatosan bővíti ismeretünket, és ezzel a reflektancia görbék minél szélesebb felhasználhatóságát.



3. ábra - Különböző felszínek reflektancia görbéi (Forrás: Jung, 2011.)

A multi- és hiperspektrális felvételek háromdimenziós adatkockát „vesznek fel”. Ugyanabban az időpillanatban több detektor egyszerre készít képet az objektumról. A detektorok általában különböző hullámhossz tartományon készítik a felvételt, ez adja az adott adatkocka csatornáinak számát. A feldolgozás során minden képponthoz egy folytonos spektrumgörbe tartozik. (4. ábra)




4. ábra - A hiperspektrális adatfeldolgozás sémája (Forrás: Jung, 2011)

Az elektromágneses spektrum hullámhossz szerinti felosztása több esetben változhat az eltérő szakterületeken. A továbbiakban a vegetációs kutatásokban legelterjedtebb, Kumar et al. (2001) által pontosított felosztást használom (1. táblázat).

1. táblázat- A rövidhullámú reflektancia spektrum fősztása Kumar, et al. (2001) nyomán

Elnevezés	Hullámhossz (nm)
Reflektancia a látható tartományban	400-700
A vörös-él reflektancia tartománya	690-720 (ez a tartomány változó, tágabban 700-800 nm pl. műholdas rendszerek és drón szenzorok esetén)
Közeli infravörös tartomány (NIR)	700-1300
Közép távoli infravörös tartomány	1300-2500

Adott hullámhossztartományok adott irányú vizsgálatokat segítenek. Például az ibolyán túli tartomány az ózon-koncentráció, a láthatóban időjárási, földhasználati, geomorfológiai vizsgálatok végezhető. A növényzet vizsgálatára leggyakrabban a 400-1100 nm-es tartományt használják (ugyanakkor a 1100-2400 nm tartomány is számos plusz információt rejt (5. ábra). Az egészséges növényzet reflektancia görbéjének egyik jellegzetessége, hogy ~700-1200 nm között a reflektancia nagymértékben (akár 40-50%-ra) is megnő. Ezen tartomány kezdeti szakaszát (~700-800 nm) hívják „vörös élnek”, vagy RedEdge-nek. Ennek meredeksége, illetve maximális pontjának változása szintén akár fajok elhatárolására, vagy az egészségi állapot felmérésére és egyéb növényi stressz kimutatására alkalmas.



5. ábra - Növényi reflektancia görbe (Forrás: Jung, 2012.)

Az ásványok, kőzetek, talaj vizsgálatára az 1100-2400 nm-es tartomány jellegzetes elnyelési sávjait, a hőmérséklet vizsgálatára a termális szakasz alkalmas. A mikrohullámú tartományban történik a jég- és hótakaró nyomon követése, illetve a felszíni magasságmérés, de napjainkra a mezőgazdaság területén is egyre gyakrabban használható gyomkeresésre, belvíz meghatározására, vagy számos erdészeti lehetőség (fahozam mérés, sérülékenység előrejelzésére) is a kutatók fókuszába került.

A korábbiakban említett passzív szenzorok esetén az okozza a legnagyobb nehézséget, hogy a vizsgált tárgy reflektált energiáját mérve a besugárzás pontos mértéke ismeretlen. Ennek következtében az $E_r(\lambda)$ értékét nem lehet közvetlenül meghatározni, hanem folyamatos kalibrációként ismert $E_r(\lambda)$ értékkel rendelkező referencia-tárgyat kell alkalmazni (Podmaniczky, 2004). A növényi levél lényeges tulajdonsága, hogy reflektancia vonatkozásában az optikailag tökéletes visszaverődési és a Lambert-féle ideális diffúz visszaverődési mód között helyezkedik el. Diffúz visszaverődéskor a vizsgálandó objektum felszínének „színe” hordozza a spektrális információt, míg a tökéletes visszaverődéskor nem.

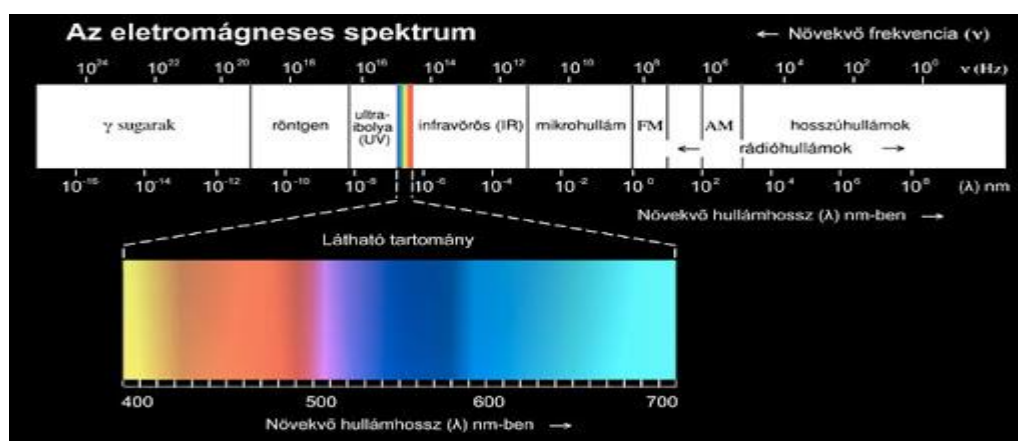
2.2 A fény növényekre gyakorolt hatásai

Mind a növények fejlődéséhez, mind a spektroszkópiai mérésekhez elengedhetetlen az elektromágneses sugárzás, így megismerése alapvető ezen vizsgálatok elvégzése előtt.

2.2.1 Elektromágneses sugárzás és spektrum

Az elektromágneses sugárzás két forrásból származhat. Lehet természetes, azaz a Napból vagy égboltról (szoláris sugárzás) és a Föld felszínéről, az anyagok által emittált energia, illetve lehet mesterséges. Tóth et al. (2001.) szerint „az elektromágneses sugárzás az energia azon megjelenési formája, amelyben periodikusan változó elektromos és mágneses erőter terjed. A fény fizikai megközelítésben kettős természetű: a terjedés közben transzverzális elektromágneses hullámként, atomokkal, molekulákkal kölcsönhatásba lépve pedig diszkrét részecskeként (kvantum) viselkedik.” A fény legkisebb kvantumait fotonnak hívjuk.

A fentiek alapján az elektromágneses sugárzást hullám, illetve részecske, energia oldaláról is le tudjuk írni. A hullám természetéből adódóan fel lehet osztani a hullámhosszok alapján. A rövidhullám felől ezek a gamma, röntgen, ultraibolya, látható fény, közeli infravörös, közép és távoli infravörös, mikro- és rádióhullámok (6. ábra).



6. ábra - Elektromágneses spektrum. (Forrás: Eifert János, 2011)

Az optikai (100-3000 nm között), különösen a látható, tartományai az életfolyamatok során, és az optikai mérőrendszerek szempontjából fontosak, mások (termális tartományok, rádióhullám, röntgen) pedig egyéb vizsgálati szempontból hasznosak. Fontos azonban, hogy a sugárzás folytonos és forrásától függően időben és intenzitásában változó, hullámhossz szempontjából többnyire összetett, így csak leírását segíti a fenti tartományokra bontás. A különböző források eltérő hullámhosszokban bocsátanak ki energiát. A sugárzás jellege alapján megkülönböztetünk monokromatikus, azaz egy hullámhosszal jellemezhető, vagy összetett sugárzást, amely több hullámhosszon egyszerre történik, mint például az optikai távérzékelés során a napfényt használjuk. A távérzékelési és műszaki gyakorlat gyakran használhat monokromatikus jellegű sugárforrásokat.

A sugárzást frekvenciájával is jellemezhetjük, hiszen ez független a közegtől, a hullámhosszával, sebességével ellentétben. A sugárzás frekvenciája fordított arányban áll a hullámhosszal (Engler, 2014; Mulders, 1987; Tóth et al., 2001).

Amennyiben részecske oldaláról jellemezzük, úgy többnyire diszkrét energiacsomagok (fotonok) sorozataként, áramaként írhatjuk le. Ezen energia kölcsönhatásba lép az anyaggal (atom, molekula), melyet kétféleképpen jellemezhetünk. Egyrészt energiacserével nem járó kölcsönhatásként, mely révén a sugárzás hullámtulajdonságai (irány, hullámhossz, sebesség) megváltozhatnak. Ilyenek például a reflexió (visszaverődés), refrakció (fénytörés), optikai forgatás, fényszóródás. Másrészt az energiacserével járó kölcsönhatások, melyek során az energia eloszlás változik meg, például abszorpció révén az anyag elnyeli ezen energiát, míg emisszió során kibocsátja. Mivel az atomok, illetve molekulák csak bizonyos, rájuk jellemző hullámhossz-tartományokban mutatnak elnyelést (abszorpciót), illetve kibocsátást (emissziót), így az elnyelt, illetve kibocsátott sugárzás jellemzői egyértelmű összefüggésbe hozható az anyag szerkezetével, összetételével.

Dr. Koczka Béla a spektroszkópiai módszereket az alábbiakkal foglalta össze: „Az analitikai spektroszkópia módszerei a vizsgált mintából származó, kisugárzott, vagy a mintával kölcsönhatásba lépő elektromágneses sugárzást használják fel a minta anyagi minőségének, mennyiségi összetételének, illetve szerkezetének vizsgálatára. A létrejövő jelenségek egy részében a kibocsátott (emittált), illetve elnyelt (abszorbeált) fény, a foton energiája, a kölcsönhatásban résztvevő atomok, illetve molekulák elektron energiaállapotának, rezgési-, illetve forgási energiaállapotának adott megváltoztatásával hozhatók összefüggésbe.” Az atomok és molekulák felépítéséről, jellemzőiről az általuk emittált vagy abszorbeált energia ad számunkra tájékoztatást, ezt nevezzük minőségi meghatározásnak. A koncentrációról, azaz a mennyiségi paraméterekről, pedig az elektromágneses sugárzás intenzitása, és ennek változása ad számunkra fontos adatokat. A távérzékelés szintén ezen fizikai elveket hasznosítja.

A spektroszkópiai technikák csoportosítására több lehetőséget is említ Tóth et al. (2001). Az egyik az elektromágneses sugárzás hullámhossza alapján történik, a másik pedig aszerint, hogy atomból vagy molekulából ered-e az adatunk (Tóth et al., 2001).

A sugárzás energiáját meghatározó hullámhossz, frekvencia és hullámszám függvényében való megjelenítéskor kapjuk az elektromágneses spektrumot (Lillesand, 2007). Ez egy analitikai jel, mely a spektroszkópiai adatok ábrázolását, egyúttal kvalitatív elemzést tesz lehetővé (Mulders, 1987). Azaz adott anyagra jellemző a lehetséges hullámhosszak skálája (Haynes, 1982).

A sugárzási törvények által ismert, hogy minden test, melynek hőmérséklete abszolút nulla felett van, emittál sugárzási energiát (Mulders, 1987). A szemünk a reflektív, visszaverődő, elektromágneses sugárzás látható tartományát érzékeli, így a szem által elnyelt sugárzás tulajdonságai a felszínről adnak számunkra információkat. Azaz szemünk is egy távérzékelő szenzorként működik. Az ezen jelek által közvetített ingereket pedig agyunk látóközpontja dolgozza fel. Szemünk színérzékenysége az ibolyától a vörösig terjed, illetve fényérzékeléssel egészül ki (szürkületi látás). A távérzékelésben, illetve a terepi spektroszkópiában a látható tartomány kiegészül a rövidebb (pl. UV), a hosszabb (IR), illetve termális (TIR) hullámhosszakkal is (Haynes, 1982).

A nagyon rövid hullámhosszú sugárzás energiája nagy, így be tud hatolni a tárgyakba, ami az orvostudományban, diagnosztikában hasznos, azonban a felszínek elemzésénél nem olyan lényegesek, hiszen kevés emittálódik vagy verődik vissza ezen tartomány esetén (Haynes, 1982).

Az 1900-as években merült fel az, hogy a színek mérésével állapítsanak meg különböző tulajdonságokat. A színösszetétel, vagyis a spektrális eloszlás azt mutatja, hogy a sugárzás mekkora része esik az ibolya (400-420 nm), a kék (420-500 nm), a zöld (500-570 nm), a sárga (570-590 nm), a narancssárga (590-600 nm) és a vörös (600-700 nm) tartományba. Ez már akkor megfelelő módszernek bizonyult.

2.2.2 A fény növényekre gyakorolt hatásai

A fényrészecskék (fotonok) útja az adott közeget elérve három módon alakulhat: visszaverődhetnek (reflexió), elnyelődhetnek (abszorpció), vagy áteresztődhetnek (transzmisszió), amely minden esetben függ a közeg anyagi minőségétől (Eltbaakh et al, 2011).

Első esetben a növény felszínére beeső elektromágneses sugárzás közvetlenül visszaverődik a kutikuláról. Ezt a fényvisszaverődési képességet nevezzük albedónak, amely az adott felület által visszavert sugárzás és a felületre érkező sugárzás arányát jelenti. Ennek az értéke nagyban függ a felszín anyagától, típusától (érdesség), valamint az árnyalattól, mivel a sötétebb árnyalatú felszínek jobban elnyelik a napsugárzást, mint a világosabbak. Második esetben a növényi felületre érkező elektromágneses sugárzás bejut a növényi szövetekbe és ott elnyelődik (abszorpció). Az abszorpció elsősorban az erre „kifejlődött” fényérzékeny sejtek révén történik (például szemünkben a retina fényérzékeny sejtjei: csapok és pálcikák, míg a növények fényérzékelő sejtjei a klorofill, xantofill, karotinoidok stb.). A folyamat célja, hogy az anyag ezen energiával gyarapodva eltárolja, hasznosítsa azt (például a fotoszintézis során az elnyelt sugárzási energiából cukrokat állít elő a növény, így tárolva a későbbi felhasználáshoz a többlet energiát). Harmadik esetben a növényi felszín átengedi az elektromágneses sugárzást (transzmisszió). A levél a napsugárzás hatására jellemzően félig áteresztő anyagként viselkedik (Anda, 2010), azaz bizonyos hullámhosszakat elnyel, míg másokat átereszt, avagy reflektál.

A növényfejlődés szempontjából fontos a megvilágítás spektruma, időtartama, iránya és intenzitása, mivel a növények ezek figyelembevételével optimalizálni tudják a fényenergia hasznosítását a fotoszintézis során (Nishio, 2000). Az elektromágneses spektrum alapján a növényekre vonatkoztatva a biológiailag aktív sugárzási tartomány jelenlegi tudásunk szerint a 300-800 nm-ig terjed, amely közötti hullámhosszon adnak a növények fiziológiás választ. Ezen belül a 400-700 nm hullámhosszú tartományt nevezik a fotoszintézis szempontjából aktív sugárzásnak (PAR). A PAR tartományba esik a foton sugárzás hozzávetőlegesen 26%-a, és a Napból származó energia 42%-a. A számítás az American Society for Testing and Materials (ASTM) G173-03 referencia spektrumon alapszik (Davis, 2015). Mivel a Nap spektruma megközelítően 100 nm-től 4000 nm-ig terjed (lux modell, 2004), kiegészülve egy távolabbi

(hő)sugárzási tartománnyal (7000-8000 nm), így a 42%-os arány magasnak tekinthető, és mutatja a természet adaptációját is. Például a növények számára hasznos fény nagy része ide tartozik, de az optimális növekedéshez UV fényre (280-400 nm) és infravörös fényre (700-800 nm) is szükség lehet. Az ultraibolya sugárzás elektromágneses spektruma tovább osztható az ISO szabvány (ISO-21348) alapján UV-A-ra (315–400 nm), UV-B-re (280–315 nm) és UV-C-re (100–280nm)).

A növények számára rendelkezésre álló fény számos tényező komplex függvénye. A Nap és Föld geometriai viszonyai, valamint a tengerszint feletti magasság meghatározzák az adott pontra érkező napsugárzás mennyiségét (W/m^2), időtartamát (napsütéses órák száma), beesési szögét ($^\circ$), spektrális összetételének arányát. Az Egyenlítőhöz közel a nappalok hossza és a rendelkezésre álló fénymennyiség viszonylag állandó, így leginkább az időjárási viszonyok határozzák meg a felhasználható fény mennyiségét. Az Egyenlítőtől északra vagy délre haladva az egyre inkább változó nappalok hossza határozza meg a rendelkezésre álló fényintenzitást és a fotoperiódust. Évszakok és napszakok szerint is változik a spektrális energia-eloszlás a napmagasság függvényében, amelynek változásai befolyásolhatják a növény fejlődését (Yang et al., 2012). A terület tengerszint feletti magassága is meghatározó, mivel az alacsony fekvésű területen a fénynek a légkör nagyobb tömegén kell áthaladnia, mielőtt elérné a földfelszínt. Ennek hatására megváltozik a fény spektruma, mivel az atmoszféra az alacsony hullámhosszú fény arányosan nagyobb részét szűri ki, több UV-t mint kéket, és több kéket, mint zöldet, vagy vöröset (Eltbaakh et al., 2011). A terület kitettsége miatt a Föld északi féltekéjén a déli lejtők a napjárásból adódóan hosszabb ideig kapnak direkt napsugárzást, mint az északi oldalak, a déli féltekén pedig mindez fordítva történik.


A fotoszintézisen túl a fény környezeti információt biztosít a növénynek ahhoz, hogy a csírázás megkezdődhessen, a növekedése során kialakulhassanak a fajra, fajtára jellemző morfológiai tulajdonságok, a környezeti stresszre reagálni tudjon és a vegetatív fejlődés irányából mikor fordítsa energiáit a generatív fejlődésre.

Összességében elmondható, hogy a fény több mint 100 növényi gént és 26 biokémiai folyamatot szabályoz, melyek közül még sok funkció ismeretlen. A fotokémiai reakció, így a fotoszintézis is csak akkor játszódhat le, ha a fény elnyelődik (abszorbeálódik) az adott rendszerben. A fotoszintézis intenzitását a növény fotoszintetikus pigmentjeinek abszorpciós érzékenysége határozza meg. A legfontosabb növényi pigmentek a klorofillok és a karotionidok. A növényi fotoszintetikus pigmentek abszorpciós maximuma a látható tartomány két szélén (400-425 nm, és 660-680 nm) felé jelentkeznek, míg a tartomány középső részét (500-600 nm) minimális elnyelés jellemzi. A fő elnyelési λ maximumok helyén a növények a rájuk eső sugárzás 80-95%-át nyelik el (Anda, 2010), ezzel a teljes napsugárzásnak csupán 4,6-6,0%-a kerül hasznosításra a fotoszintézis során (Long et al, 2006).

A klorofill-a két abszorpciós maximummal rendelkezik (7. ábra), a vörös tartományban (660 nm), valamint a kék régióban (400-450 nm). A klorofill-b a klorofill a-hoz képest eltolt hullámhosszokon, de

szintén két abszorpciós csúccsal rendelkezik. A klorofill-b csúcsai (640 nm, 425-475 nm) körül helyezkednek el. Itt jegyezném meg, hogy mindkét klorofill pigmentnek az UV tartományban is van elnyelése, különösen a klorofill a-nak.

A karotinoidokhoz tartoznak a karotinok és xantofilok. A karotinok szénhidrogének, legfontosabb tagjai a α -karotin, β -karotin, likopin. A xantofilok valójában a karotinok oxigént is tartalmazó származékai, legfontosabb képviselői a lutein, violaxantin, neoxantin, zeaxantin. Szerepük, hogy az elnyelt fényenergiát továbbítsák a klorofilok felé és védjék a fotoszintetikus apparátust a fotooxidatív hatásoktól. A „karotinoidok” elnyelési maximumai 470 és 500 nm hullámhossz körüli értékeknél jelentkeznek. A szakirodalomban eltérések adódnak a növényi pigmentek abszorpciós maximumát illetően, amely a kivonáshoz használt különböző szerves oldószerek felhasználásából adódik (Láng, 1998).



7. ábra - Néhány fotoszintetikus pigment abszorpciós spektruma (balra) és fontosabb funkciójuk (jobbra), (Forrás: Taiz, L. & Zeiger, E., 2010)

A fentiek mellett egyre több kutatás foglalkozik a fitokróm sejtekkel, a fitokróm-R-rel, illetve a fitokróm-FR-rel. Nevük is mutatja, hogy előbbi elnyelési csúcsa a piros tartományban, míg utóbbi a Far-Red (700-750 nm) tartományban található. Elsősorban fényérzékelésben és a morfogenezisben játszanak szerepet. (Ördög et al., 2011.) További jellemzőiket a később részletezem.

Összegezve az előbbieket a növények fejlődéséhez szükséges maximális elnyelési hullámhosszok:

- klorofill-a 430 nm és 662nm,
- klorofill-b 453 nm és 642nm,
- klorofill szintézis 435 nm, 445 nm, 640 nm, és 675 nm,
- 730 nm elősegíti a virágzást.

A növények a zöld spektrumú fényt visszaverik, illetve átértesztik, tehát ez szóródik a növény lombzatának belseje felé, míg a vörös és a kék spektrumú fényt abszorbeálják (Zhu et al., 2008). A lombszerkezet így befolyásolja a természetes napfény eloszlását, a lombzat tetején levő levelek a maximális fotoszintetikus kapacitáshoz képest túl sok, a „lejjebb, illetve beljebb” elhelyezkedő levelek viszont túl kevés direkt fényt kapnak. Ennek köszönhetően a fotoszintézisnél hasznosítható vörös és kék spektrumú fényből csak sokkal kevesebb jut be a lombszerkezet belseje felé, ennek megfelelően a fotoszintézis intenzitása is csökken (Terashima et al., 2009; Paradiso et al., 2011). A társulások is hasonló elven befolyásolják a fény spektrális összetételét. Míg a felső szinteken a kék és vörös fény, addig az alsóbb szinteken a zöld és a távoli vörös (FR), illetve infravörös tartomány dominál. Illetve például az erdei lombzat felszínén a vörös és távoli vörös fény aránya 1,2, míg a lombzaton belül már csak 0,4 (Turnbull & Yates, 1993).

A fotomorfogenetikai reakció segíti a növényt a fény felé fordulásban (pozitív fototropizmus) és maximalizálja a fény hasznosításának lehetőségét a fotoszintézis során. Ezenkívül a növények képesek érzékelni a fény intenzitását és minőségét/színét, így úgy alakítani a fejlődésüket, hogy az illeszkedjen a környezeti viszonyokhoz. A fény intenzitásán túl a fény színösszetétele is befolyásolja a fotoszintézis mértékét. A magasabb rendű növények többféle fotoreceptort használnak a fényviszonyok pontos érzékelésére az UV-B-től a távoli vörös (FR) hullámhosszig (Möglich et al., 2010; Rizzini et al., 2011). A fotoreceptorok különböző jelátviteli útvonalakat, kaszkádokat aktiválnak a fényfüggő válaszok és a kapcsolódó génkifejeződés szabályozása érdekében a növényekben (Zoratti et al., 2014). A növényi biológiában a fotoreceptor kifejezést azokra a molekulákra használják, melyek megkötik a fényt, és amelyeket a fény aktivál a növény fejlődésének módosítása érdekében. Szenzoros fotoreceptor néven emlegetik azokat a fotoreceptorokat, melyeket a növények a környezetükben levő fény megfigyelésére és az arra való reagálásra használnak (Weller, 2017). Mára 5 ilyen fényérzékelő rendszert azonosítottak a magasabb rendű növényekben (részletesen az 2. táblázatban). Például az UV rezisztens lókus 8 (UVR8) az UV-B hullámhosszú (280–315 nm) fényre reagál a fejlődési és egyben az UV-védelmi folyamatok szabályozása érdekében (Jenkins, 2014). Az UV-B fény hatására a növények számos pigmentet és egyéb másodlagos metabolitot hoznak létre, különösen flavonoidokat és antocianinokat, aminek hatására a levelek és a virágok színe erősebb lesz (Paul, 2006). Továbbá, az UV-B fény hatására a növények morfológiailag „kompaktak” maradnak, keményebb, robosztusabb leveleket hoznak és megemelkedik a fűszer-, és gyógynövényekben az esszenciális olajok koncentrációja (Hikosaka et al., 2010). Ezen tartomány fontossága miatt például az üvegházi termesztéstechnológiában gyakran találunk mesterséges UV-B fényrel történő kiegészítést, kezelést, melynek egyik fontos limitáló tényezője az, hogy egészségi kockázatot jelenthet az ott dolgozó emberek számára (Davis, 2015).

A növények reakciója a kék spektrumra (400–500 nm) nagyon sokoldalú, három féle fotoreceptor osztály szabályozza: a kriptokrómok (Chaves et al., 2011), a fototropinok (Christie, 2007) és a Zeitupe

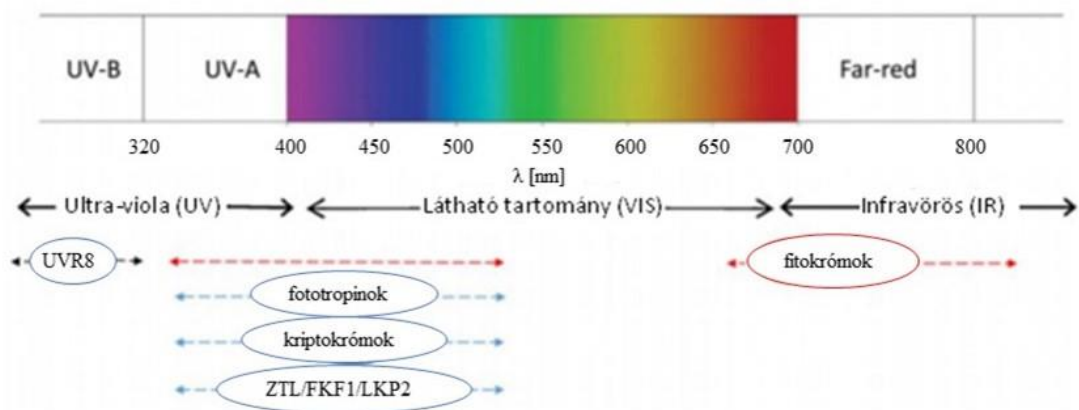
fotoreceptor család tagjai (ztl, fkl1 és lkp2) (Suetsugu & Wada, 2013). A fototropinok a növényi reakciók széles körét szabályozzák, többek között a sztómák nyitását, a fototropizmust (fény felé hajlást), a kloroplasztiszok mozgását, a levelek lelapulását és a hipokotil megnyúlásának gátlását. A kriptokrómok a pigment szintézisben vesznek részt, irányítják a növény napi biológia óráját, a virágzást és a hipokotil megnyúlásának a gátlását (Davis, 2015). A Zeitrüpe (ztl) fotoreceptor család tagjai fontos szerepet játszanak a növény napi biológiai órájának irányításában és a virágzás fotoperiodikus ellenőrzésében (Christie et al, 2014). A fitokrómok főként a vörös (600–700 nm) és a távoli vörös (700–750 nm) fényre reagálnak (Chen & Chory, 2011). Képesek érzékelni a zöld fényt is, és arra is van némi bizonyíték, hogy a fitokrómokat deaktiválhatja a zöld fény (Sellaro et al., 2010). A fitokrómok arról ismertek, hogy számos fotobiológiai válaszáért felelősek: mag csírázása, hipokotil megnyúlás gátlása, csírázás során a csúcsi kampó megerősödése, levél növekedés, virágzás ideje, a növény napi biológiai órájának irányítása, és a klorofill bioszintézis. A növények nem csak egyféle fitokrómot tartalmaznak (például a rizs hármát, a kukorica hatot). Annak ellenére, hogy általában úgy tartják, hogy a fény távoli vörös tartományát képesek érzékelni, a fitokrómok a hullámhossz teljes spektrumából, többek között a kékből is képesek fényt megkötni (Davis, 2015).

2. táblázat - A legfontosabb növényi fotoreceptor csoportok tulajdonságai a magasabb rendű növényeknél (Forrás: Weller, 2017)

Típus	Legfontosabb (kevésbé fontos) abszorpciós terület	Válaszok
Kriptokrómok	Kék (UV-A, zöld)	Fotomorfogenezis Fotoperiodizmus
Fototropin	Kék (UV-A)	Fototropizmus Sztóma nyílás Kloroplasztisz mozgás
Fitokrómok	Vörös, távoli vörös (kék, UV-A)	Mag csírázása Fotomorfogenezis Fotoperiodizmus
UVR8 fehérje	UV-B	Flavonoid bioszintézis Fotomorfogenezis
ZTL/FKF1 fehérjék	Kék (UV-A)	Növény napi biológiai órája Fotoperiodizmus

A fény hatására megfigyelhető morfológiai és fejlődési változások közül sokat a növényi hormonok közvetítenek (Lau & Deng, 2010). Az auxin például a sejtsztódás, a sejtnövekedés és a növényi morfológia fontos szabályozó anyaga, és maga is nagymértékben a fénytől függ (Halliday et al., 2009). A fény és a hormonhatások közötti komplex molekuláris kapcsolatrendszer napjaink egyik kutatási fókuszja, mely révén egyre jobban feltérképezhetőek ezen biokémiai összefüggések, ami idővel elősegíti a „minőségi” növények előállításához szükséges fénykezelések optimalizálását (Davis, 2015).

A fentiek bemutatását amiatt tartottam fontosnak, hogy rámutassak arra, hogy néhány növényi fotoreceptor abszorpciója a PAR-on kívüli tartományokat is érinti, melyet az 8. ábrán is láthatunk.



8. ábra - PAR-on kívüli fotoreceptor "aktivitás" (Forrás: Weller, 2017)

2.2.3 A fény szabályozásának új irányai

A mesterséges megvilágítás fejlődése során megjelentek az úgynevezett LED (Light Emitting Diode) fényforrások. Egy LED igen változatos hullámhossz-tartományban képes sugározni az UV-C-től az infravörösig (Bourg, 2008), valamint ez az első olyan fényforrás, melynek spektrális tulajdonságai szabályozhatóak¹, lehetővé téve, hogy a megvilágítás hullámhossza optimális legyen a növény fotoreceptorai számára, ezzel segítve a termeszést és a metabolikus növényi reakciók célzott manipulálását (Morrow, 2008). Az általánosan elterjedt kiegészítő megvilágításra használt fényforrásokhoz képest, alacsony energia szükséglettel rendelkeznek emiatt alkalmazásuk gazdaságosabb termeszést tesz lehetővé, míg élettartamuk hosszabb, mint az eddig használt rendszereké.

A termeszőberendezésekben ezáltal megjelentek a vertikális termeszési módszerek, melyek során kis légterű berendezésekben, vagy polcrendszer használatával valósítják meg a termeszést. Ahhoz, hogy kihasználják a termőterületet, amennyire csak lehet minimalizálják a távolságot a polcok között. Mivel a LED hő leadása alacsony, az izzók a növényekhez közel helyezkedhetnek el anélkül, hogy károsodást okoznának a fejlődésükben, így csíranövények és kisméretű dísz-, fűszer-, zöldségnövények termeszése is könnyen megvalósítható vertikális termeszési rendszerekben. Hatékonyságának, valamint a kisugárzott hő drasztikus csökkenésének köszönhető, hogy a kísérleti stádiumon túllépve, már a kereskedelmi termeszésben is alkalmazzák.

A termelők a lineáris fluoreszcens megvilágítás 7-8 polcát 12-14-re emelhetnék a LED-ekkel egy 7,5 méter magas plafon esetében. A LED „hűvös” fényforrás és nemcsak közel tehető a növényhez, de a lombozaton belülre is helyezhető (LED-sztring), és így olyan leveleket világíthat meg, melyek egyébként kevés természetes, vagy kiegészítő megvilágítást kapnak. Ez utóbbi a LED kis méretének köszönhető, mely révén rugalmas szálra szerelve a növényi levelek, vagy a termések, virágok mentén, bármilyen geometria szerint vezethető. Ez azt jelenti, hogy a köztes megvilágítás legalább annyira, vagy jobban növelheti a termésátlagot, mint ugyanakkora fény a lombozat felett. Ez a technika jobb ízű

¹ Szabályozhatóság alatt elsősorban arra van lehetőség, hogy egy változatos hullámhosszokban emittáló diódákból szerelt lámpatesten belül az egyes diódák egyedileg „igen-nem” logikával kapcsolhatóak, a fényintenzitás pedig változtatható.

gyümölcsöt produkál és megnöveli a növény termőképességét (Davis, 2015). A Wageningen Egyetem kutatói a C-vitamin szint megduplázódását észlelték az egyik paradicsom fajtánál, amikor a fűtőkre irányították a LED-ek fényét. A növények megvilágítására mozgó fényforrás rendszer is használható. Ez azt jelenti, hogy kevesebb égőre lehet szükség egységnyi terület megvilágítása során, ami jelentősen csökkentheti a befektetés költségeit. Li et al, (2014) mutatta be, hogy a saláta (*Lactuca sativa L.*) termelhető mobil megvilágítás alatt is, és ekkor, csak fele annyi lámpát használtak, mint a fixen beépített LED kezelésben. Az öntözőkocsira szerelt mobil megvilágítás gazdaságilag kivitelezhető megoldást jelent abban az esetben is, amikor csak kis dózisu megvilágításra van szükség, például a nap végi fénykezelés, vagy az UV-C/UV-B kezelés esetében (például a Biolumic cég által alkalmazott szántóföldi UV kezelésekkor, mely növeli a növényi immunválaszt). A napvégi, a nap világos időszakát meghosszabbító, és az éjszakai LED megvilágítás hatékonyan használható a növények virágzásának szabályozására, de az erre használt fény spektrális összetétele további kutatásokat igényel (Kubota et al., 2012). A beltartalmi paraméterekre ható „fényrecepteket” szintén számos jelenleg folyó kutatás keresi számos országban.

Számos kutatás indult a betakarítás utáni LED-es kezelések hatásainak vizsgálata céljából is (Braidot et al, 2014). Egyes élelmiszerek, mint például a levélzöltségek jobban megtartják a minőségüket a tárolás során, ha kis mennyiségű fényt is kapnak, szemben ha csak sötétben tároljuk őket. Costa et al, (2013) kísérleteiben a kétórás, alacsony intenzitású vörös fény késleltette a bazsalikom levelek előregedését két napos, 20 °C-on és sötétben történő tárolás esetén. Továbbá, a LED-ekkel hőtermelés nélkül biztonságosan tárolható az élelmiszer úgy, hogy nem használnak vegyszeres fertőtlenítőszereket, vagy adalékokat, és nem fokozzák a baktériumok rezisztenciáját (D’Sousa et al, 2015). E célból két fontos szempontot kell figyelembe venni. Első, a fényminőség közvetlen hatása a rovarok és a patogének viselkedésére. Csak néhány rovar fajnál ismert a fény összetételével összefüggő érzékenység, pedig az egyes fajok esetén ez nagyon különböző lehet (Davis, 2015). Például a méhek képesek látni az UV fényt (csúcs ~350 nm), a kékét (csúcs ~450 nm) és a zöldet (csúcs ~550 nm), viszont alacsony az érzékenységük a vörös fényre (Backhaus, 1993; Davis, 2015). A LED-ek üzemi hőmérséklete jelentősen hűvösebb, mint a HPS szerelvényeké, és így nem károsítják a méheket, amikor azok közel kerülnek hozzájuk. Így akár csalogatni tudjuk ezen rovarokat a célterületünk felé pusztán adott fényösszetétel biztosítása mellett. Egy másik kutatási irány ezen témában az adott rovarok ellen alkalmazható spektrumok kutatása. Ennek alapja, hogy ha adott spektrumon van csak érzékenység, akkor ezzel ellentétes fényt alkalmazhatunk, mely révén szinte „láthatatlanná” tehetjük növényeinket.

Másodszor a fény a növénybiológia számos tényezőjére van hatással, és ezek közül sok a növények betegségekkel szembeni rezisztenciájában is szerepet játszik. A távoli vörös arány a fitokrómokon keresztül számos génre hat, melyek szerepet játszanak a betegség rezisztenciában (Greibel & Zeier 2008 Davis, 2015). Sajnos a legtöbb kutatás csupán in vitro vizsgálatokra szorítkozik egyelőre,

de idővel biztosan átlépnek az in-vivo kísérleti stádiumba is. Másik limitáló tényező a LED fény alacsony behatolási mélysége, mely csak a zöldségek, gyümölcsök és egyes húsfélék felületére, vagy csak tiszta folyadékokra koncentrálja a fertőtlenítő hatást (D'Souza, 2015).

Salátánál (*Lactuca sativa L.*) mutatták ki, hogy a monokromatikus kék LED megvilágítás hatására emelkedett az antocianin, a xantofil és a β -karotin tartalom (Li & Kubota, 2009). A mai gondolkodás az olyan megvilágításra koncentrál, amely széles spektrumot fed le éppen úgy, mint a napsugárzás. Az iparág, úgy tűnik, hogy inkább az összetett, fehér fény felé mozdul. Fehér fény alatt, például magasabb karotinoid tartalmat észleltek a hajdina magoncokban, mint a 100%-ban kék, vagy vörös fény esetében (Tuan et al., 2013; Davis, 2015).

A „minőségi” növény előállításához nem elég csak a hagyományos kertészeti LED-ekben megtalálható vörös és kék fény használata. Ugyanez vonatkozik a nagynyomású nátriumgőz (HPS) megvilágításra, ami dominánsan sárga fényű. A helyes alkalmazás érdekében a vörös és a kék kedvező arányát ki kell egészíteni a távoli vörös és egyéb hullámhosszak megfelelő arányával. Többféle LED egy panelbe való építése során érhető el szélesebb spektrum. Ennek köszönhetően valósítható meg a spektrális szabályozhatóság. Például a távoli vörös (700-750 nm) kritikus számos növény virágzásához. A potenciális káros hatáson kívül, a növények fotomorfológiai változásokkal reagálnak az UV-B (280-315 nm) sugárzásra. Az UV-B fénynek való kitettséget kapcsolatba hozták a megemelkedett olaj és illékony anyag tartalommal számos fűszerfaj esetében. Például a kálmos (*Acorus calamus L.*) (Kumari et al., 2009; Davis, 2015), a japán menta (*Metha arvensis L. var. piperascens*) (Hikoaka et al., 2010; Davis, 2015), a citromfű (*Melissa officinalis L.*), az orvosi zsálya (*Salvia officinalis L.*), az illatos macskamenta (*Nepeta cataria L.*) (Manukyan, 2013), a citronella (*Cymbopogon citratus L.*) (Kumari & Agrwal, 2010) és a bazsalikom (*Ocimum basilicum L.*) (Bertoli et al., 2013) esetében. Mind az UV-B és az UV-A (315-400 nm) sugárzás fontos szerepet játszik a fenolok, antociánok (színesedés) és az antioxidánsok képződésében. Általában a magasabb intenzitású napsugárzás emeli a gyümölcsök flavonoid tartalmát, viszont egyes speciális hullámhosszok meg tudják változtatni a flavonoid profilt is a gyümölcsök szöveteiben. A flavonoidok a gyümölcsök minőségének és gazdasági értékének fontos meghatározói, mivel hatással vannak a színre, az aromára, a csípős ízére és antioxidáns tartalmára (He & Giusti, 2010). A fényviszonyok és az egyéb környezeti tényezők közötti kölcsönhatás is jelentős mértékben megváltoztathatja a reakciókat. (Zoratti et al., 2014).

A LED-ek révén számos olyan kutatás indulhatott meg, melyek a fény növényi életfolyamatokat befolyásoló hatásait célozza meg. De látnunk kell azt is, hogy mindennek még az elején járunk, főleg ha azt is figyelembe vesszük, hogy a fajok között és néha fajokon belül is lehetnek különbségek ebből a szempontból. A tudomány jelenleg 391 000 növényfajt ismer, amelyek közül mintegy 369 000 (vagyis 94%) virágos növény. Összehasonlításképp körülbelül 1 000 000 faj alkotja a rovarokat, míg az emlősök „csupán” 6 495 fajtól állnak. Az emberiség „csak” 7 000 növényfajt természet fogyasztásra, melyből

napjainkban körülbelül 30 növény biztosítja az emberi élelmiszer-szükséglet 95%-át, ebből pedig négy faj (rizs, búza, kukorica és burgonya) adja fogyasztásunk több mint 60%-át.

2.2.3.1 A növénytermesztésen belül a fényszabályozás jövőbeli lehetőségei

Véleményem szerint a növénytermesztésen belül a termesztőberendezéseken belüli szabályozott termesztés egyre inkább felértékelődik. Gondoljunk itt akár a globális klímaváltozás egyre nagyobb számú negatív és kiszámíthatatlan anomáliájára, melyekre az agrár termelés Világ szinten nagyon érzékeny. Az IPCC ötödik helyzetértékelő tanulmányának összegzései szerint globális szinten számolni kell a vízhiány növekedésével, a romló termelési potenciálokkal, illetve a termőterületek csökkenésével, esetleges eltolódásaikkal (azaz haszonnövényeink termőterületeinek régiói idővel változhatnak). Emellett a növekvő népesség egyre nagyobb élelmiszerigénye tovább sürgeti a termesztéstechnológiák fejlesztését. A fentiekén túl olyan területeket is találunk, ahol a túlzott környezetszennyezés miatt tolódik egyre inkább a szabadföldről a zárt terek felé a termelés.

Ezek miatt a szabályozott, minél nagyobb termés hozamot, illetve termésminőséget elérő technikák kutatása és fejlesztése jellemzi napjaink mezőgazdasági kutatásait. Az előbbieken túl a másik fontos cél a környezetterhelés csökkentése, és a fenntarthatóbb gazdálkodás kialakítása. Mindezen szempontok és célok egyesülnek a precíziós mezőgazdasági technikákban. Ezen módszerek a szabadföldi termelésen túl, a termesztőberendezéseken és az állattartáson belül is megjelentek.

A termesztőberendezéseken belül fontosnak tartom kiemelni a beágyazott rendszereket, melyek az informatikai és gépészeti eszközöket egybeolvasztva lehetővé teszik a minél nagyobb és sokoldalúbb szabályozást.

Megjelentek azon „okos rendszerek”, melyek a környezeti paraméterek (hőmérséklet, páratartalom, megvilágítás) mérését ötvözik az öntözés, szellőzés, tápanyagpótlás szabályozástechnikájával, illetve automatizálásával. A fentebb bemutatott LED fényforrások terjedésével új elemként megjelent a fényszabályozás igénye is, mely már nem csak az időbeliségre, hanem a fény spektrális tulajdonságainak, illetve intenzitásának szabályozására is kiterjed. A LED-es megvilágítás rugalmasságának következtében lehetőség van olyan megvilágítási program kidolgozására, mely változik a növényfejlődést követve és így optimalizálja a megvilágítást. Lehetőség nyílik dinamikus megvilágítási rendszerek kidolgozására is például az üvegházakban, melyek kikapcsolják a világítási rendszert, amikor a napfény elér egy bizonyos szintet, vagy amikor a napi megvilágítási igény már teljesítésre került. Sőt, arra is van lehetőség, hogy a LED-eket ki és bekapcsolják aszerint, ahogy a felhőzet mozog, vagy a nap folyamán a fényviszonyoknak megfelelően változtassák a fény spektrumot és a legkevesebb energiaigénnyel kövessék a növény morfológiai igényeit, miközben kiegészítik az adott esetben optimális spektrumból hiányzó hullámhosszbeli különbségeket. Mivel ma még kevésbé ismert, hogy a másodlagos metabolitokra milyen hatással van a fény, és hogy ezek mennyire befolyásolják például az ízt, ma a leghatékonyabb, ha próbálgatással pontosítjuk a megvilágítási programokat (Davis, 2015). Ez a folyamat

embert próbáló. Például a Philips cégtől van der Feltz úr szerint a cég kutatócsoportja majdnem egy évig vizsgált egy számocefajtát a vörös, a távoli vörös, a kék és a fehér fény különböző arányú keverékével. A csoport végül kidolgozott egy programot, mely 20%-kal javította az ízt és a lédúsabbá tette a gyümölcsöt (LEDs Magazine, 2016).

Jelenleg a fény szabályozásra két irány mutatkozik gyártói oldalról. Az egyik, hogy adott fényprogramokat tudunk elindítani adott gyártó adott fényforrásának használata során. A legtöbb gyártó nem teszi közzé a cég megvilágítási programjainak részleteit, mivel azt a cég szellemi tulajdonának tartja. Emellett léteznek olyan rendszerek is, melyek a programozott fényprogramokon túl egyedileg szabályozhatóak. Például létezik olyan magyar fejlesztő cég is (*Dilaco Lighting Kft.*), mely a természetben lejátszódó karakterisztika szerint valósítja meg a természetes napfény „lekövetését” hajnalpírtól napestig. Ehhez 1:100 000 PWM dimming rate-el² dolgozik a rendszer, azaz egy lépés elérését 100 000 „parancs” elvégzésével valósítja meg. Elsősorban az állattartáson belül alkalmazva másfélszeres növekedést értek el hús- illetve tojáshozam terén bármiféle egyéb változtatás nélkül.

Véleményem szerint a jövőben elképzelhető egy olyan beágyazott rendszer kifejlesztése, mely a korábbiakon túl, a spektroszkópos kutatások eredményeit hasznosítva, dinamikus fény szabályozást tesz lehetővé, azaz a szenzorokkal mért aktuális növényi „állapot” szerint, minőségi vagy mennyiségi céljainknak megfelelően szabályozza a fény spektrális tulajdonságait. Azaz a precíziós technikákon belül kifejlődik egy dinamikus fény szabályozási módszertan is. Ezt a növényvédelmi kutatások is ki fogják egészíteni. Mindez egyúttal azt a szemléletbeli változást is jelenti, hogy az automatizált rendszereket idővel ne a környezeti paramétereket mérő, hanem a növényi paramétereket detektáló szenzorok irányítsák (ezen szempontok és célok a jövőbeli Agrárium 5.0, Ipar 5.0 technológiai lépcsőt jellemző prognózisok). Ezek mellett műszaki szempontból megjelenni látszik egy olyan igény is a kutatók fele (zárt termesztőberendezések esetén), hogy képesek legyünk meghatározni minden növényre az adott „napi maximumokat” (mind beltartalom, mind növekedés szempontjából). Ez a visszacsatolás miatt lenne hasznos adat, mely egy automatizált, zárt rendszer esetén szintén nagyon fontos, a hatékony fejlesztések és az önellenőrzés alapja. Tehát idővel jó lenne meghatározni a fontosabb termesztett fajok/fajták esetén, hogy adott napon (a vegetációs ciklus akár minden napján) mely növekedést, mely paramétereket várunk teljesülni. Amennyiben tisztában vagyunk az egyedi biológiai változatosságokkal, a paraméterek egymást befolyásoló nagymennyiségű hatásmechanizmusaiival, úgy belátható, hogy ezen cél rendkívül bonyolult.

² dimmelhető LED lámpák: fényerejük szabályozható, mivel pusztán a feszültség szintek változtatásával egy bizonyos szint alatt már nem lehetséges a szabályozás, emiatt ezen rendszerek az impulzus szélességének változtatásával (PWM) képesek a kisléptékű szabályozásra, ezáltal szabályozni a fényerőt

2.2.4 A növényi fényvizsgálatokban leggyakrabban használt mértékegységek, spektrális mérőszámok

A fény leírására számos mérőszám és mértékegység lett kidolgozva. De kiemelném, hogy sokszor az adott mérési megközelítés az adott tudományterület céljait is ötvözte. A különböző mérési rendszerek adott esetben eltérő fizikai-műszaki megközelítéssel, szenzorikával, mérőszámmal dolgoznak. Idővel egyes mérési módszereket más tudományterületek is elkezdtek használni, nem minden esetben gondolva arra, hogy a rendszer mögötti fizikai-műszaki alapok esetleg nem teljesen fedik le a számukra fontos szempontrendszerét. A fentiek mellett fontos azt is látnunk, hogy az eltérő módszertan eltérő szenzorikát is jelenthet. Ezen belül két nagyobb csoportra oszthatjuk a mérési szenzorokat, egyik irányban a kvantummérők elvén működő szenzorparkot vizsgálhatjuk, másik megközelítésben a spektroradiométerek elvén működőeket. Míg előbbieken a fotonok számának összmenyiségére helyezzük a hangsúlyt, és az adott detektor érzékenység melletti összmenyiség pontos mérése a cél, addig az utóbbinál a hullámhossz szerinti eloszlásra teszik a hangsúlyt.

A következőekben bemutatom a leggyakrabban használt fénytani paramétereket, melyeket a növényvizsgálatok során alkalmaznak.

Az elektromágneses hullámok (sugárzások) kibocsátásával, terjedésével és elnyelésével foglalkozó tudományág a radiometria (sugárzásmérés, sugárzástechnika). Az ide tartozó fizikai mennyiségeket radiometriai (sugárzástechnikai) mennyiségeknek nevezik, melyek számszerűen jellemzik az elektromágneses sugárzás energiájának kibocsátását, terjedését és elnyelését. Mivel a látható fény is elektromágneses hullám, terjedése leírható a radiometriai mennyiségekkel.

A látható fényre ezen kívül külön kidolgozták az ún. fotometriai (fénytani) mennyiségek rendszerét is. Definiálásuk nemcsak fizikai, hanem fiziológiai tényeket is figyelembe véve történik. A fotometriai mennyiségek kizárólag a látható fényre vannak értelmezve, és mérési megközelítésekor az emberi szem érzékenységét is figyelembe veszik.

2.2.4.1 Radiometriai mérőszámok

- Sugárzott energia és teljesítmény

A sugárforrásokat jellemző (ki)sugárzott energia, mint fizikai mennyiség a sugárforrás által valamely adott idő alatt elektromágneses sugárzás formájában kibocsátott összes energiát jelenti. Jele Q_e (az alsó 'e' index mindig a CIE szabvány szerint a radiometriai megközelítésre utal, energiát fejez ki). Mértékegysége a Joule (J).

A sugárzott energiát elosztva a sugárzás időtartamával kapjuk a sugárzott teljesítmény értékét:

$$\Phi_e = \frac{Q_e}{t}, [W] \quad (2.4)$$

ahol:

Φ_e sugárzott teljesítmény, [W]

Q_e a sugárzás energiája, [J]
 t a sugárzás időtartama, [s]

- Kisugárzott és besugárzott felületi teljesítmény

Egy véges felületű sugárforrás kibocsátása (emissziója) a kisugárzott felületi teljesítménnyel jellemezhető. Ez a sugárzott teljesítményből a sugárforrás felületének nagyságával történő osztással adódik:

$$M_e = \frac{\Phi_e}{A_s}, \left[\frac{W}{m^2} \right] \quad (2.5)$$

ahol:

M_e kisugárzott felületi teljesítmény, [W/m²]

Φ_e besugárzott teljesítmény, [W]

A_s a sugárforrás felülete, [m²]

M_e megmutatja a sugárforrás egységnyi felülete által egységnyi idő alatt kisugárzott összes energiát.

A besugárzott felületi teljesítmény már a besugárzott testek jellemzője. Definíciója hasonló az előzőhöz, csak itt nem a kibocsátott, hanem a beeső sugárteljesítményt kell osztani a besugárzott felület nagyságával.

$$E_e = \frac{\Phi_e}{A}, \left[\frac{W}{m^2} \right] \quad (2.6)$$

ahol:


E_e Besugárzott felületi teljesítmény, [W/m²]

Φ_e besugárzott teljesítmény, [W]

A A besugárzott test felülete, [m²]

A későbbiekben besugárzásnak, vagy irradianciának fogom nevezni.

A radiometrikus megközelítés tehát elsősorban teljesítményben (W) adja meg egységeit, melyek vagy a fényforrást, vagy a felszint elérő sugárzási teljesítmény összeget mutatják meg, a sugárzás hullámhosszbeli eloszlásával nem foglalkozik. Amennyiben a fényforrás minden irányban egyenletesen adja le sugárzását, úgy izotropikus sugárforrásnak nevezzük. Ekkor annyival kiegészíthető a fenti megközelítés, hogy a tér minden irányában, adott távolság mellett ezen teljesítményt adott térszögben értelmezhetjük (9. ábra). A térszög dimenziómentes mérőszám, de a gyakorlatban a szteradián mértékegységet használjuk jellemzésekor.



9. ábra - A térszög értelmezése adott távolság mellett (Forrás: Ábrahám, 2014.)

Tehát a teljes térszög az alábbiak szerint írható fel:

$$\Omega_{\text{total}} = \frac{4\pi r^2}{r^2} = 4\pi \text{ [sr]} = 12.57 \text{ sr} \quad (2.7)$$

- Ki/besugárzás intenzitása (I_e)

Amennyiben a sugárzási intenzitást (I_e) szeretnénk jellemezni, mely megmutatja, hogy adott irányban mennyi a kisugárzott energia összege, az alábbi összefüggést kapjuk:

$$d\Phi_e = I_e d\Omega \quad (2.8)$$

$$\Phi_e = \int_{4\pi} I_e d\Omega \quad (2.9)$$

A sugárzás intenzitása tehát a tér irányától is függ már ebben az esetben. Mértékegységként a W/sr -t használjuk.

- Radiancia (L_e)

A sugárzási energia intenzitásának adott forrás adott pontjából adott irányban kisugárzott teljesítmény összege. (Logikája ekvivalens a fotometriai fényáram sűrűséggel.)

Ha a besugárzást szeretnénk kifejezni, az alábbi összefüggés kapjuk:

$$d\Phi_e = L_e \cdot \cos(\vartheta) dA d\Omega \quad (2.10)$$

ahol:

ϑ – azon szög, mely a $d\Omega$ térszög irányának és a kibocsátó vagy visszaverő dA felület normálisa által bezárt szög (egy felület normálisa, azaz normálvektora, merőleges a vektorok által kifeszített síkra). Ebből kifolyólag, amennyiben derékszögben érkezik egy felszínre a besugárzás a $\vartheta=0$, $\cos(0)=1$

Ha az irányított sugárzási intenzitást szeretnénk a radianciával levezetni, a következő összefüggés adódik:

$$dI_e = L_e \cos(\vartheta) dA \quad (2.11)$$

$$I_e = \int_{\text{kibocsátó felszín}} L_e \cdot \cos(\vartheta) dA \quad (2.12)$$

A radiancia mértékegysége: W/(m²sr)

2.2.4.2 Napsugárzást leíró és fotometriai mérőszámok

A napsugárzás jellemzésére leggyakrabban a globálsugárzás értékét használjuk, azaz a földfelszín adott pontját jellemző összes sugárzási energia intenzitást. Mértékegysége W/m².

Globálsugázmérővel, azaz piranométerekkel mérjük. Emellett fontos jellemző szám a napfénytartam (óra/év) értéke is.

A hagyományosabbnak vehető fotometriai mértékegységek az emberi szem érzékenységi tartományába (380-780 nm) eső beérkező sugárzás jellemzésére szolgálnak. Ezen belül a fényforrások fényintenzitását (I_v) jellemző SI mértékegység a candella (cd). A fényáram (Φ_v), avagy a fényteljesítmény jellemzésére használt egység a lumen (lm). Ez utóbbit a gyakorlati életben gyakrabban használjuk, mint a candellát. A megvilágítás erősségének (E_v) jellemzésére szolgál a lux (lx). Ez utóbbit fotométerekkel mérjük, míg az előbbi kettőt ebből szoktuk számolni, vagy speciális laborokban lehet még meghatározni.

A megvilágítás fotometriai, világítástechnikai fogalom, a felület egy adott pontján a beeső fényáram és a felület hányadosa:

$$E_v = \frac{\Phi_v}{A}, \left[\frac{\text{lm}}{\text{m}^2} = \text{lux} \right] \quad (2.13)$$


ahol:

E_v megvilágítás, [lux]

Φ_v fényáram, [lm]

A a megvilágítás felülete, [m^2]

A növények és az emberek egymástól nagyon eltérő módon érzékelik a fényt. Fotopikus látásnak nevezzük az emberek és sok más állat jól megvilágított körülmények közötti szín és fény érzékelését. A lumen egy olyan mértékegység, amely az emberi szem érzékenységének modelljén alapul jól megvilágított körülmények között, ezért a modellt fotopikus válaszgörbének ($V(\lambda)$) hívják (10. ábra).



10. ábra - A PAR, a VIS tartomány és a fotopikus válaszgörbe $V(\lambda)$ együttes ábrázolása a növényi klorofill elnyelésének sematizált, színezett képe mellett

A 10. ábra alapján elmondhatjuk, hogy a fotopikus válaszgörbe harang alakú, és megmutatja, hogy az emberek sokkal érzékenyebbek a zöld fényre, mint a kék vagy a piros fényre. Fotométerekkel (luxmérők) mérjük a fény intenzitását (lumen használatával, lm/m^2) a világítási alkalmazásoknál.

A kertészeti világítási rendszerek fényintenzitásának mérésekor a fotométerek használatának alapvető problémája a kék (400 - 500 nm) és a vörös (600 - 700 nm) fény alulreprezentációja a látható

spektrumban. Lehet, hogy az emberek nem tudják hatékonyan érzékelni a fényt ezeken a területeken, de a növények nagyon hatékonyan használják a vörös és a kék fényt a fotoszintézis révén. Éppen ezért a lumen és a lux ugyan könnyen használhatóak, mégsem írják le megfelelően a fényviszonyokat a növények szempontjából.

A Napból érkező sugárzásból (170-4000 nm) a növények csupán a 380-720 (780) nm közötti hullámhosszú tartományt hasznosítják. Ezen belül a 400-700 nm közötti sugárzási tartományt nevezzük a fotoszintetikusan aktív sugárzásnak (PAR). A fotoszintetikusan aktív sugárzás tartományában a növények esetén két fényelnyelési maximumot találhatunk. Az egyik az ibolya-kék (430-470 nm), a másik a narancs-vörös (640-680 nm) közötti tartomány. Ebben a két tartományban a növényi fényelnyelő képesség igen jó, a beérkező sugárzás 90%-át is elnyelhetik. Ennek a két fényelnyelési tartománynak a növényi élet biztonsága miatt van jelentősége.

A fotoszintetikusan aktív sugárzás (PAR) mennyisége és spektrális összetételének mérése fontos a fény növénynövekedésre gyakorolt hatásának felmérésében. 1972-ben K. McCree bizonyította, hogy a fotoszintetikus válasz jobban korrelál a fotonok számával, mint az energiával. Mindezt az is magyarázza, hogy a fotoszintézis egy fotokémiai átalakulás, amelynek során az egyes molekulákat egy foton abszorpció aktiválja az elsődleges fotokémiai folyamat során.

A PAR meghatározása a foton (kvantum) fluxussal, azaz a fotonok molszámával a sugárzási energia 400 nm és 700 nm közötti tartományában történik. Egy mol foton egyenlő $6,022 \cdot 10^{23}$ darab (Avogadro-szám - N_A) fotonnal. Azaz a PAR nem más, mint a 400-700 nm-es spektrumtartományban a vízszintes síkra érkező napsugárzásban a fotonok száma, avagy a fotoszintetikus foton áramlás (PPF, Photosynthetic Photon Flux). A PPF-t $\mu\text{mol/s}$ -ben adjuk meg, de a gyakorlati élet a fotoszintetikus foton áramlás sűrűségét (PPFD, Photosynthetic Photon Flux Density) használja gyakrabban, mely a foton besugárzás mértékét mutatja meg négyzetméterenként és másodpercenként, azaz már a növény szinteken. Mértékegysége: $\frac{\text{mol}}{\text{m}^2 \cdot \text{s}}$, általában a $\frac{\mu\text{mol}}{\text{m}^2 \cdot \text{s}}$ mértékegységet használják. Mindkettőnél a mólok közvetlenül átszámíthatók fotonokká. A foton energiája Planck egyenlete alapján:

$$E_f = h \cdot f = \frac{h \cdot c}{\lambda} \quad (2.14)$$

ahol:

h Planck állandó értéke $6.626 \cdot 10^{-34} [\text{J} \cdot \text{s}] = \left[\frac{\text{m}^2 \text{kg}}{\text{s}} \right]$

c fénysebesség, értéke $2,99 \cdot 10^8 \left[\frac{\text{m}}{\text{s}} \right]$

Így egy adott hullámhosszú foton 1 mólnyi energiája $E_f \cdot N_A$ ($N_A = 6,022 \cdot 10^{23} \text{ mol}^{-1}$).

A fotonok száma (N_f) másodpercenként és felületi egységenként kiszámítható a besugárzott felületi teljesítmény (E_e) alapján (megjegyzés: amennyiben a λ értékét nm-ben adjuk meg úgy alkalmaznunk kell a 10^{-9} átváltást a képletben):

$$N_f = \frac{\Phi_e}{E_f} = \frac{\Phi_e \cdot \lambda \cdot 10^{-9}}{h \cdot c} = \frac{\Phi_e \cdot \lambda \cdot 10^{-9}}{1.988 \cdot 10^{-25}} \frac{\left[\frac{W}{m^2}\right] \cdot [m]}{\left[J \cdot s \cdot \frac{m}{s}\right]} \left[\frac{1}{m^2 \cdot s}\right] \quad (2.15)$$

A foton fluxus (Φ_{PPF}) meghatározható a fotonok számának μmol -á történő átalakításával:

$$\Phi_{PPF} = \frac{N_f}{N_A \cdot 10^6} \left[\frac{\mu\text{mol}}{m^2 \cdot s}\right] = \Phi_e \cdot \left(\frac{\lambda \cdot 10^{-9}}{h \cdot c \cdot N_A}\right) \cdot 10^6 = \Phi_e \cdot \lambda \cdot 10^{-9} \cdot 8,359 \cdot 10^6 \left[\frac{\mu\text{mol}}{m^2 \cdot s}\right] = \mu E \quad (2.16)$$

A fenti egyenletet használhatjuk tehát a besugárzás és a fotonfluxus közötti átváltásra.

A fotoszintetikus foton áramlás jellemzésére a növényteni vizsgálatokban gyakran a $\mu\text{Einstein}$ mértékegységet használják, mely a foton fluxusnak megfelelően μE foton mennyiséget jelent, illetve a sűrűség megadásakor $\mu\text{E}/m^2/s$ mértékegység használatos. A foton fluxus és PAR mérése során a gyakorlatban kvantum szenzorokat használnak. Ezen szenzorok műszaki oldalról adott pillanatban jellemző össz energiát mérve adják meg a fotonmennyiséget a PAR tartományon belül, viszont mivel nem képesek detektálni ezek spektrális eloszlását, ezen összeg szintén nem teljesen fedi le a növényi igényeket. Egyrészt a korábbiakban már láthattuk, hogy a hullámhossz és az energiamennyiség fordítottan arányos, azaz például a kék tartományban érkező fotonok nagyobb energiát hordoznak, míg a piros tartományban kevesebb energiát. Ezáltal pedig ugyanazon PAR energia alapján egy általános eloszlással kalkulált fotonszám a valóságban többféle tartományú fotonok révén is egyezhet. Ezen módszertan alapján azt nem lehet megmondani, hogy mindig a fotoszintézisnek megfelelő hullámhossztartományú fotonok állnak a mért érték mögött, avagy ettől teljesen eltérőek.

A napi teljes megvilágítottság (DLI) az összes mól, ami a fotonokból eléri az adott felületet egy 24 órás periódus alatt. A PAR tartományra vizsgált DLI különösen hasznos mutató a növény napi szintű, fotoszintetikusán aktív fényexpozíciójának kifejezésére. A DLI lehet egy egyszerű mérőszám, például a beltéri művelés során, mivel ekkor a fényintenzitás és a fotoperiódus a művelés minden szakaszában állandó marad. Ugyanakkor bonyolultabb kiszámítása van, ha kültéri vagy üvegház alatti művelést vizsgálunk, mivel ilyenkor a 24 órás periódus alatt folyamatosan légköri és szezonális változások következnek be.

$$DLI = \frac{PPFD (\mu\text{mol}/m^2/s) \cdot 60 \text{ min}/h \cdot 60 \text{ s}/\text{min} \cdot \text{napfénytartam (h)}}{1000000 \mu\text{mol}/\text{mol}} \quad (2.17)$$

Míg a beltéri megvilágításból származó PPFD megfelelő tervezés mellett közel állandó maradhat, a természetes napfénytől származó PPFD akkor csúcsosodik ki, amikor a nap délben eléri a csúcspontját, de a környezeti tényezők, például az időjárás vagy az égen lévő szennyeződések, például pollenek vagy szennyező anyagok miatt, egész nap szakaszosan változik. A DLI térképek hasznosak annak becslésére is, hogy egy növény mennyi kiegészítő fényt igényel, de akár más szempontokat is befolyásolhatnak, például amikor árnyékolásra van szükség a növény fényidőszakának lerövidítéséhez, a rövid nappalos növények virágzásának kiváltásához stb.

A növényi „fénytelítettség” szintén egyre több kutatásban megtalálható. A vizsgálat alapját az adja, hogy a fényintenzitás (PPFD) növekedésével a fotoszintetikus sebesség is szignifikánsan nő egy

bizonyos telítettségi pont eléréséig. Minden növényfajnak van tehát egy fényteltettségi pontja, melynek elérése után a fotoszintetikus tevékenység már nem növelhető tovább. Erre a pontra viszont számos egyéb tényező is hatással van köztük a növény kora, mérete, a CO₂ ellátottság, egyéb stresszt jelentő változások.

Ezek a mértékegységek a fotoszintetikus válasz körül mozognak, viszont már folyamatban van új mértékegységek kifejlesztése. Olyan szervezetek dolgoznak további mértékegységeken, definíciókon és tesztmódszereken, mint az ASABE³. Az egyik ilyen potenciális mértékrendszer kiterjesztené a hullámhossz tartományt a fotoszintézis szempontjából aktív sugárzason túl az UV, a távoli vörös és az infravörös tartományra, amire a növények szintén érzékenyek (UL, 2016).

A kertészeti világítási rendszerek fényintenzitásának számszerűsítésére, jellemzésére is egyre inkább a PAR tartomány mérését használják a fotometriai mérések helyett. Ehhez leginkább kvantumérzékelőket alkalmaznak elsődlegesen. Ezek az érzékelők optikai szűrő alkalmazásával egyenletes érzékenységet hoznak létre a PAR fényre (10. ábra), és fénymérővel kombinálva alkalmazhatók a pillanatnyi fényintenzitás mérésére, vagy adatgyűjtővel a kumulatív fényintenzitás mérésére. Tehát, hogy mennyi PAR tartományba eső fényt biztosít a lámpatest, fotoszintetikus fotonfluxusként (PPF) mérhetjük. Hogy mennyi PAR tartományú sugárzás áll rendelkezésre adott pillanatban a növényeknél, azt fotoszintetikus fotonfluxus sűrűségként (PPFD) adjuk meg. Míg, hogy mennyi energiát használt fel a berendezés, hogy a PAR elérhető legyen növényei számára fotonhatékonyságként jellemzik.

Minél többet tudunk a növényi fotoreceptorokról (7-8. ábra) felmerül az igény, hogy a PAR értékét és mérési módszertanát ki kellene szélesíteni a 350 – 750 vagy 800 nm-es tartományig (Far-Red és közeli UV igazolt fontosságai miatt). Ebből kifolyóan egyre többen kezdenek el használni egy új mérőszámot a PBAR-t (Plant Biologically Active Radiation – Növényi biológiai folyamatok szempontjából aktív sugárzás), mely a 350-800 nm-es tartományt jellemzi. Ez a mutató egyre fontosabb, mivel a klorofillon kívül más, a hullámhosszak szélesebb tartományára érzékeny fotopigmenteket, és metabolikus folyamatokat fedeztek fel a növényekben. Ezért javasolt egy kiterjesztett spektrális tartomány mérési rendszer.

A világítástechnika oldaláról emellett a fentieket kiegészítve a teljes elektromos W-ot, Ft/W-ot vagy W/m² használják a kertészeti világítási rendszerek összehasonlítására, de ezen mutatók növényi szempontból haszontalanok, és valószínűleg a vásárlót rossz vásárlási döntésre készítetik. Elsősorban amiatt, mivel nem az áram természet növényeket, hanem a növények számára hasznos „fotonok energiája”. A LED panelekben használt diódák teljesítménye (1W, 3W, 5W stb.) szintén félrevezető lehet, mivel nem tükrözi a teljes világítási rendszer teljesítményét. A LED teljesítmény egy rendszerbemenet, de a

³ ASABE - American Society of Agricultural and Biological Engineers; Amerikai Mezőgazdasági és Biológiai Mérnökök Társasága

termelőknek a rendszer kimenete fontos. Ezenkívül a radiometrikus hatékonyság (mennyi fényt bocsát ki egy lámpatest egy watt villamos energiából) óriási változatosságot mutat a ma piacon lévő népszerű lámpatestek és LED rendszerek között. Mivel a fény (és nem az elektromosság) szükséges a növények növekedéséhez, ismernünk kell, hogy egy lámpatest mennyi „hasznos” fényt bocsát ki. A világítástechnikai termékeket gyártó cégek 99,9%-a nem hirdeti ezt a mutatót. Gyártói oldalról nagyon nehéz hatékony ($\mu\text{mol}/\text{J}$ -ban mért) világítási rendszert tervezni, amely magas fényszintet biztosít. Nem létezik olyan műszaki megoldás, sem olyan spektrális összeállítás, amely lehetővé tenné egy 1000W-os lámpatest cseréjét 50W-ra, még akkor sem, ha csak a növények számára szükséges „hullámhosszakat” használja. A nagy hatékonyságú LED-ek, tápegységek és optika többet kerül, mint a kevésbé hatékony alkatrészek, és sok gyártó alacsonyabb minőségű alkatrészeket használ a haszonkulcs növelése érdekében. Ezért a fénykibocsátás és a rendszer által a fényt előállító hatékonyság kvantitatív mérése a kritikus mutató, amelyet a kertészeti világítási megoldások teljesítményének összehasonlításához tudunk használni.

A fentiekén túl szintén fontos, hogy ne csak egy PPFD-mérést végezzünk közvetlenül a világítóttest alatt. Vizsgálni kell az egész terület esetén a PPFD szinteket, hogy kiszámítsuk az átlagos fényszintet. A LED-ek szoros összefogásával és megfelelő optikával a gyártó nagyon könnyen képes rendkívül magas PAR-mérést mutatni közvetlenül a lámpatest alatt. Azonban ismernünk kell, mennyi PAR oszlik el az egész növény szinten. Mivel a legtöbb LED-es világítási rendszer a LED-eket egy kis lámpatestbe tömöríti, ezen rendszerek nagyon magas PPFD-szintet produkálnak közvetlenül a lámpatest alatt. Ezek a fényszintek azonban jelentősen csökkenni fognak, amikor a mérőrendszerünket akár csak kis távolságra mozgatjuk el a lámpánktól. A fény egyenletessége a növekedési területen nagyon eltérő is lehet. Mivel a PPFD értéke a lámpatest és a növényállomány távolságától, egyéb kialakításoktól, reflektáló felületektől is nagymértékben függ, ezáltal a legtöbb gyártó nem publikál teljes PAR „térképeket”, hanem elsősorban helyszíni mérések révén lehet pontosan meghatározni. A gyártói adatok is csak ezek ismeretében használhatóak.

A kertészeti világítási rendszerek esetén a fotonhatékonyság összevetése lehet még fontos. Ha a fény PPF-je a bemenő teljesítmény mellett ismert, kiszámítható, hogy egy kertészeti világítási rendszer mennyire hatékony a villamos energia PAR tartományú foton sugárzássá történő átalakításában.

$$\eta_{foton} = \frac{P_{PPF}}{P_{vill}} = \frac{\frac{\mu\text{mol}}{\text{s}}}{W} = \frac{\mu\text{mol}}{\text{s}} \cdot \frac{\text{s}}{J} = \frac{\mu\text{mol}}{J} \quad (2.18)$$

A matematikai egyszerűsítések után a fotonhatékonyság a $\mu\text{mol}/\text{J}$ értékkel jellemezhető. Minél nagyobb ez a szám, annál hatékonyabban alakítja át a kertészeti világítási rendszer az elektromos energiát PAR fotonokká.

A növekedési területre juttatott fény mennyisége (PPFD), a fotonhatékonyság (PPF $\mu\text{mol}/\text{J}$), a villamos fogyasztás és a fényeloszlás mintázata válhatnak előnyösebb mérőszámokká a kertészeti

üzemekben. Egyre fontosabb tehát a megfelelő választás és tervezés mellett az ellenőrző mérések elvégzése, mind a spektrális összetétel, mind a fény területi eloszlásának ellenőrzése céljából.

2.2.4.2.1 Napsugárzást leíró és fotometriai kvantummérésből adódó nehézségek

Nincs kimondott átváltási tényező a fotonmérések és a szélessávú sugárzás energia- vagy fénymérése között. Azonban egy adott konverziós tényező meghatározható egy adott spektrális energiaeloszláshoz, például egy adott fényforráshoz. Ez gyakorlati érték, mivel a hagyományos megvilágítási számítási technikák felhasználhatók a növénynövekedési területek megtervezésére, és mivel a színértékkel korrigált fény- vagy megvilágítási mérők használhatók a PAR-értékek mérésére.

A 3. táblázatban láthatjuk a Osram laborjában mért összehasonlító mérések alapján megalkotott szorzótényezőket. Azaz, hogy adott fényforrás esetén mért lux (lm/m^2) értékeket mely szorzófaktorral szorozva kaphatjuk meg a fotonfluxust ($\mu\text{mol}\cdot\text{s}^{-1}\cdot\text{m}^{-2}$) (CIE, 1993).

3. táblázat - Különböző fényforrások összehasonlító mérései alapján használt szorzótényező Forrás: Osram

Fényforrás fajtája	Szorótényező – 400-700nm	Szorótényező – 400-800nm
Izzó (3000 K)	0.019	0.036
HPS (High Pressure Sodium - nagynyomású nátriumgőz) lámpa	0.012	0.013
Higanygőz lámpák		
Sima	0.011	0.013
Foszfórral bevont/kevert	0.012	0.014
Fémhalogén	0.014	0.015
Fluorescens:		
Hideg fehér	0,013	0,013
Nappali fény	0.014	0.015
GRO	0.029	0.030
GRO/WS	0.019	0.022
Tiszta nyári nap (6000 K)	0.018	0.024
Északi fény (12 000 K)	0.020	0.024

A napsugárzás méréséhez a legtöbbször globálsugárzás mérők, vagy PAR mérők adatait alkalmazza a gyakorlat. Ezen szenzorok a pirométerek csoportjába tartoznak. Leggyakrabban termoelemes detektorokkal, vagy szilícium alapú detektorokkal dolgozó műszerekről van szó. A luxmérők sokféle méréstechnikát alkalmazhatnak. Ezek között a leggyakoribb az egyszerűbb fotoszenzorok alkalmazása. Mindkét műszertípus azon elven működik, hogy az abszorber felület által elnyelt energia hatására az azt abszorbeáló anyag – vagy a vele hőkapcsolatban lévő valamilyen másodlagos anyag – tulajdonsága megváltozik. Ez legtöbbször valamilyen elektromos impulzus (például luxmérők), vagy hőtani változás (kvantummérőknél, pirométereknél), mely arányos az elnyelt energiával. A luxmérők számos anyagot alkalmazhatnak detektorként, mint például szelént, kadmium-szulfidot, de

napjainkra félvezetők, például szilícium alapú érzékelők is fellelhetőek közöttük. A luxmérők a mért értékeket ezután korrigálják a fotopikus $V(\lambda)$ görbe szerint. Számos PAR mérőműszer leírását áttanulmányozva itt is elmondható, hogy ezen műszerek szintén elvégzik a spektrum-érzékenységi súlyozási funkciót a $V(\lambda)$ görbével, így képesek meghatározni a fényt luxokban vagy a fényáramot lumenekben is a PAR értékek mellett.

Sem a radiométerek, sem a kvantumérzékelők nem tudnak semmilyen spektrális információt szolgáltatni, és ezáltal erősen korlátozza azok lehetőségeit a „világítási receptek” kidolgozásában és nyomon követésében a modern kertészetben, automatizációban. Ezen probléma egyik megoldása lehet, az úgynevezett kombinált technológiák és szenzorok használata, melyek egyszerre ötvözik a fotódiodák, illetve a spektroradiométerek tudását. Ilyen irány például a BTS szenzorok (Bi-Technology light Sensor) megjelenése. Viszont ezek ára még elég magasnak tekinthető.

2.2.4.3 Spektrális mérőszámok

A távérzékelés során a növények megfigyelésére alkalmazott módszerek két nagy csoportba sorolhatók: empirikus és fizikai. Az empirikus módszerek megkísérlik feltárni a statisztikai kapcsolatokat a terméshővelkedési tulajdonságok és a lombkorona spektrumok között (Aparicio et al., 2002). Ezzel szemben a fizikai módszerek megkísérlik meghatározni azokat az alapvető mechanizmusokat, amelyek az empirikus összefüggéseket generálják az oksági elvek megértése érdekében (Dorigo et al., 2007).

Az empirikus módszerek leggyakrabban alkalmazott megközelítése a különféle spektrális indexek alkalmazása és keresése. A spektrális indexeket elsősorban az „érzékenyebb” hullámhossztartományok matematikai kombinációi révén alkotjuk, cél olyan párok megtalálása, melyek a legjobban korrelálnak a vegetáció általunk fontosnak vélt jellemzőivel. A vegetációs indexeket általában 3 csoportba sorolhatjuk, így lehetnek egyszerű hányados (SR), hányados (RVI – Ratio Vegetation Index), illetve normalizált (ND – Normalized difference) indexek. Az egyszerű indexeket összeadással, vagy kivonással, illetve osztással képezzük, a hányados index esetén csak osztással (egy hányados index esetén emiatt mindkét egyszerűsítést használnak a szakirodalmak, ezért ezen tanulmányban az SR jelöléssel látom el az egyszerű hányados indexeket), míg a normalizált indexek esetén a különbség és az összeg hányadosát képezzük. Az indexek képzéséhez 2, esetleg 3, ritkábban 4 érzékeny hullámhosszat használunk fel.

A spektrális elemzések egyre nagyobb hangsúlyt kapnak a növények vizsgálatában. Ennek egyik általánosan alkalmazott mérőszáma a levélfelületi index (Leaf Area Index, LAI), melynek értéke megadja, hogy egységnyi talaj felület felett hány egységnyi zöld növényfelület található (m^2/m^2).

$$LAI = \frac{T_{levél}}{T_{terület}} \quad (2.19)$$

ahol:

$T_{levél}$ a levélfelület nagysága [m^2]

$T_{terület}$ a növényállomány alatti terület nagysága [m^2]

A levélfelületi index maximális értékét a genetikai, környezeti és agrotechnikai tényezők határozzák meg (Huzsvai, 2008). Napjainkra megjelentek olyan megoldások, melyek okostelefonok használatával próbálják megbecsülni a LAI értékét (például VitiCanopy), bár nem adnak tudományosan pontos eredményt, de méréseik jól korrelálnak a professzionális mérőrendszerekkel.

A másik gyakran használt mérőszám a vegetációs az NDVI, amely egy adott terület vegetációs aktivitását fejezi ki egy dimenziómentes mérőszámmal. Értékét a növényzet által a közeli infravörös (NIR, 800-1100 nm) és a látható vörös (RED, 600-700nm) sugárzási tartományban visszavert intenzitások különbségének és összegének hányadosa határozza meg. Az NDVI korrelál a területet takaró növényzet fajlagos klorofill tartalmával (Mika et al., 2011). A vegetációs index értéke -1 és +1-ig terjed. A negatív értékek a vízzel borított területeket jellemzik, a zérushoz közeli érték a növényzet hiányát jelzi (mesterséges, avagy ásványi felszínek), a 0,2-0,3 körüli értékek füves, bokros területekre, míg a 0,8-0,9 értékek sűrű erdőkre utalnak (Eredics, 2007). A távérzékelés elsősorban különböző felszínekkel borított területek arányainak meghatározására, míg a precíziós mezőgazdaság a vegetációs stádium megállapítására, vagy az egészségi állapot meghatározására és ezáltal előrejelzésre alkalmazza (Jung, 2014). Az NDVI érték elsősorban a növényi biomasza mennyiségével áll szoros kapcsolatban (Fan et al., 2009; Swatantran et al., 2011), de alkalmazható a növényzet egészségi állapotának felmérésére, betegségek előrejelzésére, illetve az agrotechnikai munkálatok ellenőrzésére, segítésére is (vetési hibák, belvízkárok, gyomvédelem, kártevők). A fentiekén túl a nitrogén felvétellel is szignifikáns összefüggést mutat, így a tápanyagutánpótlás precízebb alkalmazása, területi diverzifikálását is segíti.

A vegetációs indexeknek létezik emellett számos hasonló formája (M5 melléklet), melyek szintén segíthetik a növényzet állapotának nyomonkövetését. Egyre több olyan alkalmazás, illetve szolgáltató jelenik meg a piacon, melyek beépítve, automatán kalkulálják, térképen ábrázolják például az NDVI értékét, és azonnal bármely eszközre továbbítják a gazdák számára, vagy akár valamely gép számára az adatokat.

A növényi stressz észlelése a távérzékelés egyik fontos alkalmazási célja (Prabhakar et al., 2011). A távérzékelési elv abból indul ki, hogy a tápanyaghiányból adódó stressz megmutatkozik a fotoszintetikus aktivitásban, a sejtek szerkezetében, és eredményül megváltoztatja a növények spektrális reflexióját a látható (VIS), a közeli infravörös (NIR) és rövidhullámú infravörös (SWIR) régiójában.

2.2.4.3.1 Klorofill indexek

- CI – Chlorophyll Index: Ezen indexet a levelek teljes klorofill tartalmának kiszámításához használják. Többféle változatban is kidolgozták, melyek közül a CI_{green} és a $CI_{red-edge}$ értékeit fogom használni, mivel ezek mutatták eddig a legnagyobb érzékenységet a klorofill-tartalom kis változására is, és a legtöbb fajban konzisztensek. Matematikai formulájuk:

$$- CI_{green} = (NIR / GREEN) - 1 = \rho_{730} / \rho_{530} - 1 \text{ illetve } \rho_{730} / \rho_{570} - 1 \quad (2.20)$$

$$- \text{CI}_{\text{red-edge}} = (\text{NIR}/\text{REDEGE}) - 1 = \rho_{850}/\rho_{730} - 1 \quad (2.21)$$

- MTCI - MERIS Terrestrial chlorophyll index: Ez az index is érzékeny a klorofill-koncentráció változásaira, a számítás során a NIR, a vörös él és a vörös sáv fényvisszaverődését veszi figyelembe. Matematikai formulája (egyes szakirodalmak eltérései miatt az alábbi formulát használtam kutatásom során):

$$- \text{MTCI} = (\rho_{850} - \rho_{730}) / (\rho_{730} - \rho_{675}) \quad (2.22)$$

- MCARI – Modified Chlorophyll Absorption in Reflectance Index: Az MCARI meghatározza a klorofill abszorpció mélységét, és nagyon érzékeny a klorofill koncentráció változásaira, valamint a levélterület-index (LAI) változására. Az MCARI értékeket emellett kevésbé, vagy egyáltalán nem befolyásolják a megvilágítási körülmények, a talaj és más nem fotoszintetikus anyagok háttérvisszaverődései. Matematikai formulája:

$$- \text{MCARI} = ((\rho_{850} - \rho_{710}) - 0.2 \cdot (\rho_{850} - \rho_{570})) / \rho_{710} \quad (2.23)$$

$$- \text{MCARI2} = (\rho_{700} - \rho_{670}) - 0.2 \cdot (\rho_{700} - \rho_{550}) \cdot (\rho_{700} / \rho_{670}) \quad (2.24)$$

$$- \text{TCARI} = 3 \cdot [(\rho_{700} - \rho_{670}) - 0.2 \cdot (\rho_{700} - \rho_{550}) \cdot (\rho_{700} / \rho_{670})] \quad (2.25)$$

- CCI – Chlorophyll Content Index: bizonyos mérőeszközök (például *Opti-Sciences*) a relatív klorofill-tartalmat határozzák meg, amit a 653 vagy 660 nm-es hullámhossztartományú fénysugár elnyelése alapján kalkulálnak, melyhez a 930, vagy 940 nm-es referenciát alkalmazzák. Mivel ez a levél fényáteresztésén alapul, ezért az adott hullámhosszoknak megfelelő transzmittancia értékeit használtam fel az index kalkulációja során.
- NPCI – Normalized Pigment Chlorophyll ratio Index: $(\rho_{680} - \rho_{430}) / (\rho_{680} + \rho_{430})$ (2.26)
- PSRI – Plant Senescence Reflectance Index: a növényi öregedést hivatott vizsgálni.

$$- \text{PSRI} = (\rho_{678} - \rho_{500}) / \rho_{750} \quad (2.27)$$

2.2.4.3.2 Vízüindexek

A klorofill-tartalom, illetve a tápanyagellátottság mellett a másik fontos kérdés általában a megfelelő vízellátottság. Ezt zárt rendszerekben könnyebb az automatizált rendszereknek szabályozni, de szabadföldön egyre fontosabb kérdésként felmerül a megfelelő és precíz öntözés. Különösen fontos mindez, ha még hozzávesszük az utóbbi pár év nyári időszakokban jellemző egyre nagyobb területeket és egyre hosszabb időszakokban súlytó aszálykárt is.

Számos olyan megoldás születik már, melyek például a meteorológiai adatok valós idejű elérése révén is igyekeznek csökkenteni a vízfelhasználás mennyiségét (pl. a *Gardenia* cég kiskertekre fejlesztett automata öntözőrendszereinek legújabb generációi).

A vízstressz detektálására a termális érzékelők is egyre gyakrabban felmerülnek, mivel ilyenkor a levelek felszínhőmérséklete szintén növekedni fog, mivel a párologtatás csökken. A termális érzékelők például szabadföldi rendszereknél is nagyban segíthetnek akár a belvíz előrejelzésében, hiszen a vízzel telítődő talajfelszín hőmérséklete is fizikailag alacsonyabban kell legyen, mint a kevésbé vízzel telített

talajé. De ezen logikát megfordítva nyáron az aszályosabb területek detektálására is alkalmas lehet, ezzel olyan automatizációkat elősegítve, mely akár egy drónnal lerepülve segíti az öntözőrendszerek diverzifikált működtetését, azokon a területeken bekapcsolva az öntözést, ahol egy bizonyos szint fölé emelkedik a felszínhőmérséklet. Ezen módszer még szintén kutatást igényel, hiszen a termális kamera ugyan jelezheti a stressz meglétét, de arról nem nyújt információt mi okozza ezen stresszt. Így a felvetésem elsősorban azokban a helyzetekben utalhat vízstresszre, amennyiben adott területet rendszeresen monitorozzák, így kizárható, akár a tápanyaghiány, és elsőre utalhat vízstresszre, míg ha öntözés után is jelentkezik a stresszet jelző emelkedettebb növényi felszínhőmérséklet, akkor inkább kártevőkre, kórokozókra fog utalni a termális eltérés.

A spektrális indexek abból az elvből indulnak ki, hogy a víz meghatározott hullámhosszokon erősen elnyeli az energiát, és ebből kifolyólag a korábbi kutatások különböző reflexiós indexeket javasoltak a növények víztartalmának előrejelzéséhez (Peñuelas et al., 1993; Gao, 1996, 1997; Serrano et al., 2000; Stimson et al., 2005). Gao (1996) a normalizált különbségű vízindexet (NDWI; $[\rho_{860} - \rho_{1240}] / [\rho_{860} + \rho_{1240}]$) javasolta a vegetatív víztartalom előrejelzéséhez, melyet elsősorban műholdképek értékelésekor alkalmaznak. Anderson et al. (2004) ezt az indexet használta a szójabab és a kukorica lombkorona víztartalmának meghatározására. Stimson et al. (2005) megállapította, hogy az NDWI és a normalizált vegetációs index (NDVI; $[\rho_{900} - \rho_{680}] / [\rho_{900} + \rho_{680}]$) szignifikáns összefüggést mutatott a levélvíztartalommal és a vízpotenciállal ($R^2 = 0,44-0,71$) két tűlevelű fajban (*Pinus edulis* és *Juniperus monosperma*). Zarco-Tejada & Ustin (2001, 2003) az egyszerű vízindexet (SRWI, ρ_{860} / ρ_{1240}) modellezte, hogy ezzel megbecsülje a növényzet víztartalmát a levélvastagság, a biomassza és a levélterület-index vonatkozásában.

A vízindexet (WI, ρ_{970}/ρ_{900}) Peñuelas et al. (1993) a *Phaseolus vulgaris*, a *Capsicum annuum* és a *Gerbera jamesonii* vízállapotának becslésére használták, és összefüggésbe hozták az RWC (relatív víztartalom, %) értékkel. A brokkoli növényekben (*Brassica oleracea var. italica*) a WI összefüggést mutatott a növények víztartalmának, valamint a teljes biomassza változásaival különféle „vízkezelések” során (El-Shikha et al., 2007). Babar et al. (2006) két normalizált vízindexet javasolt ($NWI_1 = [\rho_{970} - \rho_{900}] / [\rho_{970} + \rho_{900}]$ és $NWI_2 = [\rho_{970} - \rho_{850}] / [\rho_{970} + \rho_{850}]$) a Peñuelas által javasolt vízindex alapján. Vizsgálataikban ezen indexek jól korreláltak a tavaszi búza genotípusaiban a jól öntözött és vízhiányos, stresszes körülmények közötti labormérések eredményeivel. Prasad (2007) két további normalizált vízindexet ($NWI_3 = [\rho_{970} - \rho_{880}] / [\rho_{970} + \rho_{880}]$ és $NWI_4 = [\rho_{970} - \rho_{920}] / [\rho_{970} + \rho_{920}]$) javasolt, melyek szintén alkalmasak lehetnek ezen célú vizsgálatok során. Tanulmányában ez az öt vízindex (WI és négy NWI) megmagyarázta a gabonatermés változékonyságának nagy hányadát, és alternatív megközelítést jelentett a búza vízstressz körülményeinek előrejelzésére különböző környezeti paraméterek mellett (Babar et al., 2006; Prasad et al., 2007).

A vízindexek (WI) azon a feltételezésen alapulnak, hogy a NIR hullámhosszak (970 nm) mélyebben behatolnak a levelekbe, és ezért pontosan megbecsülik a víztartalmat (Babar et al., 2006; Prasad et al., 2007; Gutierrez et al., 2010). Ráadásul például a búzánál a WI-k és a szemtermés közötti összefüggést is meghatározták, mely azt jelzi, hogy a levelek víztartalma létfontosságú szerepet játszik a búza genotípusának hozamának meghatározásában optimális és kedvezőtlen növekedési körülmények között is (Babar et al., 2006; Prasad et al., 2007).

További vízindexek:

- WBI (Water Band Index): reciproka a vízindexnek. A növények víztartalmának növekedésével a 970 nm körüli abszorpció mértéke nő a 900 nm-hez képest. Mind a vízindex, mind pedig ezen index is ezt alkalmazza.
- NDWI: egyre gyakrabban használt távérzékelési vízindex, melynek előnye, hogy például műholdas távérzékelési adatok esetén kevésbé érzékeny az atmoszféra hatásaira, mint az NDVI index. (Gao, 1996)
- NDII: Az index érzékeny a növények víztartalmának változására, értékei -1 és 1 között mozognak, a víztartalom növekedésével nőnek. A zöld növényzet közös tartománya 0,02–0,6.
- MSI (Moisture Stress Index): Ahogy a levelek víztartalma nő, az abszorpció az 1599 nm körül növekszik. A 819 nm-es abszorpciót a víztartalom változása szinte nem befolyásolja, ezért referenciaként alkalmazzák. Az MSI magasabb értékei nagyobb vízstresszt és kevesebb víztartalmat jeleznek. Az indexnek az értéke ekkor 0 és 3 között mozog. A zöld növényzet közös tartománya 0,4–2 (Ceccato, P., et al., 2001).

Léteznek olyan tanulmányok is, melyek a talaj nedvességtartalmát jellemzik spektrális indexekkel. Ilyen célú gyakran használt index az NMDI index (Normalized Multi-band Drought Index), mely három specifikus sávot alkalmaz, mivel ezek egyedülállóan reagálnak a talaj és a növényzet nedvességének változásaira. Az index a közép távoli infravörös tartományban (SWIR) (1640 és 2130 nm) két vízabszorpciós sáv közötti különbséget használja a vegetáció és a talaj vízerzékenységének mérésére. A talajnedvesség növekedésével az indexértékek csökkennek, száraz talaj esetén 0,7 és 1 között, közepes nedvességtartalmú talaj esetén 0,6 és 0,7 között, nedves talaj esetén pedig kisebbek, mint 0,6. (Wang, L., 2008).

2.2.4.3.3 Nitrogén-indexek

A távérzékeléssel történő N monitorozással már számos kutatás foglalkozott, és több spektrális indexet igazoltak már, melyek megfelelően korreláltak a növények nitrogéntartalmával. A leggyakrabban alkalmazott ezen célú vegetációs index az NDVI index (Rouse et al., 1974), melyet a korábbiakban már bemutattam. Emellett számos, különböző diagnosztikai hullámhosszon alapuló, NDVI-szerű indexet dolgoztak ki a növények N monitorozására. Ranjan et al. (2012) például búzanövények spektrális reflexiók mintázatának változásait tanulmányozták különböző fenofázisokban, különböző N

stresszszintek mellett. Megállapították, hogy a spektrális reflexiós minta a változó N stressz szintek szerint különült el, azaz korrelált.

Egyedi nitrogénszenzorok is elérhetőek a piacon, melyek közül a legismertebbek a *Yara* cég termékei. Legtöbbször az NDVI indexszel szokták jellemezni és vizsgálni a növények nitrogéntartalmát. Kutatásomban az M5 számú mellékletben összefoglalt spektrális indexeket vizsgáltam meg.

Más megközelítésben a növényi stresszt vizsgáló kutatások is leírták már, hogy különböző stresszorok hatására fellépő válaszreakciók során a növényekben jellegzetes fluoreszcencia sajátosságokkal rendelkező metabolitok is felhalmozódnak. Ezek általában olyan anyagok, melyek a kék és a zöld tartományban emittálnak. A stresszorok közvetve, vagy közvetlenül a fotoszintetikus apparátus módosulását, vagy akár károsodását is okozhatják, ezért a legfontosabb fotoszintetikus pigment, a klorofill-a fényelnyelésének jellemzőit is megváltoztatják. Például nitrogénhiány esetén megfigyelték, hogy a kék és piros tartományban történő fényelnyelés aránya megváltozik. Ehhez a 440, illetve 690 nm-es tartományban történő fényelnyelés arányát vizsgálják. Az elv abból indul ki, hogy az egészséges növény fényelnyelésének aránya a 11. ábra szerint jellemezhető, mivel a fotonsűrűség magasabb a piros fény esetén, így az arány egy alacsonyabb érték, míg stresszhelyzetben a kisebb piros tartományú fényelnyelés az arányszám értékének emelkedésével jellemezhető.



11. ábra - Növények fényelnyelésének aránya

A fentiek mellett a 690/740 nm arány is nagyobb lesz, mely arány az in situ klorofilltartalom inverz indikátora is egyben. Összességében elmondható, hogy a fiziológiai állapotváltozások a különböző reflexiós arányokban (SR 440/690 nm, SR 440/740 nm, SR 690/740 nm) jól tükröződnek, ezért ezeknek a mutatóknak nagy diagnosztikai jelentősége van a stresszhelyzetek kimutatásában.

Ezen indexeknél leírják, hogy a növényházban nevelt növények esetében a mesterséges fényviszonyok, vagy az üvegburkolatok miatt alacsonyabb UV hányadot kapnak, s emiatt a szabadföldi növényeknél kevesebb fotoprotektív anyagot halmoznak fel az epidermiszben. Ezen kívül a hőmérséklet is hatással van az index arányára. Esetemben egységes körülmények jellemezték a növényeket, ezért hipotézisem alapján alkalmasak lehetnek a nitrogén tartalom változásának előrejelzésére, illetve a víztartalom változásának előrejelzésére.

Ezen hullámhosszakokat és arányokat a fluoreszcens spektroszkópia alkalmazza leggyakrabban. Az arányok változását elsősorban az alábbi táblázat szerint súlyozza a szakirodalom.

4. táblázat - A kék/vörös (440/690), kék/távoli vörös (440/740), vörös/távoli vörös (690/740) és kék/zöld (440/520) arányok, mint stressz indikátorok mértékének változásai különböző stresszorok hatására a kezeletlen növényhez képest. ++ = jelentősen magasabb, + = magasabb, -- = jelentősen alacsonyabb, - = alacsonyabb, 0 = nincs szignifikáns változás (Forrás: Buschmann et al., (2000) nyomán, kiegészítve Szigeti et al., (2008))

stresszor	SR440/690	SR440/740	SR690/740	SR440/520
vízhiány	++	++	0	0
nitrogénhiány	++	++	+	0
erős fény	++	++	+	--
levéltetű szúrás	++	++	0	+
levélrozsda fertőzés	++	++	++	-
hőstressz	--	--	0	-
UV-A stressz	--	--	0	+
fénygátlás	++	++	--	0
kadmium stressz	+	+	+	-

2.2.4.3.4 Kálium-, és foszfortartalommal összefüggést mutató spektrális indexek

A precíziós gazdálkodás egyik fő célja a racionális trágyázási gyakorlatok kidolgozása terepi szinten, ezzel a gazdasági teljesítmény maximalizálása és a környezetre gyakorolt káros hatások csökkentése. Az intenzív növénytermesztés elmúlt időszakában jellemző túlzott igénybevétel révén a talajokban kimerültek az olyan makro-tápanyagok, mint az N, P, K. A növények esszenciális tápanyagainak monitorozására szolgáló hagyományos módszerek részletes mintavételt, időt és költséges laboratóriumi kémiai elemzéseket igényelnek, ami gazdaságilag is megterhelő, de időben is nehézkes, pláne, ha a minták nagy léptékben történő vételezését is figyelembe vesszük. Mire mindezen hagyományos rendszerek alapján a növényi tápanyaghiány tünetei világosan láthatóvá válnak, számos fizikai folyamatot már elindított a tápanyag-stressz (Zhao et al., 2003). Egy ilyen helyzet arra ösztönzi a mezőgazdaságot, hogy olyan hatékony technikákat és gépeket alkalmazzon, amelyek gazdaságilag életképesek és környezetkímélők. Ebben az összefüggésben a növényi tápanyag-koncentrációra vonatkozó kvantitatív információkra van szükség a tápanyag-kijuttatási alkalmazások valós idejű kezeléséhez (Stropiana et al., 2009).

A növényi tápanyagutánpótlás másik két fontos anyaga a nitrogén mellett a kálium, illetve a foszfor. Adott tápanyag hiánya ráadásul korlátozó tényezőként jellemzi más tápanyagok felvételét (Liebig-féle minimum-elv). Míg a nitrogén esetén már számos tanulmány ajánl különböző indexeket, addig a K-P előrejelzésére kevesebb tanulmány áll egyelőre rendelkezésre.

Osborne et al. (2002) lineáris regressziós modelleket használt, amelyek a kukorica (*Zea mays L.*) P-koncentrációjának előrejelzéséhez a 730 és 930 nm-en reflektanciát adták legjobb eredményül. Ugyancsak jelentős spektrális választ figyeltek meg a NIR régióban P hiányos kukoricában. Pimstein et al. (2011) a búza lineáris korrelációs elemzését használva azonosították a P és K érzékeny hullámhosszúságú régiókat. Eredményeik azt mutatták, hogy az újonnan javasolt keskeny sávú vegetációs indexek $N_{1645_1715} = \frac{\rho_{1645} - \rho_{1715}}{\rho_{1645} + \rho_{1715}}$ és $N_{870_1450} = \frac{\rho_{870} - \rho_{1450}}{\rho_{870} + \rho_{1450}}$ korreláltak leginkább a búzában a P és K koncentráció értékeivel. Ezen új indexek nagyobb pontosságot értek el a P és K szint becslésében, mint a hagyományos vegetációs indexek, például NDVI, Green NDVI (GNDVI), Simple Ratio (SR), SAVI és OSAVI. Ez a tanulmány megmutatta az új spektrális algoritmusok azonosításának és fejlesztésének lehetőségét is a N és a N-től eltérő tápanyagok monitorozására.

Számos tanulmány leírta, hogy a makro-tápanyaghiány csökkentette a levelek klorofill-tartalmát és növelte a reflexiót a 400–700 nm-ben (VIS), illetve a 700–1200 nm-ben (NIR).

Ferwerda és Skidmore (2007) bemutatták a hiperspektrális távérzékelés lehetőségét az alapvető tápanyagok, például N, P, Ca, K, Na, Mg koncentrációjának előrejelzésében négy fás növényben. Megfigyelték azt is, hogy a vörös él helyzete eltolódik a rövidebb hullámhosszak felé a vizsgált tápelemek esetében.

Mások az 1645 és 1715 nm-es SWIR tartományú spektrális reflexiós tartományt vizsgálták a P monitorozáshoz, valamint a 870 nm (NIR) és 1450 nm (SWIR) tartományt a K monitorozásához búzanövényeknél. A SWIR régióban a hullámhosszak használatának legfőbb előnye, hogy azok a vízabszorpciós sávokon kívül helyezkednek el, és nincs nagy hatással rájuk a szokásos aeroszolok, például füst vagy szulfátok (Pimstein et al., 2011).

2.2.4.3.5 Többváltozós és kombinált modellek

A vegetációs indexeket kifinomultabb többváltozós modellekben használhatjuk fel, például egyre gyakrabban alkalmazzák lépésenként a többszörös lineáris regressziót (MLR) (Thenkabail et al., 2000; 2002), a főkomponens elemzést (PCA) (Atzberger et al., 2010; Thenkabail et al., 2004), a PLS-R elemzést (Nguyen et al., 2006), a mesterséges ideghálózati modellt (ANN) (Atzberger, 2004; Miao et al., 2006) és egyéb vektoros megoldást (Verrelst et al., 2012). Azért érdemes szem előtt tartani, hogy mind a spektrális indexeknek, mind pedig a többváltozós modelleknek megvannak az előnyei és hátrányai. Ezért többféle és integrált módszerre van szükség a növényi tulajdonságok legjobb előrejelzéséhez, hogy a növényi fejlődés dinamikája idővel szabályozható legyen. Vannak további spektrális elemzési módszerek, például a vörös él helyzetének vizsgálatára épülő technikák (Dawson & Curran, 1998; Guyot & Baret, 1988; Miller et al., 1990; Pu et al., 2003) és a kontinuum eltávolítás elemzése (Huang et al., 2004). Mindezek az empirikus módszerek megmutatták a távérzékelés alkalmazásának hasznosságát és lehetőségeit a mezőgazdaságban, bár a mögöttes mechanizmusokat még mindig nem teljesen írják le. Egyre több szakirodalom utal arra, hogy a PLS-R (parciális legkisebb négyzet) módszer segíti a legjobban az

„érzékenyebb” spektrális területek detektálását. Egyes kutatók felvetették, hogy a módszert „Projection to Latent Structures” (Vetítés látens struktúrákra) jelentéssel töltsék meg, ami jobban utal a módszer lényegére.


A fizikai sugárzási transzfer modellek (RT) ezzel szemben a fény és a levelek/növények és más lombkorona szerkezeti kölcsönhatásának megértését igyekeznek elérni (Jacquemoud et al., 2009). Számos RT modellt fejlesztettek ki az elmúlt időszakban, például a levelek modellezéséhez a PROSPECT-et (Jacquemoud & Baret, 1990), a LIBERTY-t (Dawson et al., 1998) és a SAIL lombkorona modellt (Verhoef, 1984). Ezen modellek a növény biokémiai és fizikai tulajdonságainak figyelemmel kísérésére alkalmas modellek, melyek futtathatók előrejelző és inverz módon is (Jacquemoud et al., 2000). RT modellek előrejelző módban történő alkalmazása során lehetővé teszik egy nagy adatbázis létrehozását, amely a bemenő változók kombinációinak széles skáláját fedi le, amelyek vezérlik a kapott reflektancia spektrumokat (Féret et al., 2011). Ebben a módban a reflektancia sávokra reagáló biokémiai vagy biofizikai tulajdonságok változói tanulmányozhatók, ami hasznos a spektrális indexek azonosításához és finomításához, így idővel alkalmasak lehetnek a vegetáció biokémiai vagy fizikai paramétereinek becslésére.

Az RT modellek inverz módban történő futtatása lehetőséget kínál a természetjellezők lekérdezésére a hiperspektrális reflexiós adatokból 400-2500 nm tartományban. Például több modell összekapcsolásával alkalmazzák erre a célra a PROSAIL modellt (PROSPECT + SAIL) (Jacquemoud & Baret, 1990; Jacquemoud, 1993; Verhoef, 1984). Normális esetben a PROSAIL inverziója háromféle módon hajtható végre (Jacquemoud et al., 2006): (1) numerikus inverzió (Botha et al., 2007), (2) keresési táblázat (Darvishzadeh et al., 2012) és (3) felügyelt tanulási megközelítések, pl. klasszifikációs módszerek vagy ANN (Atzberger, 2004).

Az empirikus és fizikai módszerek kombinálásához az RT-modellek előre történő futtatásával kapott növényi reflexiós spektrumok szimulációit alkalmazták a növényzet spektrális indexeinek kidolgozására és finomítására a növény biokémiai paramétereinek előrejelzésének céljából. Például a lombkorona reflektanciáját (CanRefl) a PROSAIL modell segítségével szimulálhatjuk 13 db bemeneti paraméterrel: klorofill-tartalom (C_{ab}), karotinoidok (C_{ar}), levél ekvivalens víztartalom (C_w), szárazanyag-tartalom (C_m), levélfelület-index (LAI), átlagos levélszög (ALA), forró pont paraméter (H_{spot}), a diffúz beeső sugárzás ($skyl$), a talajvisszaverődés (R_s), a szolár zenit szög (θ_s), a nézet zenit szög (θ_v) és a relatív azimut szög (φ_{sv}), amelyek látható az alábbi összesítő formulában:

$$CanRefl = PROSAIL(C_{ab}, C_{ar}, C_w, C_m, N_{stru}, LAI, ALA, H_{spot}, skyl, R_s, \theta_s, \theta_v, \varphi_{sv}) \quad (2.28)$$

Az alábbi ábrán láthatunk egy szimulációt, hogy hogyan változik a szimulált lombkorona reflexiója a LAI variációkkal.



12. ábra - PROSAIL modell révén becsült eltérő reflektancia görbék eltérő LAI indexek szerinti alakulása (a modell során alkalmazott bemeneti paraméterek: $C_{ab}=30 \mu\text{g cm}^{-2}$, $C_{ar}=0$, $C_w=0.01 \text{ cm}$, $C_m=0.005 \text{ g cm}^{-2}$, $N_{stru}=1.5$, $ALA=\text{spherical}$, $H_{spot}=0.25$, $skyl=0.23$, $\theta_s=30$)

A kombinált módszer fő előnye, hogy segíti a különféle spektrális jellemzők és vegetációs indexek kidolgozását, módosítását és tesztelését, valamint segíti azon vizsgálatokat, melyek célja azon folyamatok megértése, hogy az eltérő biokémiai és biofizikai jellemzők hogyan befolyásolják a lombkorona tükröződését. Idővel ezen kombinált modellek arra is alkalmasak, hogy például egy automatizált rendszert vezéreljenek. Ehhez előbb tisztázni kell (a fentiekén túl) a paraméterek egymásra való hatásait is, illetve, hogy növényfajonként a vegetáció előrehaladtával mi az a maximum, amit el lehet majd érni.

A fentiekén túl számos szoftver (*QGIS – Spectral viewer*, *ORFEO Toolbox*, *SCP plugin*, *Matlab – Spectral Toolbox*, *R* programcsalád számos modulja, *SAS – MAX-R* modul) alkalmas a távérzékelési adatok kiértékelésére. Mindezen szoftverek és az utóbbi években hozzájuk fejlesztett moduljaik is mutatják, hogy napjainkra óriási figyelem fordult a távérzékelési adatokra, viszont ezen óriási adatmennyiség megfelelő feldolgozása adott esetekben szintén új módszereket és matematikai megoldásokat igényel.

2.3 Roncsolásmentes növényvizsgálati módszerek és eszközök

Napjaink növénytermesztésében a növényi fejlődés nyomon követése, illetve a növényi megbetegedések korai és pontos felderítése, diagnosztizálása kulcsfontosságú tényező a minőségi és mennyiségi veszteségek csökkentése céljából. Az optikai technikák, mint az RGB képalkotás, a multi- és hiperspektrális érzékelők, a radar eszközök, a termográfia vagy a klorofill fluoreszcencia, automatizált, objektív és reprodukálható detektáló rendszerekben bizonyították potenciáljukat a növényi fiziológiai állapot azonosítására és mennyiségi. A közelmúltban 3D-s szkennelést is társítottak optikai elemzésként, amely további információkat szolgáltat a növényi vitalitásról.

Az egyes növényi szervek vagy teljes mezők többszörös megfigyelésére különféle platformok állnak rendelkezésre a proximálistól⁴ a távérzékelésig. A növényi vitalitás pontos és megbízható

⁴ proximális érzékelés: magában foglalja a növények közvetlen közelében lévő érzékelők használatát, például traktoron, betakarítógépen, földi roboton, illetve közeli állványokra vagy levélklipszre elhelyezve

felderítését rendkívül kifinomult és innovatív adatelemzési módszerek teszik lehetővé, amelyek az összetett növényi rendszereket érzékelve adatokat szolgáltatnak, és új információkhoz vezetnek. A roncsolásmentes, érzékelő-alapú módszerek támogatják a növényi vitalitás vizuális és/vagy molekuláris elemzését, illetve elősegítik a térbeli és időbeli modellezést.

A szenzor-alapú elemzések legfontosabb alkalmazási területei a precíziós mezőgazdaság, a növény fenotipizálás, illetve a növényvédelem. A precíziós mezőgazdaság és a növényi fenotipizálás olyan információs és technológiai alapú területek, amelyek speciális igényeket és kihívásokat jelentenek a növénytermesztési szakágaktól. Olyan termény-gazdálkodási rendszer elérése a cél, amely a területen belüli termés- és talajfaktorok térbeli és időbeli változékonyságán alapul (Stafford 2000). Ezen rendszer célja, hogy valós idejű feltérképezési rendszereket érjen el a növényi, talaj- és környezeti változók számára, és ezzel megkönnyítse a döntés irányítást. (Hillnhütter és Mahlein 2008). Az optikai érzékelési technikák hasznosak az elsődleges vitális vizsgálatokhoz, illetve a hatásterületek azonosításában, segítve a heterogén eloszlás feltérképezését (Franke és Menz 2007).

A fejlett adatelemzési módszerekkel kombinálva ezeket a technikákat a fenntartható növénytermesztés programjaira is felhasználhatják. A tápanyag-visszapótlás, illetve a peszticidek, de akár az öntözés helyspecifikus és célzott alkalmazása a pontossági növénytermesztési-, és növényvédelmi stratégiák szerint ezen anyagok felhasználásának potenciális csökkenését eredményezik, ezáltal csökkentve a mezőgazdasági költségeket, illetve a mezőgazdasági növénytermesztési rendszerek káros ökológiai hatásait (Gebbers és Adamchuk 2010).

Míg a precíziós mezőgazdaság célja a növényi állományok térbeli heterogenitásának vizsgálata, a növény fenotipizálás egy genotípus megjelenését és teljesítményét különböző környezeti feltételek mellett értékeli. A növénynevelés során nagyszámú különböző genotípust tesztelnek a betegség és az abiotikus stressz-ellenállás, a hozam, a termékminőség és sok másodlagos tulajdonság esetében (Fiorani és Schurr 2013). A betegség ellenálló tenyésztés során a gazdaszervezet patogén kölcsönhatásait és a nemesítési anyagok érzékenységét kell hatékonyan értékelni. A célzott növényi anyagot genotipizálással és fenotipizálással kell vizsgálni. Különösen a növény fenotipizálás munkaerő és időigényes, ezért meglehetősen költséges. A közelmúltban a fenotipizálás gyakran szinonimája lett a nem invazív képzőanyag és az anatómiai, fiziológiai és biokémiai növényi tulajdonságok érzékelő-alapú elemzésének (Guo és Zhu 2014, Walter et al., 2015).

Az objektív, megbízható és automatikus diagnosztika és felderítés érdekében új megközelítéseket kell bevezetni és beépíteni a hagyományos felületei és minősítési rendszerekbe. Egyre több képzőanyag és egyéb szenzor áll rendelkezésre, melyek támogatják a fenti célokat.

Az optikai szenzorok általános hátránya, korlátja az összegyűjtött adatok nagy mennyisége és összetettsége. Annak érdekében, hogy hatékonyan felhasználhassuk az optikai szenzorok adatait, elengedhetetlen a fejlett adatelemzés és statisztikai módszerek alkalmazása. Az adatoknak számos fontos

tényezőt kell tartalmaznia: (a) a vitalitás, illetve a betegségek korai felismerését, (b) a különböző változók közötti differenciálódást, (c) az abiotikus stressz okozta elváltozások elválasztását, és (d) a mennyiségi meghatározást, avagy a betegség súlyosságát. Ezeket a paramétereket a standard értékelési módszerekkel és rövidebb számítási idővel elérni kívánt pontossággal magasabb, vagy azzal egyenértékű szinten kell értékelni. Ebben az összefüggésben az adatbányászati módszerek folyamatosan kerülnek bevezetésre a növénytudományban, és kulcsfontosságú technológiává válnak.

A mérőműszerek általában a spektrum egy vagy több részét felvételezik. Az eltérő energia kölcsönhatásokat fel tudják ezzel ismerni, így a heterogenitást jobban felmérhetik (Engler, 2014).

2.3.1 Roncsolásmentes vizsgálatok múltja és jelene

A növényi vitalitás, illetve a megbetegedések diagnózisának és kimutatásának közös módszerei közé tartoznak a vizuális szemrevételezés, a kórokozók azonosítására szolgáló morfológiai jellemzők mikroszkópos értékelése, valamint a molekuláris, szerológiai és mikrobiológiai diagnosztikai technikák (Bock et al., 2010; Nutter, 2001). Az utóbbi évtizedekben a DNS-alapú és a szerológiai módszerek forradalmasították a kórokozók és a betegségek azonosítását és számszerűsítését (Bock et al., Martinelli et al., 2014; Ward et al., 2004).

Ezek a tesztek közvetlenül alkalmazhatók a mezőn, az üvegházban vagy a termelési láncban a releváns növényi kórokozók értékelésére és azonosítására (pl. ELISA) (Danks & Barker, 2000).

A hagyományos, vizuális szemrevételezés a betegség jellegzetes növényi betegség tüneteit (pl. a különféle elváltozások, penészedés, hólyagok, daganatok, férgesedés, hervadás, rothadás), vagy a kórokozó látható jeleit (pl. *Pucciniales*, micélium vagy *Erysiphales conidia*) keresi. A vizuális becslést szakképzett szakértők végzik (Bock et al., 2010; Nutter, 2001). Mindazonáltal a vizuális becslés mindig egyéni tapasztalatnak van kitéve, az időbeli eltérés befolyásolhatja, és olykor nem megoldható a terület teljes bejárása. (Bock et al., 2008, 2010; Newton & Hackett 1994; Nutter, 2001; Nutter et al., 1993; Steddom et al., 2005). Emellett időigényes, költséges, és képzett szakembereket igényelnek.

Riker & Riker 1936-ban úgy fogalmaztak, hogy a vizuális szemrevételezésnél jobb diagnosztikai módszerekre van szükség, egyiket sem lehet szabványosítottnak tekinteni. Ezek miatt csak addig használhatók, amíg jobb eljárásokat nem lehet kidolgozni. Ezen vélemény sokak szerint ma is igaz. Új és innovatív technikára van szükség a mezőgazdasági termelés következő kihívásainak és tendenciáinak kezeléséhez, amelyek a fogyasztói felügyelet miatt nagyobb pontosságot igényelnek, mint valaha. Ezért a nagyfokú érzékenységgel és megbízhatósággal rendelkező új és automatizált módszerek szükségesek a vitalitás vizsgálatokhoz, illetve a betegség kimutatásának javítása érdekében.

Az intenzív kutatások a közelmúltban új, szenzor alapú módszereket határoznak meg a növényi vitalitás és megbetegedések kimutatására, azonosítására és mennyiségi meghatározására (Hillnhütter, 2010; Mahlein et al., 2012). Ezek az érzékelők felmérik az elektromágneses spektrum különböző tartományain a növények optikai tulajdonságait, és képesek a látható tartományon kívüli információk

felhasználására. Lehetővé teszik a biotikus stresszek miatti korai növényi fiziológiai változások kimutatását, mivel stressz hatására módosulhat a szöveti szint, a levél alakja, a transzpirációs sebesség, a növény morfológiája és a növényesűrűség (West Et al., 2010).

Jelenleg a legígéretesebb technológiák olyan érzékelők, amelyek mérik a reflexiót, a hőmérsékletet vagy a fluoreszcenciát (Van der Straeten, 2000).

A növénytudományokban a távérzékelés adhat olyan módszert, amely a közvetlen érintkezés nélkül, növényekről származó adatok beszerzésére szolgál. A koncepciót a közelmúltban bővítették a növényi anyagok proximális, szűk tartományú, illetve kis léptékű érzékelésével (Chaerle & Van der Straeten, 2000; Mahlein et al., 2012; Oerke et al., 2014). Ezek az érzékelők több platformra is telepíthetők (digitális mikroszkópok, traktorok, hordozók, robotok, nagy teljesítményű platformok, UAV-k, repülőgépek, műholdak stb.), vagy helyhez kötött érzékelők is elhelyezhetők stratégiai pontokon. Ezen szenzorok használatakor figyelembe kell venni az egyedi előírásokat és feltételeket.

2.3.2 A távérzékelés fontosabb eszközei

A távérzékelési szenzorokat érzékelőik alapján az alábbi nagyobb csoportokra oszthatjuk (13. ábra).



13. ábra – Jelenlegi szenzor technológiák

2.3.2.1 RGB fotográfia

A digitális fotográfiai képek fontos eszközök a növényi fiziológiai állapot értékeléséhez. A digitális fényképezőgépek könnyen kezelhetők, az RGB (piros, zöld és kék) spektrális tartományban rögzítik az adatokat. Ezeknek az egyszerű, kézi eszközöknek a műszaki paraméterei, például a fényérzékenység, a térbeli felbontás vagy az optikai és digitális élesség jelentősen javult az utóbbi években. Ma szinte minden ember, gazdálkodó vagy fitopatológus, modern és kifinomult digitális fényképezőgép-érzékelőket hordoz mobiltelefonnal vagy táblagéppel, számítógéppel. A videokamerák, vagy szkennerek alternatív módszerek a különböző növényi szervek digitális képeinek felmérésére, a gyökerektől a virágzatokig.

A vörös, zöld és kék csatorna RGB színes képét alkalmazták a biotikus stressz kimutatására a növényeknél (Bock et al., 2010). Az RGB, LAB (L a világosság és az A és B a szín-ellentét dimenziói, nemlineárisan tömörített koordinátákon alapulva), YCBCR (színkompressziós séma, az Y a fényerő

komponens, a CB és CR a kék különbség és a vörös-különbség színtelítettségi komponensek), vagy a HSV (színárnyalat, telítettség, érték) szintér, a térbeli információk a növényi vitalitás fontos jellemzőit mutatja (Bock et al., 2010). Továbbá a színek, a szürke szintek, a textúra, a diszperzió, a kapcsolódási és az alakparaméterek definiálhatók adott betegség tüneteinek kimutatásában és azonosításában (Camargo & Smith, 2009; Neumann et al., 2014). Számos kutatócsoport használt minta-felismerési módszereket és gépi tanulást az RGB-képekből származó növénybetegségek kimutatására és azonosítására (Camargo & Smith, 2009; Neumann et al., 2014). Ráadásul az RGB-képek lényeges tulajdonságainak szisztematikus kiválasztása növeli a besorolási pontosságot (Behmann et al., 2014).

A digitális képelemzés napjaink egy jól bevált technológiája. Számos szoftvercsomag áll rendelkezésre (például az ASSESS 2.0, a "Leaf Doctor", a Scion Image szoftver és az egyéni modulok) (Bock et al., 2010; Pethybridge & Nelson, 2015; Tucker & Chakraborty, 1997; Wijekoon et al., 2008). Az ASSESS 2.0-ban a képek színeloszlását hisztogramokban analizálják, amelyek alapul szolgálnak a későbbi küszöbértékek meghatározásához (Lamari, 2008). Ezenkívül a betegség súlyossága beteges képpontokként vagy százalékos arányként elkülöníthető, miután a háttér maszkolja a tárgyat. Az ASSESS 2.0 nagyon praktikus a betegség súlyosságának megállapításához egyetlen levélen és jól elrendezett képeknél. Különös figyelmet kell fordítani viszont a „képgyűjtési” lépésekre. Az egységes fókusz, az élesség és a megvilágítás döntő fontosságú a nagy pontosság és az automatizált képelemzés megbízható eredményeihez. Továbbá természetes körülmények között a képszög (levél tájolása), a tárgy és az érzékelő (képpontméret) közötti távolság további hatással van a képminőségre. Az észlelési nehézségek és a pontosság alacsony szintje gyakran a heterogén körülmények és az alacsony képminőség következménye. Az ASSESS 2.0 legfontosabb elve egy jól szabványosított képalkotási eljárás, amely megismételhető eredményeket hoz.

2.3.2.2 Multi- és hiperspektrális reflexiós érzékelők

A spektrális szenzorokat általában a spektrális felbontás (azaz a mért hullámsávok száma és szélessége) alapján, a térbeli skála alapján és az érzékelő típusa (azaz képalkotó-, vagy nem képalkotó rendszerek) alapján csoportosítják. A multispektrális érzékelők az első spektrális érzékelők voltak. Ezek az érzékelők általában viszonylag széles hullámsávokban értékelik az objektumok spektrális információit. A multispektrális képalkotó kamerák például az R, G és B hullámsávokban és egy további infravörös sávban szolgáltathatnak adatokat. A modern hiperspektrális szenzorok fejlődése megnövelte a 350-2500 nm spektrális tartományban a mért adatmennyiséget, adott esetben 1 nm alatti szűk spektrális felbontással (Steiner et al., 2008). Ellentétben a nem képalkotó szenzorokkal, amelyek átlagolják a spektrális információt egy adott területen, a hiperspektrális képalkotó szenzorok spektrális és térbeli információt szolgáltatnak a képen lévő tárgyról. A hiperspektrális adatokat mátrixokként lehet megfigyelni térbeli x- és y-tengelyekkel, és a spektrális információt hullámhosszanként ábrázolja a harmadik dimenzióban. A térbeli felbontás erősen függ az érzékelő és az objektum közötti távolságtól.

Így a levegőben vagy térben elterjedt, messzemenőig terjedő rendszerek alacsonyabb térbeli felbontással rendelkeznek, mint a közeli vagy mikroszkopikus rendszerek. A térbeli felbontás erősen befolyásolja a növényi vitalitás, a megbetegedések vagy a növényi kórokozók kölcsönhatásainak kimutatását (Mahlein et al., 2012; West et al., 2003). A levegőben lévő érzékelők alkalmasak a talajban élő kórokozókkal fertőzött (Hillnhütter et al., 2011), vagy a betegség későbbi stádiumaiban megbetegedett terepi foltok kimutatására (Mahlein et al., 2012).

Az 1 m-es térbeli felbontással rendelkező érzékelők nem alkalmasak egyedszintű tünet, vagy 11 beteg levél kimutatására; Itt a proximális érzékelőplatformok előnyösek (Oerke et al., 2003). A több vizsgálat ellenére az innovatív hiperspektrális képalkotó rendszerek használata a növényi patológiában és a betegség súlyosságának vizsgálatában még mindig kutatási szakaszban van (Bock et al., 2010). A levelek optikai tulajdonságait az alábbiak jellemzik: a.) Fényáteresztés levélen, b.) Levélkémiai anyagok (pl. pigmentek, víz, cukrok, lignin és aminosavak) által abszorbeált fény és c.) a belső levélszerkezeten vagy közvetlenül a levélfelületen visszavert fény. Tehát a növények fényének visszaverődése összetett jelenség, amely számos biofizikai és biokémiai kölcsönhatáson alapul. A látható tartomány (VIS 400-700 nm) főként a levél pigment-tartalmától függ, a közel infravörös reflektancia (NIR 700-1100 nm) a levél szerkezetétől, a belső szórási folyamatoktól és a levél víztartalmától. A rövidhullámú infravörös tartományt (1100-2500 nm) a levél víztartalmának kémiai összetétele befolyásolja (Carter & Knapp, 2001; Jacquemoud & Ustin, 2001). A növényi vitalitás megváltozásának és a növényi megbetegedések következtében fellépő reflexiós változások magyarázata a szövetek levélszerkezetének és kémiai összetételének károsodása, ezek között specifikus hatások is megfigyelhetők, pl. a klorotikus és nekrotikus szövetek szukcessziója vagy tipikus gombás szervezetek megjelenése, mint pl. lisztharmat hifák és konídiumok vagy rozsda uredospórák.

Mahlein et al. (2010, 2013) demonstrálta a cukorrépa lombzat kórokozóinak differenciálódását a levél reflexió alapján. Ezekre az eredményekre alapozva, Rumpf et al. (2010) a látható tünetek megjelenése előtt képes volt a korai *Cercospora* levélfoltot, a lisztharmatot és rozsdaganatos cukorrépakat felismerni. Más növényi kórokozó rendszerekben a spektrális adatok szintén hasznosnak bizonyultak, például a *Fusarium graminearum* a búzában (Bauriegel et al., 2011), a *Venturia inaequalis* almánál (Delalieux et al., 2007) vagy a *Phytophthora infestans* paradicsomban (Wang et al., 2008).

A proximális vizsgálatban a hiperspektrális képalkotás is hasznosnak bizonyult a mikotoxint termelő kórokozók megítéléséhez (Del Fiore, 2010). Továbbá Bravo et al. (2003) a sárga rozsda fertőzött búza korai kimutatására szolgáló helyszíni spektrális képeket használt. A talajfertőzött betegségeket sikeresen elkülönítette Hillnhütter et al. (2011), akik a fonálféreg *Heterodera schachtii* és a *Rhizoctonia solani* gombafertőzése által okozott tüneteket vizsgálják a cukorrépa-mezőkben. A cukornádban végzett munkáiban Apan et al. (2004) az EO-1 *Hyperion* hiperspektrális képalkotással képesek voltak a narancs rozsdásodást kimutatni. Később Huang et al. (2007) a búzában lévő sárga rozsda megbízható és pontos

detektálását mutatta be talajon spektrális mérések és hiperspektrális képalkotás segítségével. A növényi megbetegedések felismerése mellett a hiperspektrális képalkotást széles körben használják a gyümölcsök egészségének és minőségének ellenőrzésére. A citrusfélék (Qin et al., 2009), az alma felszíni hibái (Mehl et al., 2004) vagy a szamóca rothadása (ElMasry et al., 2007) a hiperspektrális képérzékelőkkel azonosítható. Ezek a technikák fontosak a gyümölcsök és a növények szűrésénél a tárolási betegségek elkerülése érdekében.

2.3.2.3 Spektoradiométer

A spektoradiométerek általános felépítése: sugárforrás, monokromátor, érzékelő, erősítő és regisztráló rendszer. A sugárforrások lehetnek mesterségesek vagy természetesek. A felszín, a kémiai paraméterek és a sugárzás hőmérséklete nagyban hat a minta energia kibocsátására (Kissné, 1974; Tóth et al., 2011). Az elektromágneses polikromatikus, azaz több hullámhosszú sávokból álló, sugárzást egy fényfelbontó egység, a monokromátor (prizma, rács), alkotóira bontja szét.

A spektoradiométerek esetén általában két detektort találhatunk meg, a szilícium-alapú detektorok 200-1100 nm között érzékenyek, míg az InGaAs-alapú detektorok 900-1700 nm-re (vagy hűtéssel 2500 nm-re) érzékenyek.

Ezáltal a spektoradiométerek elsősorban pontszerű mérést, 1 vagy 0,5 nm-es felbontású spektrumot rögzítenek (mért tartományuk detektoroktól függően 200 nm-től – 1100 nm-ig vagy 2500 nm-ig terjed).

Jellemzőire és használatára a későbbiekben még részletesebben kitérek.

2.3.2.4 Termális kamerák

Az infravörös termográfia (IRT) felméri a növényi hőmérsékletet, ami jól korrelál a növényvíz állapotával (Jones et al., 2002), a növényi állományok mikroklíma (Lenthe et al., 2007), valamint a növényi kórokozók korai fertőzéseinek köszönhető transzpirációs változásokkal (Oerke et al., 2006). A termikus infravörös tartományban 8 és 12 μm közötti infravörös sugárzást termográfiai és infravörös kamerákkal lehet kimutatni, és hamis színes képeken ábrázolhatók, ahol minden egyes kép pixel tartalmazza a mért tárgy hőmérsékleti értékét. A növénytudományban az IRT különböző időbeli és térbeli méretekben alkalmazható a levegőből mérve, vagy terepi spektroszkópiában egyaránt. Azonban, gyakran a környezeti tényezők befolyásolják, például környezeti hőmérséklet, napfény, csapadék vagy szélsébség.

A levélhőmérséklet szoros összefüggést mutat a növényi transzpirációval (Jones 1992, Jones et al., 2002), amelyet a kórokozók sokfélesége különböző módon befolyásol. Miközben sok levél kórokozó, például a levélfoltok vagy rozsdák, helyi és jól definiált változásokat indukál, addig a gyökér kórokozók (pl. *Rhizoctonia solani* vagy *Pythium spp.*) vagy a szisztémás fertőzések (pl. *Fusarium spp.*) által okozott károsodás gyakran befolyásolja a transzpirációs sebességet is és az egész növény vagy növényi szervek

vízáramlását is befolyásolják. A kórokozó fertőzés elleni védekező mechanizmusok miatt bekövetkező helyi hőmérsékleti változásokat a dohányban a növényi vírus kölcsönhatásaira és a *Cercospora beticola* cukorrépa esetében Chaerle et al. közölték (2004). Oerke et al. (2006) sikeresen detektálták az IRT segítségével uborka fertőzéseket, például peronoszpóra fertőzést (*Pseudoperonospora cubensis*), illetve almabetegségeket például a varasodást (*Venturia inaequalis*) (Oerke et al., 2011). Az alma és az *V. inaequalis* növényi kórokozórendszerében a termográfia az alma szövetek térbeli kolonizációját is képes volt megjeleníteni a látható tüneteken túlmenően, olyankor is, amikor a hifák és a konídiumok csak mikroszkóposan voltak detektálható (Oerke et al., 2011). Gomez (2014) nyomon követte a *Peronospora sparsa* fertőzését és terjedését különböző rózsa fajtákon. Nilsson (1991) szabadföldön végzett kísérletei igazolták, hogy magasan korrelál a különböző gyökér- és levélbetegségek súlyossága és a különböző növények vitális paramétereivel (árpa, búza, zab, cukorrépa, burgonya stb.). Az IRT-képek hatékony elemzéséhez a levelek közötti és a leveleken belüli heterogenitás használható. Az egyes levelek, növények és növényi állományok átlagos hőmérsékletkülönbsége fontos mutatója a növényi vitalitásnak és a betegség megjelenésének.

2.3.2.5 Fluoreszcens képalkotás

Számos klorofill fluoreszcencia paramétert használnak a növények fotoszintetikus aktivitásában mutatkozó különbségek becsléséhez. A klorofill fluoreszcens képalkotó eszközök általában olyan aktív szenzorok, amelyek LED-es vagy lézerefényforrással rendelkeznek, mely felméri a fotoszintetikus elektronátvitelt (Chaerle et al., 2004; Murchie & Lawson, 2013). Ezt a módszert alkalmazták a biotikus és abiotikus stresszek által okozott fotoszintetikus aktivitás különbségeinek tanulmányozására (Bürling et al., 2011; Scholes & Rolfe, 2009). A fluoreszcens képalkotás és a képelemzési technikák kombinálása hasznosnak bizonyult a gombás fertőzések megkülönböztetésére és mennyiségi meghatározására (Konanz et al., 2014). Az aktuális klorofill fluoreszcens képalkotó rendszerek egyik hátránya, hogy a növények előállításának szigorú protokollt kell követnie, és ezért nehéz a normál mezőgazdasági növényházakban vagy terepi környezetben megvalósítani. Ezért a kutatás a napsugárzás által kiváltott reflektancia fluoreszcencia paramétereinek extrakciójára irányult, mely segítené a növényi megbetegedések felmérésére a lombkorona vagy a mező szintjén (Rossini et al., 2014).

2.3.2.6 Szenzorok a növényi biomassza és a növényi szerkezetek értékeléséhez

A növényi felépítés és a növényi biomassza fontos információkkal szolgálhat az egészségi állapottól vagy a betegség jelenlétéről egyetlen növényi szervezetben vagy táblák szintjén. A korábbi években különböző nem invazív érzékelőket fejlesztettek ki. A növényi állomány sűrűsége fontos paraméter lehet a célzott fungicid alkalmazások tervezéséhez is (Dammer et al., 2014). A fotogrammetriai megoldások, mint például a sztereó kamerák, a 3D lézeres szkennerek, az ultrahang vagy a sűrűségmérés is képesek megkülönböztetni a növényi biomassza vagy a növényi architektúra információit (Busemeyer, 2013; Wahabzada et al., 2015). Egyetlen növényi szervet automatikusan meghatározhatunk, sőt

kimutatták, hogy nagymértékben korrelál például a búzavirág mennyisége az ezermagtömeggel. Ezért a *Fusarium* spp. által fertőzött búzamazag észlelésére fotogrammetriai technológiát alkalmazhatunk. A sztereoó kamerák és a 3D-s lézeres szkennerek például színes vagy reflexiós intenzitással rendelkeznek, amelyeket fel lehet használni a betegség kimutatására képi vagy reflexiós analízis alapján (Paulus et al, 2014). Illetve a gyomtérképezésben is eredményesnek bizonyultak akár zárt állományok vizsgálata során is.

2.3.2.7 Komplex terepi rendszerek

Számos komplex eszköz és technológiai megoldás elérhető mára a terepen és az üvegházakban is. Ezek azonban többnyire egyedi célokra és fajtákra szabott prototípusok, és nem alkalmazhatók széles körben. Ilyen fejlett rendszer például az a képalkotó platform, melyet a tulipán törő vírussal (TBV) fertőzött tulipánhagymák kimutatására fejlesztett Polder et al. (2014). Ez egy robot multispektrális kamerákkal és egy online gépi látáselemző csővezetékkel felszerelve. Ezt a kutatást a tulipánhagymák minősítésével foglalkozó technikai szakértők korlátozott rendelkezésre állása motiválta. Képesek voltak beállítani és optimalizálni ezt a rendszert, hogy elérjék azt a pontosságot, amit a tapasztalt minősítő szakértők által tudnak elérni.

De létezik olyan hiperspektrális képalkotó rendszer prototípus is, mely a sárga rozsda (*Puccinia striiformis*) kimutatására alkalmas. A Bravo et al. (2003) által fejlesztett "Buggy"-val, hiperspektrális képalkotással a búzamezőkben sárga rozsda által fertőzött foltokat észleltek és osztályoztak, 96% -os sikeresség mellett környezeti fényviszonyok között. Eredményeik nagyon ösztönzik a költséghatékony optikai érzékelő platformok kifejlesztését a növényi megbetegedések korai és pontos kimutatására különböző növényeknél.

Kimutatták azt is, hogy a különböző genotípusok és fajták bizonyos betegségre való fogékonyságának és / vagy rezisztenciájának szintjét optikai szenzorokkal is lehet értékelni. Chaerle et al. (2007) képesek voltak meghatározni a cukorrépa *C. beticola* elleni különböző fokú érzékenységi szintjeit multispektrális és fluoreszcens képalkotással. Emellett ők voltak az első olyan kutatók is, akik automatizált, szenzorokkal szerelt platformokat használtak az egész növény átvizsgálására, amely egy robot rendszerre szereltek fel. A cukorrépaikat különböző léptékeken tesztelték a kis levélrészekről a teljes levélen át az egész növényig. A levélvizsgálatok kiválóan bizonyultak a korai tünetek detektálására, a klorofill fluoreszcencia összefüggéseket mutatott a *C. beticola* különböző érzékenységi szintjei között, a méréseket in vitro vizsgálatokkal is összehasonlították.

A nagy átérésztő képesség elérése érdekében Rousseau et al. (2013) kifejlesztett egy küszöbérték megközelítést a klorofill fluoreszcencia paramétereken, a *Xanthomonas fuscans subsp.* és a *Phaseolus vulgaris* törzseire. A vizsgálatban a klorofill-fluoreszcencia eredményei kihangsúlyozták annak lehetőségét, hogy kimutathatóak a pre-sztomatikus területek, ezáltal fontos eszköze lehet a kvantitatív rezisztencia értékeléséhez.

Kidolgoztak egy *HyperART* rendszert, ami a levél reflektancia és a transzmisszió egyidejű mérésére szolgál (Bergsträsser et al., 2015). Egy kísérleti alkalmazásvizsgálatban ez az érzékelőrendszer bizonyította a *C. beticola* cukorrépa rezisztenciájának és érzékenységének különböző szintjeinek értékelését. Kimutatták, hogy a mérésekből származó további információk növelik a detektálási érzékenységet. Egyelőre a mérési protokoll és az eljárás meglehetősen összetett, így még jelentős kézi beavatkozást igényel.

Bizonyos növényi válaszokat csak idősoros vizsgálattal, vagy roncsolásmentes képalkotási megközelítésekkel lehet vizsgálni. Ennek céljából a közelmúltban Kuska et al. (2015) kidolgozta a hiperspektrális mikroszkopikus megközelítést. A képalkotó szenzor 7,5 μm nagyságú képpontjához 1 nm-es spektrális felbontás társul, ezzel a nagyfokú felbontással lehetővé tette a finom folyamatok idősoros kimutatását. Például értékelni tudta a gazdanövény-kórokozó kölcsönhatások időbeliségét és az árpa genotípusok differenciálódását, melyek a liztharmat-érzékenységtől eltértek. Ezzel lehetővé vált az érzékelő-alapú, adatvezérelt fenotípus-megközelítés mikroszkopikus szinten.

2.3.2.8 A terepi távérzékelés módszertani kérdései

A legtöbb érzékelő nem közvetlenül méri a növényi fiziológiás paramétereket, hanem egy olyan spektrumot rögzítenek, amely a különböző növényi jellemzőknek és a mérési feltételeknek (pl. lejtős dőlés, megvilágítás és felületi textúra) tulajdonított reflektancia összege (Gitelson et al., 2002; Jensen, 2007). A növényi érzékelők által rendelkezésre bocsátott adatok jelenlegi minősége és mennyisége jelentősen megnőtt. Az érzékelők által generált adatok mennyisége és mérete könnyen elérheti a terrabájtot. Ez az adatszint a nagy spektrális, térbeli és időbeli felbontással megköveteli az adatkezelés, elemzés és értelmezés fejlett módszereit (Bauckhage & Kersting, 2013; Wahabzada et al., 2015). A precíziós mezőgazdaságban nagy területek, vagy teljes területek megfigyeléseivel foglalkozunk, melyet például az új eszközhordozók, a drónok képesek elvégezni. Fontos, hogy az adatokat közvetlenül és online módon feldolgozzák.

A növény fenotipizálása során a vizsgált genotípusok vagy kezelések nagy száma növeli az előállított adatok méretét és összetettségét. Feladat-specifikus algoritmusokat kell kidolgozni ezen adatok hatékony kezelésére. Behmann et al. (2014) a betegség kimutatására szolgáló szenzorok adatainak különböző adatelemzési módszereit tárgyalták.

Különböző vizsgálatok kimutatták, hogy a 350-2500 nm teljes spektrumra nem volt szükség minden esetben, például a gombás fertőzések okozta növényi stressz kimutatására sem, mivel a keskeny spektrális sávok nagymértékben korreláltak egymással (Bravo et al., 2003; Delalieux et al., 2007; Mewes et al., 2011). Azaz elmondhatjuk, hogy az objektumtól és a céltől függően a spektrális tartomány szűkebb szakaszai is elegendően érdekesek lehetnek. Viszonylag kis számú hullámsáv használatával az érzékelő berendezés egy adott növényhez és az adott vizsgálati szempontrendszerhez igazítható (Bravo et al., 2003; West et al., 2003).

Ezt követően Mahlein et al. (2013) kifejlesztett egy módszert a releváns hullámsávok hiperspektrális reflexiós adatokból való kinyerésére, majd ezeket a hullámsávokat spektrális indexekbe kombinálva különféle lombos cukorrépa-betegségek specifikus kimutatására használta. De gondolhatunk a korábbiakban bemutatott NDVI indexre is, mely szintén két szűkebb sávra összpontosul.

Ezek az eredmények technikailag megvalósíthatók a keskeny sávú LED-ek és a szilícium C-MOS képalkotó érzékelők használatával, melyek drasztikusan csökkentik a spektrális növény szenzorok költségeit (Grieve et al., 2015).

A terepi távérzékelés új eszközhordozó drónos rendszereinek szenzorfejlődése (elsősorban a multispektrális szenzorok, a termális érzékelők, illetve a LiDAR szenzorok emelhetők ki, de a hiperspektrális kamerák is egyre nagyobb fókuszt kapnak) révén lehetőségünk van egyre nagyobb területek, több szenzorral egyszerre történő monitoringjára. A növekvő spektrális és térbeli felbontás révén viszont egyre nagyobb adatállomány feldolgozását kell megoldani. A térinformatika az adatbázis-technológia fejlődésének és az open source rendszerek (*PostgreSQL/Postgis*, *QGIS*, stb.) előretörésének köszönhetően kezd átalakulni. Egyrészt megszűnni látszik a nagy cégek vezető szerepe (pl. ESRI, Integraph), míg a megnövekedett digitális kép adatbányászati kiértékeléséhez és az informatikához is értők szaktudása felértékelődött. Ezen rendszerek programozói hátterében a *Python* programnyelv a legelterjedtebb, de adatformátumtól függően egyes rendszerek a *C#* programnyelvet is előszeretettel használják. Az előbbi 2 nyelven túl a webhez kötődő alkalmazási megoldások a *JavaScript* nyelvet igénylik. Míg adatbázis oldaláról az *SQL* parancsok ismeretei segítik a kutatókat.

Nemrégiben a nagy adatok kontextusában új és innovatív algoritmusok és gépi tanulási módok jelentek meg. Wahabzada et al. (2015) bemutatta az első adatvezérelt és automatizált analitikai megközelítést a hiperspektrális képalkotó adatokra. Módszerével lehetséges volt a karakterisztikus spektrális adatok kinyerése és értékelése emberi beavatkozás nélkül.

A képi adatfeldolgozás képosztályozási algoritmusai számos módszert alkalmazhatnak. Egyik megoldás lehet a nem ellenőrzött osztályozási megoldások, például klaszterezéssel történő megközelítése. Másik lehetőség, hogy ellenőrzött módon tanítjuk be modellünk. Ez utóbbi gyakran használt algoritmusai a minimális távolság (MD), a legnagyobb hasonlóság (ML), illetve a spektrális szög (SAM) algoritmusok alkalmazása. Az MD matematikai hátterét az Euklideszi távolság kalkulációja adja, az ML hátterét a Bayes tétel, míg a SAM két képpixel spektrális vektorai közötti bezárt szöget kalkulálja. A fentiek mellett megjelentek a gépi tanulás algoritmusai, például az SVM, az ANN, a RF. Az RF matematikai hátterét a Gini indexre építették fel, maga az algoritmus véletlenszerűen alakít ki a felhasználó által megadott számú döntési struktúrát. Az ANN egy nem-parametrikus osztályozási módszer többretegű mesterséges neuronháló (MLP) segítségével (Jenser et al., 2009). Az SVM egy kernel-alapú módszert használ az adatok nemlineáris vetületének megtalálására, ahol az osztályok lineárisan elválaszthatók (Chang & Lin, 2011; Haridas, et al., 2015; Li, et al., 2019; Bazi, et al., 2018).

Emellett találkozhatunk már a mélytanulás (*deep learning*) megoldásokkal is (például konvolúciós neurális háló – CNN)(Cresson, 2018; Yao, et al., 2019; Baumgartner, et al., 2021; Punitha, et al., 2020). Mindkét irány algoritmusainak közös jellemzője, hogy megnövekedett gépi számítókapacitást igényelnek, mely ettől függően csökkenteni tudja ezek futtatási idejét. Ez labor oldalon megoldható, viszont nehezíti a gyors, közel valós idejű, döntéstámogatást támogató fejlesztéseket. Ezen mély tanulási modellek építése a mesterséges intelligencia bevonásával napjainkban indultak, így a modell-, és adatbázisépítés szakaszában járnak. Másik lehetőség lehet, hogy adattovábbítással távol dolgozzuk fel az adatokat, viszont ennek szintén fontos háttérfeltétele a megfelelő gyorsaságú hálózati hozzáférés, melyre így szintén figyelni kell. Az adattovábbítás az adatfeldolgozás egyik megoldása mellett az M2M⁵ (gépek közötti) kommunikáció és az így támogatott beavatkozási parancsok átadása szempontjából is fontos fejlesztési terület.

Várható, hogy a közeljövőben az okostelefon-alapú megoldások, akár beépített érzékelőként, akár külső érzékelő eszközökként, jelentősen befolyásolják a tudásalapú információk és érzékelési technikák rendelkezésre állását és terjedését a növényi gazdálkodók körében. Azonban az ilyen típusú alkalmazások képző technológiáinak nagy része még mindig fejlődési szakaszban van. Ezen technológiáknak a precíziós mezőgazdaságban vagy a növény fenotipizálásban történő mezőgazdasági gyakorlatba történő szabványosított bevezetésének határideje még nem minden esetben látható.

A precíziós mezőgazdaságban nagy léptékű területeket kell figyelemmel kísérni, és az intézkedést rövid időn belül kell végrehajtani (Stafford, 2000). Ugyanakkor a végleges módszertanoknak minden skálára relevánsan alkalmazhatónak kell lenniük a sejtenyészetektől az egyes növényi szerveken át, az egész mezőig (Granier & Vile, 2014). A nagyszámú ismétléseket értékelni és jellemezni kell, esetenként a hagyományos analitikai labor eredményekkel való megfeleltetés is fontos, miközben figyelembe kell venni a morfológiai és fiziológiai növényi jellemzőket. Emellett a szenzort hordozó platformokat és a nyomon követési adatok elemzését különböző perspektívákból kell kifejleszteni. Vannak olyan platformok, mint az UAV-k, az autonóm robotok és a traktoron alapuló érzékelők, melyek megvalósítják az előző célt.

Egy másik szempont, amelyet eddig nem vettünk figyelembe, hogy a különböző szenzorokból származó információk és adatok összevethetők vagy akár összevonhatók legyenek, hogy komplex képet kapjunk. A jövőbeli kutatásokhoz elengedhetetlen olyan kiegészítő kutatási területek, mint például a növénypatológia, szenzorfejlesztés, informatika és a gépi tanulás összekapcsolása. Csak egy nagyon interdiszciplináris megközelítés, amely ugyanakkor szoros kapcsolatban áll a gyakorlati mezőgazdasággal, vezethet olyan hatékony megoldásokhoz, melyek nagy pontossággal és

⁵ M2M – Machine-to-Machine: azon fejlesztések gyűjtőszava, melyek révén a berendezések képesek egymás között adatot továbbítani emberi beavatkozás nélkül. Általában internetkapcsolaton keresztül valósítják meg.

érzékenységgel rendelkeznek. Ezen túlmenően számos olyan kutatási területre van még szükség, melyek a teljesség igénye nélkül például a következők:

- Meg kell vizsgálni a biotikus és az abiotikus stressz kölcsönhatásait
- Vizsgálni kell a növények genomikus, transzkripciós és metabolikus tulajdonságainak az optikai tulajdonságokra gyakorolt hatását
- Kapcsolódás más tudásalapú módszerekhez, melyek komplex perspektívát nyújthatnak a növényi rendszerek szempontjából (például az időjárás alapú előrejelzési modellek)
- A mérések időbeliségének fejlesztése, a pillanatnyi mérések folyamatossá tétele (mozgóképeszerű adatfelvétel és kiértékelés)
- Növényvédelmen belül:
 - Annak a lehetőségnek a vizsgálata, hogy a korai fertőzés detektálása révén (még a látható tünetek előtt), milyen beavatkozások jöhetnek szóba
 - Különböző kórokozó-csoportok (gombák, baktériumok és vírusok, talaj- illetve levélzet kórokozók) spektrális jellemzése, további vizsgálata
 - A vegyes fertőzések hatásainak vizsgálata a növények optikai tulajdonságaira
 - A kórokozók közötti kölcsönhatásokat értékelni kell

3 ANYAG ÉS MÓDSZER

Dolgozatomban a terepi távérzékelés két területét vizsgálom, rávilágítva bizonyos nehézségeikre, és az ezekre választ adó fejlesztési megoldásokra. Mivel korábbiakban a terepi távérzékelés elsősorban a spektroradiométerekre támaszkodott, így ezen rendszerrel foglalkozom először. Bemutatom, hogy egy spektroradiométer adott esetben mely egyéb, gyakran használt mérési rendszert tudna kiváltani. Ezen munkám során szabályozható LED rendszerekkel, illetve hagyományos HPS rendszerekkel dolgoztam, így összehasonlításukra is kitérek.

Majd a dolgozat másik felében a drónokon (UAV) elérhető mérési módszertant fogom bemutatni, összevetve mind a műholdas, mind pedig a spektroradiométeres mérésekkel, egyúttal bizonyos nehézségeikre is felhívva a figyelmet.

3.1 Passzív terepi spektroradiométerek terepi mérési módszertanának támogatása

Először bemutatnám a *Qmini* spektroradiométert (14. ábra), melyet méréseimhez használtam. A *Qmini* egy német cég, az *RGB Photonics GmbH* terméke. Számos spektroszkópiában használt terméket fejlesztenek, míg áruk viszonylag kedvező a piacon. A *Qmini* egy kis méretű kivitelben készült, összsúlya 39 g. Kompakt kialakítása lehetővé teszi az integrációt olyan alkalmazásokban, ahol korlátozott a hely, például a mobil elemző eszközöknél, vagy akár repülő szerkezeteknél, drónoknál.

Lehetővé teszi:

- A spektrumok teljes feldolgozását az eszközben (eltolás, nemlinearitás, sötét spektrum, spektrális érzékenység)
- Átlagolás és simítás
- Spektrumok összevonása és kiegyenlítése
- Komplex alkalmazás-specifikus értékelési algoritmusokat tartalmaz
- Széles választékban rendelkezik kommunikációs interfészekkel
- Új I / O csatlakozó analóg és digitális jelekhez



14. ábra - *Qmini* spektroradiométer képe

Spektrális felbontása 220 nm-1100 nm-ig terjed (ez a gyakorlatban 250 nm -1000 nm-ig nyújt pontos méréseket, az ezen túli tartományok zajossága már magas), ezen tartományban átlagosan 0,5 nm-enként végez méréseket (UV tartományban 0,3 nm-ként, míg VIS, NIR tartományban 0,7 nm-ként). Ezzel jobb felbontást biztosít, mint az *ASD*, avagy *Ocean Optics* termékei, melyek típusfüggően 1 nm, vagy 5nm-es spektrális érzékenységgel rendelkeznek.

Expozíciós ideje 3 μ s - 600 s között állítható. USB 2.0 kábellel csatlakozik a számítógép egységhez. Amiatt is ezen eszközt választottam, mivel a cég rendelkezésre bocsátja a szenzor és annak programjának SDK fájlját, ez pedig segíti a további fejlesztéseket, egyelőre *Windows* operációs rendszerhez optimalizálva.

A mérési adatok méréséhez és elődolgolásához a *Waves* nevű elemző szoftvert alkalmazhatjuk.

A szoftver jellemzői a következők:

- Segíti a spektrum sorozatok felvételezését, megjelenítését, elemzését
- Automatikusan segíti az expozíció-szabályozást sötét spektrumú interpolációval
- Képes automatán, előre beállított időközönként is a felvételezésre
- Több spektrum valós időben történő megjelenítését, elemzését is lehetővé teszi
- Bármely „sávdigram” jellemző értékeit megjeleníti, kalkulálja
- Dinamikusan keresi a csúcsokat (nincs szükség küszöbérték beállítására)
- Képes a sötét spektrumú interpolációra
- A transzmittanciás, abszorpciós és reflexiós mérések többféle mértékegységben is megjeleníthetők, rögzíthetők
- Kolorimetriai elemzések elvégzésére is alkalmas
- A legtöbb ASCII-alapú fájlformátumot képes importálni
- ASCII táblázatként szinte bármilyen numerikus elemző szoftverre tudja exportálni az adatokat (például *Excel*)
- Az elkészült grafikonokat képes közvetlenül nyomtatni, illetve PDF-be exportálni

3.1.1 Egy új mérőegység fejlesztése és prototípusa

A spektroradiométerek (pl. *Qmini*) általában nem rendelkezik önálló energiaszolgáltatással, így csak laptopról üzemeltethetőek, melyhez USB-vel csatlakoznak. Ez a terepen megnehezíti a méréseket, mivel egyik kezünk a spektroradiométert fogja, másik a laptopot (vagy nyakba kötve nem kell fogni, csak egyensúlyozni), de szintén kell egy kéz a mérés indításához, és a pontosság szempontjából a levelet ismételt magasságokból és szögből kell felvételezni, mely szabadkézi használat mellett nem biztosítható. Az első célom, hogy egy egyszerűbben hordozható spektroradiométeres mérési módszert dolgozzak ki, melyekhez különböző segédeszközöket terveztem, melyek használatával elérhetőek a fentebbi célok.

A szabadkézi használattal szemben egy állítható állványt készítettem, mely akár laborban, akár terepen, a kalibrációhoz és a méréshez is alkalmazható oly módon, hogy fix magasságban és szögben tartja a szenzort, ezzel pontosabb mérést biztosítva a szabadkézi használatához. Az állványrendszer tartófejehez a *Qmini* műszaki paramétereit használtam. A tartófej 45 fokos szögben tartja a szenzort. A szenzortartó 360 fokban képes az elfordulásra, és csúsztathatóan eltérő magasságokban is rögzíthető a tartó rúdon. A szenzor előre csúszását jelenleg egy gumipánttal tudjuk megakadályozni a tartófejen, mely a jövőben kiváltható a tartó alsó részén történő perem kialakításával. Fontosnak tartottam, hogy az állvány tartórúdja kivehető és cserélhető legyen a kívánt magasság szerint (egyelőre 1 méteres és egy 20 cm-es változatot készítve hozzá). Amennyiben kis magasságban, vagy laborkörülmények között szeretnénk

alkalmazni, a kisebb állványra helyezve használhatjuk. A tartórúd egy stabilitást biztosító talprészhez csatlakozik. A kialakításhoz szögvas gépelemeket használtam.

Az állvány mellett számos kereskedelmi cég gyárt úgynevezett 'Contact Probe' mérőfej egységeket, melyek aktív szenzorrá alakítják a passzív mérőrendszert. Öt eltérő kialakítást tanulmányozva az alábbi követelményeket fogalmaztam meg:

- Maga az adapter alsó és felső része egy tengely mentén képes szétnyílni és zárni, mint egy klipsz.
- A mérési területet 5 cm átmérőjű négyzetben határoztam meg
- A szenzor feje 2 irányból is csatlakoztatható:
 - egyik esetben szemben helyezkedik el a fényforrással (180°-os szögben) a mérőtérben, ekkor transzmittancia mérésére alkalmas
 - másik esetben a fényforrás oldalán helyezkedik el, 45°-os szögben, és reflektancia mérésére alkalmas
 - a szenzor feje pontosan csatlakozzon, a nyílások zárhatóak legyenek
- A felhasznált fényforrás cserélhető legyen
- Mivel ezek kisméretű fényforrások kell legyenek, a világítástechnikában alkalmazott G4 foglalatot választottam.
- A kis hely miatt fontos foglalkozni a választható fényforrásokkal. A spektroszkópos mérésekhez leggyakrabban halogén fényforrásokat alkalmaznak, mivel ezek spektruma széles, és hasonlít a természetes napfény spektrális összetételéhez, viszont ezek működés közben hőtermeléssel járnak. Ahol van megfelelő távolság, ott nem okoz mindez gondot, viszont kis távolságoknál túltelíthetik a szenzort, vagy befolyásolhatják a mérést, adott esetben akár a mintát is roncsolhatják. A választott G4 foglalatba 12V 10W-os, vagy 20W-os mikroszkóp halogén izzót célszerű választani, és csökkenteni kell a szenzor expozíciós idejét. A halogén fényforrás alkalmazása miatt, számolva a melegedés kockázatával, a fényforrás G4 foglalatát a burkolaton kívül helyeztem el.
- Hogy ne folyamatosan üzemeljen a fényforrás egy megszakítókapcsolóval lehet vezérelni
- A fényforrás áramellátására alacsony feszültségű, tölthető lítium-polimer akkumulátort alkalmaztam (de a jövőben a csatlakozó cseréjével kialakítható egyéb megoldás is, pl. AAA vagy AA akkumulátort tartalmazó elemtartó is helyet kaphat rajta)
 - A mérés pontosságát segítő a fényforrás körüli teret félgömb formaként modelleztem (a diffúz spektroszkópiai laboratóriumi vizsgálatok gömb formájú mérési elvét ötvözve)

A tervezéshez az *AutoCAD 2021* szoftvert használtam. A modellt *Crealty Ender 3D* nyomtatóval, ABS filament anyagból gyártottam le. A mérőfej mérési terét bárium-szulfát festékkel vontam be. A fényforrás G4 foglalatának műszaki paramétereit a tervezés során figyelembe vettem. Áramforrásként

egy *Parrot* drón lítium-polimer akkumulátort csatlakoztattam. A lámpa megszakítható üzemeltetése révén csak a mérés és az azt megelőző, gyártói ajánlás szerinti, szenzor bemelegedés idején világít, ezzel megelőzve a túlmelegedést és üzemidő szempontjából is előnyös. A levél „leszorító” részét szilikonnal vontam be, hogy ne okozzon sérülést.

Az első prototípus elkészülte után az alábbi javításokkal módosítottam az első verziót:

- A G4 foglalat könnyebb és stabilabb rögzíthetősége miatt egy alátámasztást alakítottam ki a félgömb külső oldalán
- A félgömb részt elválasztottam a mérési négyzet alakú tértől, és egy 3 mm-es keretet alakítottam ki a mérési tér peremén, ezáltal a félgömb fej cserélhető a későbbiekben eltérő kialakítású fejekre. (Ezen megoldás a gyártást is segíti, mivel így a háromdimenziós nyomtatás külön tudja nyomtatni a tartó részt és a félgömb alakú fejrészt. Ezzel többféle nyomtatási elhelyezést tudunk választani, pontosabb nyomtatást elérve.)

Az eszköz a későbbiekben egyedi paraméterekkel, akár többféle „fejjel” is kiegészíthető (például termések vizsgálatához).

3.1.1.1 Mérési „alátétek” alkalmazása

Amennyiben reflektanciát mérünk célszerű valamilyen mérési alátétet alkalmazni, ezzel is pontosíthatjuk mérésünket. Itt lehetőségünk van valamilyen fehér, avagy fekete anyag használatára. Létezik akkreditált mérési lap is, mely a legnagyobb pontosságot biztosítja.

A kétféle alátét két eltérő megközelítést is jelent. Fekete alátét esetén, ezen felület elnyelése nagy, így a levélen áthaladó fényt is elnyeli. Ekkor a spektrális adatok a levél felületéről és a felszínhez közelebb szövetek visszavert sugárzását fogják inkább jellemezni. Míg fehér háttér esetén a levél teljes szövetén átjutó (a pigmentek által nem elnyelt) fény visszaverődik, így a spektrális adatok a mélyebb szövetekről is adatot mutatnak, nem pusztán a felszínhez közelebbéről.

A fentiekhez fehér háttérként a burkolathoz hasonló bárium-szulfáttal bevont lapot készítettem, a mérőtér paramétereinek megfelelően. Fekete háttérként többféle anyagot vizsgáltam a Tanszék mérőszekrényében. Ebben az alkalmazott fényforrás egy *ASD ProLamp 50W*-os akkreditált halogén laborlámpa volt, melyet kimondottan az 250 - 2500 nm reflektancia mérésekhez ajánlanak. A mérőszekrény faburkolattal rendelkezett, melyet belülről a vizsgált anyagokkal fedtem le. A rögzített fényforrás és az előző részben bemutatott laborállvánnyal alkalmazott spektroradiométer elhelyezését fixen tartva biztosítottam a mérések összehasonlíthatóságát. A legjobb abszorpciós értékeket egy textillel értem el, így ebből készítettem fekete háttér lapot.

Ezeket tehát egyszerűen a mérés előtt becsúszathatjuk, illetve ahhoz, hogy a mérés során ne csússzanak ki, oldalról egy forgatható kis ékkel láttam el a klipszet.

3.1.1.2 Spektrométer lehetséges csatlakoztatása Raspberry Pi-hez

A korábban bemutatott terepi mérések nehézségeinek megoldásának későbbi lépése lehet a laptop kiváltása. Első lépésben pusztán az adatfelvételezés elérése elegendő, ezzel az adatok elemzése, megjelenítése stb. később is laptopon végezhető (a megjelenítés fejleszhető).

Az adatfelvételezéshez kell:

1. felismerje az USB eszközt (és ellássa energiával)

2. **képes legyen elindítani és leállítani a mérést**

3. **tárolja az adatokat míg áthelyezésre kerülnek** (később internetelés mellett online helyen is gyűjtheti az adatokat, ehhez a WIFI rendszert egy okostelefonról is megoszthatjuk a terepen, de SIM rendszerrel is idővel kiegészíthető)

4. kalibráció:

- aktív szenzorként a kalibrációhoz továbbra is használhatjuk a laptopunkat, majd ezen kalibrációs fájlra kell másolni a Raspberry Pi rendszerére, ahonnan mérés előtt beolvasható

- passzív szenzorként a kalibráció a sötét spektrum, illetve az aktuális környezeti fényviszonyok felvételezésével indulna, melyekkel korrigálja a mért adatokat. Ráadásul mindezt minden méréskor, minden optikailag fontos változásra (megváltozott szög, távolság, felhőzet, stb) el kell végezni. Amennyiben a *Waves* szoftvert *Raspberry Pi*-n tudjuk integrálni, úgy ezen lépést a szoftveren belül el fogjuk tudni végezni.

Ami idővel a passzív mérés igényét erősítheti a klipsszel szemben az esetleg a drónok és az automatizálás további igénye. Ezen spektrométerek úgy lettek már fejlesztve, hogy nagyon kis súlyúak legyenek (például a *Qmini* 39g), így egyre többször felmerül drónokkal való használatuk, vagy egy üvegházban egy robotkaron történő elhelyezésük. Zárt rendszerekben az automatizálás adja ugyanezen igényt, de egy klipsz automata használata szintén számos további kérdést felvet (például a minta sérülése nélküli felhelyezése egy robotkar által).

5. A spektrométer mozgatható maradjon, így két irányból tudjon mérni.

Mivel a *Qmini*hez a *Waves* nevű szoftver SDK fejlesztői fájlját megkaptuk, így ebből indultam ki. A *Raspberry Pi 3* mikroszámítógéphez csatlakoztattam egy HDMI csatlakozást segítő modult, majd egy TFT kijelzőt csatlakoztattam. Ezután egy WIFI vezérlőkártyát integráltam a rendszerbe, majd egy *Windows 10 IoT* operációs rendszert telepítettem rá, melyen a korábbiakban integrált modulok kezelését alakítottam ki. Ezek után az SDK csomagból telepítettem a spektrométer driver fájljait.

3.1.1.3 Összehasonlítás *ASD FieldSpec Handheld 2* típusú spektrométerrel

Mivel a leggyakrabban használt terepi spektrométerek az *ASD* cég termékei, így összehasonlító mérésekkel vettem össze a prototípus adapterrel alkalmazott *Qmini* méréseit, vizsgálva a két rendszer egymással szembeni pontosságát.

A mérésekhez egy *ASD FieldSpec HandHeld 2™* hordozható spektrométert (325-1075 nm) használtam, melynek spektrális felbontása <3 nm (3,5 nm), kiegészítve egy gyártói *Plant Probe*-bal. Az alábbi táblázatban összefoglaltam a két műszer műszaki paramétereit.

5. táblázat - *ASD FieldSpec Handheld 2* és a *Qmini* spektrométerek műszaki adatainak összehasonlítása

	<i>ASD FieldSpec Handheld 2</i>	<i>Qmini</i>
spektrális felbontás	3-3,5nm	0,3-0,5 nm
érzékelési tartomány	325-1075 nm	220-1100 nm
súly	1,17 kg	39 g
hozzávetőleges ár	~12000 €*	~2500-3000€*

(*2015.évi árak mellett, *Plant Probe* kiegészítő nélkül)

A méréseket 2017. nyarán a Hajós-Bajai borvidéken, Borotán, a Koch Borászatban végeztem. 100 mintát felvételezve, minden esetben ugyanazon leveleket és lehetőleg ugyanazon helyen vizsgálva mindkét műszerrel.

Az adatok feldolgozásához az *ASD* esetén először a *ViewSpec Pro* programmal dolgoztam, melyből mérésenként egyesével lehet az adatokat szöveggé kimenteni. Majd *Excel* szoftverben végeztem el az összehasonlítást. A *Qmini* esetén ezen konverziós lépés nem szükséges, mivel a *Waves* által létrehozott nyers eredményfájl kompatibilis az *Excel* szoftverrel, azaz azonnal be tudja olvasni. Ráadásul az összes mérést egy fájlba mentve egyszerre behívható és elemezhető minden spektrális adat.

A statisztikai értékelést a feltételvizsgálatokat követően egytényezős varianciaanalízissel értékelttem (*Excel*), összehasonlítva a két rendszer pontosságát. Emellett megvizsgáltam a mérések során jellemző REP (Red Edge Point) értékeket, mivel ezen pont számos spektrális index alapját jelenti. Az értékeléseket a könnyebb összehasonlíthatóság miatt az értékek eltéréseinek átlagával és százalékos alakulásával jellemeztem.

3.1.2 Eltérő megvilágítási környezet mellett végzett vizsgálatok

A növénykísérletek előtt két, a műszaki specifikációk szerint hasonló rendszert hasonlítottam össze. Ezen vizsgálat tapasztalatai segítettek a későbbiekben, hogy a környezeti paramétereket egységesen tudjam biztosítani adott esetben eltérő világítási megoldások mellett is. A vizsgálat során a *KIND K5 panelt* és a *Sylvania GroLux 600W* lámpát hasonlítottam össze. A *Sylvania GroLux 600W*-os lámpája 55000 lm megvilágítást ígér, a gyártói ajánlás szerinti 1,5 méterre helyezve a lámpát a növény szinttől ~24000 lx megvilágítást érünk el a felszínen. Hogy össze lehessen hasonlítani a két rendszert (hasonló megvilágítást biztosítva), a *KIND K5* esetén mindhárom csatornát 50%-on



15. ábra – Az összehasonlításhoz használt *Plant Probe*-bal kiegészített *ASD FieldSpec Handheld 2* spektrométer

üzemeltetem 50 cm-es távolságba helyezve a lámpát a növényzettől (szintén a gyártói ajánlott távolságot tartva, mely szerint 100% esetén 44000 lx-t ígér 50 cm távolság mellett).

A kísérlet során regisztráltam a klimatikus paramétereket mindkét növényátorban (egy-egy *TFA 30.3015* hőmérséklet és páratartalommérővel). A fentiek mellett megvizsgáltam, hogy milyen megtérülés várható egy nagyteljesítményű LED rendszer esetén. E célból a villamos fogyasztási adatokat (*Basetech EM-3000* típusú fogyasztásmérővel mérve mindkét lámpa esetén) értékeltem egy hónapos üzemeltetés, napi 12h megvilágítási program szerint alkalmazva.

A LED rendszer esetében a PPFD értékeket területileg mérve ellenőriztem (50 cm távolságban a lámpától, 125 cm x 85 cm-es térrészt 5 cm-es távolságokra osztva), a méréseket minden ponton 3-szor ismételttem a későbbi növény szinten, melyhez a állványrendszer labor kialakítását használtam és egy Lambert-féle fehér reflektor felületet alkalmaztam. Az átlagértékek segítségével vizsgáltam a területi fényeloszlás jellemzőit.

3.1.2.1 Összehasonlító mérések Konica Minolta SPAD 502 mérőrendszerrel

A SPAD métereket Japánban fejlesztették ki elsősorban a növényi klorofill-tartalom és nitrogénellátottság becslésére (Chubachi et al., 1986). Azóta szintén egy gyakran használt kontakt terepi távérzékelési eszköz. Célja tehát a levél klorofill-tartalmának becslése, mérése. Ehhez aktív szenzorként 2 eltérő hullámhosszon bocsát ki fénysugarat, egyet 940 nm-en a közeli infravörös tartományban, egyet pedig a piros tartományban 650 nm-en. Mivel a klorofill az infravörös tartományban visszaver, míg a vörösben elnyel, így a szenzor működési elve az, hogy ezt az abszorpciós különbséget méri. Ezt egy úgynevezett SPAD értéként adja meg a műszer. Számos korábbi kutatás igazolta, hogy ezen érték pontos képet ad a növényzet klorofill-tartalmáról, egyszersmind egészségi állapotáról, így elsősorban a tápanyagellátás precízebb alkalmazását segíti.

Megvizsgáltam, hogy egy SPAD méter mérési adatai mennyire korrelálnak a spektrométer mért értékeiből alkotott indexekkel. A mintákat analitikai laboratóriumban is megvizsgáltam, majd ezen eredmény szerinti klorofill-tartalommal vettem össze a két terepi rendszer eredményeit.

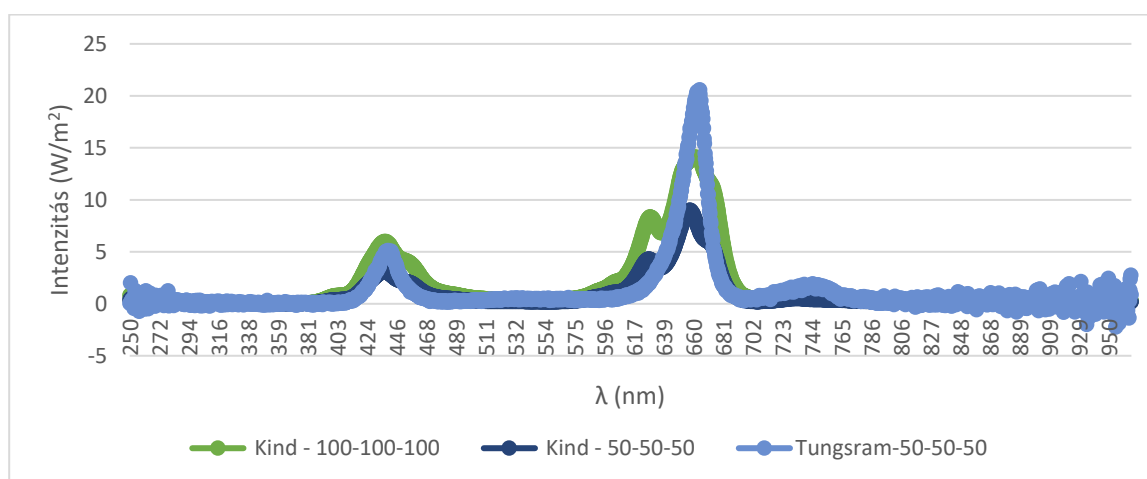
A vizsgálatokhoz saláta (*Lactuca sativa L.*) növényeket neveltem erre a célra kialakított 1x1x2 méteres növénynevelő sátrokban (3 db), sátranként 20-20-20 db növényt magról indítva kőzetgyapot kockákban. A sátrokban nyomon követtem a klimatikus viszonyokat, melyhez egy-egy *TFA 30.3015* hőmérséklet és páratartalommérőt használtam minden sátorban, melyek folyamatosan, 15 perces időközönként tárolták a klimatikus értékeket. Céлом volt, hogy a sátrokban a hőmérséklet-, és páratartalom értékeit szinte azonos értékek mentén tudjam biztosítani, és a növényeknél ugyanazon öntözést és tápanyagutánpótlást tudjam fenntartani. Így csak a fényviszonyokban volt különbség. A környezeti viszonyok stabilan tartásának céljából még a növénykísérletek megkezdése előtt számos méréssel vizsgáltam közel hasonló megvilágítást ajánló LED, illetve HPS rendszert, melynek tapasztalataira szintén kitérek a későbbiekben.

Az egyik sátorban a *Tungsramp* állítható spektrumú, nagyteljesítményű, 540 $\mu\text{mol/s}$ Research LED lámpáját alkalmaztam, melyet a céggel közösen fejlesztett az Egyetem. A lámpa 3 csatornában állítható [vörös (600-700 nm), kék (400-500 nm), fehér]. Mivel a szakirodalmi kutatások alapján kisebb fotonfluxus elegendő a saláta (*Lactuca sativa* L.) növények számára, ezért a három csatornát 50%-os beállítás mellett üzemeltettem. A lámpa spektrális fényösszetételét *Qmini* spektrométerrel mértem, a megvilágítás erősségét pedig *Holdpeak HP-881A* luxmérővel. A megvilágítási hosszt 16 órás megvilágítás és 8 órás sötét periódus szerint vezéltem. A növény-lámpa távolságát 50 cm-re állítottam be.



16. ábra - Kísérleteimben használt szabályozható LED lámpák (balra: *Tungsramp* Research Modul, jobbra: *KIND LED K5*)

A második sátorba *KIND LED K5* szabályozható LED rendszerrel biztosítottam a megvilágítást, melyet a Magyar Agrár- és Élettudományi Egyetem, Kertészeti Intézet, Zöldség- és Gombatermesztési Tanszék és az Élelmiszertudományi és Technológiai Intézet, Érzékszervi minősítő laboratórium munkatársai biztosítottak. A megvilágítási hosszt a korábbiak szerint 16 órás megvilágítás és 8 órás sötét periódus szerint vezéltem. A növény-lámpa távolságát 50 cm-re állítottam be, és szintén 50%-os csatornateljesítmény mellett üzemeltettem.



17. ábra - Kísérleteimben használt, szabályozható LED lámpák spektruma saját mérések alapján

A harmadik sátorba egy *Sylvania GroLux 600W*-os HPS lámpát alkalmaztam kontrollként. A megvilágítási hosszt a korábbiak szerint (16-8 órás periódusok) állítottam be, a lámpa-növény távolságot pedig 1,5 méterre. Ez utóbbira a növényi roncsolások elkerülése miatt volt szükség ebben az esetben,

mivel a HPS rendszerek teljesítménye nem szabályozható, és 50 cm-es távolság mellett roncsolja a növényi mintákat.

Mindhárom lámpa villamos fogyasztását egy-egy *Basetech EM-3000* típusú fogyasztásmérővel mértem.

A SPAD méterrel való összehasonlításhoz egy *Konica Minolta 502*-es típusú SPAD készüléket használtam, melyet a Magyar Agrár- és Élettudományi Egyetem, Kertészeti Intézet, Zöldség- és Gombatermesztési Tanszék munkatársaitól kaptam kölcsön. Összesen 20-20-20 darab növényt neveltem sátranként, kalkulálva a növényi elhalással is. Egy-egy növényen három darab véletlenszerűen kiválasztott levelet mértem le háromszori ismétléssel, melyeket később átlagoltam. A mérések ugyanazt a pontot próbáltam mérni mindkét műszerrel. Végeredményül 58 db mérési adatot gyűjtöttem sátranként. A három sátorra vonatkoztatva mindösszesen 174 átlagolt adat adódott, melyből a további elemzés során 165-öt elemeztem.

A vizsgált levelek összes klorofill tartalmát analitikai módszerrel, acetonos kivonást követően spektrofotometriásan adott hullámhosszokon mennyiségileg meghatároztam. A kivonást követően a szűrletet üveg küvettába töltöttem, majd az aceton vak mintával szemben mértem az abszorbanciát $\lambda=661,6$; $\lambda=644,8$; $\lambda=470\text{nm}$ -en, Helios-alpha spektrofotométerrel. Számítás: $C_{la} (\mu\text{g}/\text{mg}) = 11,24 \cdot A_{661.6} - 2,04 \cdot A_{644.8}$, $C_{lb} (\mu\text{g}/\text{mg}) = 20,13 \cdot A_{644.8} - 4,19 \cdot A_{661.6}$, $C_{(x+c)} (\mu\text{g}/\text{mg}) = (1000 \cdot A_{470} - 1,90 \cdot C_{a} - 63,14 \cdot C_{b}) / 214$. A méréseket 5 párhuzamos ismétlésben végeztem. Az analitikai mérésekkel meghatározott klorofill tartalmat vettem össze a SPAD értékekkel, illetve a mért adataimból képzett spektrális indexek eredményeivel, párosított t-próbával vizsgáltam az eredményeket.

3.1.2.2 A világítási rendszerek szabályozását és a spektrális adatokból kiinduló fényparaméterek megadását segítő vezérlőtábla létrehozása

A korábban bemutatott BTS szenzorok használata mellett a világítástechnikai automatizációt a mérőrendszerek adatainak összevetése alapján létrehozott matematikai átszámítás is segítheti. A korábbiakban levezetett módon látható, hogy a fotonfluxus, illetve irradiancia közötti átváltás egyenlete:

$$E_{\text{ff}} = E_e \cdot \lambda \cdot 0,836 \cdot 10^{-2} \left[\frac{\mu\text{mol}}{\text{m}^2 \cdot \text{s}} = \mu\text{E} \right].$$

Bemutattam, hogy a piranométerek, PAR-mérők, és luxmérők eltérő anyagokat alkalmaznak detektorként. Azt is bemutattam, hogy a sugázmérők a detektortól függően egy adott tartományú sugárzás összmenységét adják meg radiometriai egységekben. A fotometriai megközelítés és mérőrendszerek emellett az emberi szem érzékenysége miatt korrigálják a mérést a $V(\lambda)$ érzékenységi görbével, azaz a fotopikus látás érzékenységgel. A $V(\lambda)$ görbe korrekciós értékeit a CIE szabványokban találjuk meg, melyet többször pontosítottak már bevezetése óta. A fényerősségmérők (luxmérők) növényi megvilágítás mérésére történő alkalmazásának alapvető problémája tehát az is, hogy a kék (400-500 nm) és a vörös (600-700 nm) fényt alulértékelik a látható spektrumban. A növények viszont intenzíven

használják a kék és a vörös fényt a fotoszintézishez. A fent említett fotometriai mérések ezért nem kimondottan alkalmasak a növények megvilágításának értékelésére, mégis a gyakorlati élet gyakran alkalmazza őket, mivel mérőműszerei egyszerűen kezelhetők és viszonylag olcsón beszerezhetőek.

Kutatómunkám során ezen lehetőséget vizsgáltam meg. A felületre eső fény intenzitásának meghatározásához a mért fizikai (radiometriai) spektrális besugárzást (E_e) a $V(\lambda)$ görbe súlyozza és integrálja adott spektrális tartományban. A kapott értéket ezután megszorozzuk a K_m arányossági tényezővel az E_v fotometrikus megvilágítás kiszámításához. A K_m tényező a fényintenzitás SI alapegységének fizikai meghatározásából származik, 683 lm/W. A megvilágítás meghatározására ezért a következő egyenletet alkalmaztam:

$$E_v = K_m \int_{380nm}^{780nm} E_e(\lambda) V(\lambda) d\lambda \quad (3.9)$$

A $V(\lambda)$ korrekciós tényezőinek az ISO 23539:2005 (CIE S010/E:2004) szabvány adatait használtam. Mivel a fotoszintetikusan aktív sugárzás (PAR) csak a 400–700 nm hullámhossztartományú fényre vonatkozik, és itt állandó fényérzékenysége van az egész tartományban, ezért a 400 - 700 nm közötti spektrumtartományban besugárzott fényenergia megadható területenként (W/m^2). Matematikailag tehát az alábbiak szerint írható fel:

$$E_{PAR} = \int_{400nm}^{700nm} E_e(\lambda) d\lambda \quad (3.10)$$

Míg a PPFD a következőként alakul:

$$PAR \text{ PPFD} = \int_{400nm}^{700nm} E_e(\lambda) PAR(\lambda) d\lambda \quad (3.11)$$


Ahol a W/m^2 -ről $\mu mol/m^2$ -re történő átalakítást az alábbiak szerint hajtjuk végre:

$$k = \frac{1}{\frac{hc}{\lambda} \cdot N_A} = \frac{\lambda}{hc \cdot N_A} \quad (3.12)$$

Az alábbiakban egy minta konverziót láthatunk (550 nm-re):

$$1 \frac{W}{m^2} = \frac{550 \cdot 10^{-9}}{6,626 \cdot 10^{-34} \cdot 3 \cdot 10^8 \cdot 6,022 \cdot 10^{23}} \frac{m \cdot mol \cdot W}{Js \cdot \frac{m}{s} \cdot m^2} = 4,6 \frac{\mu mol}{m^2 s}$$

Mivel a különböző hullámhosszú fotonok energiaszintje eltérő, ez a PAR spektrális függvény lejtését eredményezi (18. ábra).



18. ábra - A PAR relatív spektrális függvénye

A 18. ábrán jól látszik, hogy azért ezen megközelítés jóval pontatlanabb, mint egy spektroradiométerrel elérhető spektrális mérés. A növényi abszorbancia spektrum is jóval diverzebb ennél, és napjainkra a LED-ek által elérhető, nagyfokú spektrális variabilitás szintén. Viszont azt jól szemlélteti az ábra, hogy az eltérő hullámhosszú fény eltérő fotonfluxussal jellemezhető energiaoldalról, azaz például egy növényházi LED rendszer esetén ugyanazon energiamennyiséghez a piros és Far-Red LED-ek sokkal magasabb PPF-eket kínálnak, mint a kék LED-ek, azaz kevesebb mólnyi kék fény elegendő ugyanazon energiamennyiség biztosításához, mint vörös, vagy távoli vörös tartomány esetén. Ezt a fejlesztéseknél is láthatjuk a beépített diódák darabszám eloszlásában is.

A fentieket összegezve, tehát ha egy fényforrás spektrális teljesítményeloszlása (SPD) ismert a vonatkozó hullámhosszakon (400-700 nm) (vagy spektrométerrel megmértük), akkor meghatározható a növények számára rendelkezésre álló fotoszintetikusan aktív energia mennyisége. Figyelembe véve a *CIE 1931* $V(\lambda)$ fényhatékonysági függvényt, kiszámíthatjuk a növények spektrális fluxusát $\Phi(\lambda)$ W/nm-ként minden egyes lumenre:

$$\Phi(\lambda)/\text{lumen} = \frac{W_{rel}(\lambda)}{683 \cdot \sum_{(400-700)} [V(\lambda) \cdot W_{rel}(\lambda) \cdot \Delta\lambda]} \quad (3.13)$$

ahol $W_{rel}(\lambda)$ a relatív spektrális teljesítményeloszlás és $V(\lambda)$ a fényhatékonysági függvény λ hullámhosszon.

Ezzel kiszámítható a fotoszintetikus foton fluxus (PPF) nanométerenként $\mu\text{mol/s/nm}$ -ben:

$$\text{PPF}_{\text{nm}} = (10^{-9}) \cdot \frac{\lambda \Phi(\lambda)}{N_A \cdot h \cdot c} \quad (3.14)$$

ahol:

N_A = Avogadro állandója, $6,022 \cdot 10^{23}$

h = Planck állandója, $6,626 \cdot 10^{-34}$ [J·s]

c = fénysebesség, $2,998 \cdot 10^8$ [$\frac{\text{m}}{\text{s}}$]

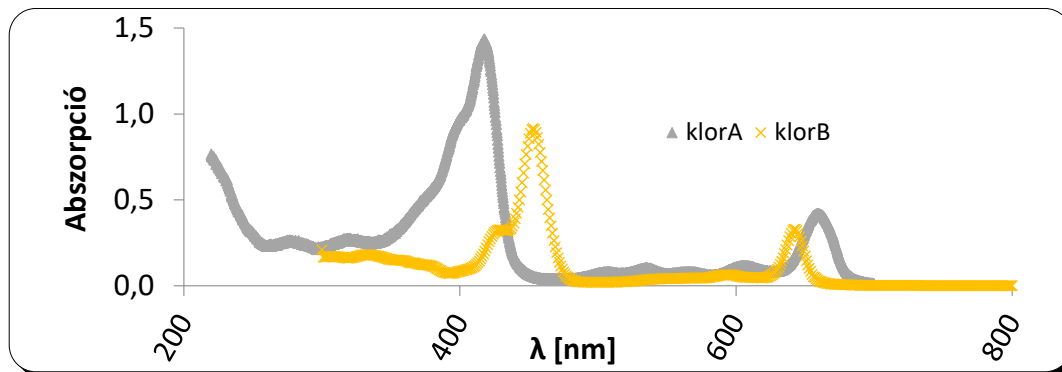
λ = hullámhossz [m].

Hasonlóan ehhez a metodikához a megvilágítási érték (lux) függvényében kiszámíthatjuk a fotoszintetikus foton fluxus sűrűségét (PPFD) $\mu\text{mol/s/m}^2$ értékben az adott fényforráshoz.

Gueymard 2004-es tanulmányában leírt napsugárzási adatokból kiindulva egy modellben egyesítettem a fizikai egyenleteket, melyek a Planck törvényből kiindulva a fotometriai egyenletekig terjedtek. Mivel adott mérőrendszer használja a CIE S010/E:2004 szabványban rögzített fotopikus látás ($V(\lambda)$) görbét, így ezzel a modellben is korrigáltam a megfelelő értékeket. Emellett feldolgoztam az eltérő mérőrendszerek mérési érzékenységének jellemzőit. Ezek alapján bemutattam az eltéréseket.

A modell egyenleteit továbbfejlesztettem, hogy a tábla bármely spektrális mérés alapján automatikusan átszámolja és ábrázolja az aktuális fénytani paramétereket.

A növényfejlődés szempontjából az egyik két legfontosabb fényreceptor, a klorofill A és B elnyelési tartományait jobban megvizsgálva (19. ábra) láthatjuk, hogy jóval nagyobb fényelnyelésük van a kék tartományban. Sőt, míg a PAR tartomány 400 nm-től 700 nm-ig terjed, addig például a klorofill A-nak (illetve B-nek) az UV-A tartományban is van fényelnyelése, mely akár duplája a zöld tartományban detektálható értékeknek.



19. ábra - Klorofill A és B abszorpciója

A $V(\lambda)$ -függvény logikájából kiindulva, mely az emberi szem érzékenységével súlyozza a spektrális adatokat, a klorofill elnyelési görbéket használtam súlyozás céljából, a maximális elnyelést véve 100%-nak. Ezzel a vezérlőtábla új elemként a klorofill a és b elnyelési görbéje alapján is súlyozza a spektrális eredményeket. A fotonfluxust pedig a PAR tartomány mellett 380-700 nm és 380-750 nm között is megadja.

Zárótábláján egy referencia spektrummal veti össze a mért eredményeket, kijelvezve hullámhosszak szerint bontva az eltéréseket. Ennek kialakításához 10 perces időintervallumokban mértem a Nap spektrumát 2019. augusztus 6-10. között. A mérések közül a 2019. 08. 09-i értékeket használtam, mivel ezen a napon végig derült, felhőmentes időszakot tudtam felvételezni. Ezek közül a délben detektált mérést használtam az összehasonlításokhoz, mely alacsonyabb értékű volt a későbbi 14 óra körüli csúcsoknál. Referenciaként használva, koncentrálna a klorofill elnyelésre 400-480, illetve 620-680 nm közötti tartományra, a vezérlőtábla valós időben, 10 perces mért adatokkal azonnal összeveti ezen referenciát. Amennyiben adott hullámhosszak esetén, vagy szakaszokra negatív értéket kaptunk, úgy elegendőnek vehetjük a besugárzást, míg amennyiben pozitív, úgy ezen fotonszám hiányzik az aktuális besugárzásból. Így amennyiben szabályozható LED rendszerünk van, elegendő ezen „hiányzó részt” pótolni egy toplighting rendszerrel, vagy interlighting megoldással. Mindezzel tovább növelhető a hatékonyság.

A vezérlőtábla működését többféle világítási rendszer mérésén keresztül mutattam be. Egyúttal vizsgálva két nagyteljesítményű LED rendszer (*KIND LED K5* és *Tungsram Research Modul*), egy fitotronban elhelyezett világítási rendszer (*SANYO*), egy HPS rendszer (*Sylvania Grolux*), illetve a Nap spektrális adatait mérve a fénytani paraméterek alakulását.

3.1.2.3 Beltartalmi paraméterek összevetése a spektrális adatokkal

Egyre többször felmerül a precíziós gazdálkodásban azon igény, hogy a minőségi paraméterek, azaz a beltartalmi adatokról mennyire tud megbízható információt nyújtani. Már nem elsősorban a hozamnövelés minden esetben a fő cél, különösen vertikális kialakítás mellett. Ezért megvizsgáltam, hogy a beltartalmi paraméterek közül léteznek-e már olyanok, melyek szignifikánsan előrejelezhetőek a spektrális adatokból.

3.1.2.3.1 Növényi vízstressz spektroradiométeres detektálása

Megvizsgáltam, hogy a távérzékelési indexek, spektrális adatok mennyire alkalmasak a vízstressz detektálására. Ehhez két növénynevelő sátrat alakítottam ki, nagyteljesítményű LED fényforrásokkal biztosítva a megvilágítást. A sátrakban paprika növényeket (*Capsicum annuum L.*) neveltem kőzetgyapot kockákon, sátranként 25-25 egyeddel. Az első hónapban mindkét sátorban ugyanolyan mennyiségű öntözést (50ml/növény/nap) és a második héttől kezdve tápoldat-adagolást alkalmaztam. Míg a 2. hónaptól kezdve a 2. sátorban nevelt növények fele annyi öntözést kaptak.

1 hónap elteltével végeztem el a méréseinket 3-szori ismétlésben az általam tervezett klipsz mérőfejet alkalmazva a *Qmini* spektroradiométerrel, illetve egy nagyobb spektroradiométerrel az *ASD Fieldspec 3* eszközzel, mely 350-2500 nm-ig képes detektálni.

A vizsgálat során az alábbi vízindexeket használtam: SRWI, WI, WI_{corrected}, NDWI, NDII, MSI, NDMI, LVI2, DSWI_5, WBI, melyek matematikai formuláit a 24. táblázatban láthatjuk (M5 melléklet)

A relatív víztartalmat analitikai laboratóriumban szárítószekrényben határoztam meg. A levéli mintákat összegyűjtöttem, majd lemértem a friss súlyukat (FW). Ezután desztillált vízben áztattam 4 órán keresztül, és lemértem a víztelített súlyt (SW, Water-saturated weight). Majd szárítószekrényben 80°C-on tömegállandóságig szárítva lemértem a száraz súlyt (DW, Dry weight). A relatív víztartalom meghatározásának céljából az alábbi egyenlettel dolgoztam:

$$RWC [\%] = \frac{(FW - DW)}{(SW - DW)} \cdot 100 \quad (3.15)$$

A spektrális indexeket megvizsgáltam összevetve az adott relatív víztartalmi (RWC %) eredményekkel, idősorosan is, az *Excel*-ben. Mivel a korábbi salátákat vizsgáló növénykísérletünk alkalmából is bevizsgáltuk a víztartalmat, így ezen adatokat is összevetettem az indexek szempontjából.

3.1.2.3.2 Nitrogén- és kálium tartalom meghatározása spektrális adatokból

Vizsgálataimhoz két zárt, növénynevelő sátorban, a *Tungstram Research* modul fényforrást alkalmazva, kőzetgyapot kockákon nevelve, két kertészeti növényfajt vizsgáltam: bazsalikomot (*Ocimum basilicum L.*) és salátát (*Lactuca sativa L.*).

Minden fajból 25 – 25 palántát indítva 5 kezelést alkalmaztam a tápoldat (Wuxal Super lombtrágya (N-tartalma 10 V/V%, P-tartalma 10 V/V%, K-tartalma 7,5 V/V%) mennyiségének változtatásával. Minden fajnak a számára megfelelő tápoldat koncentrációt előre meghatároztam, majd

0,5 ml/l-es mennyiséggel „hígítási sorozatot” alakítottam ki, így a 3. mintaszámot kapott növényeink kapták az optimális koncentrációjú tápoldat mennyiségét, az 1., 2. mintaszám ehhez képest 1 és 0,5 ml/l-mal kisebb, míg a 4. és 5. mintaszám 0,5 és 1 ml/l-rel nagyobb koncentrációjú tápoldatot kapott a 2. héttől kezdve. Így eltérő nitrogén adagolást kialakítva vizsgáltam a spektrális indexek nitrogénnel szembeni korrelációját.

A termesztési ciklus végével minden növényt lemértem a *Qmini* spektrométerrel (a klipsz mérőfej használata mellett), illetve egy nagyobb spektrométerrel az *ASD Fieldspec 3* eszközzel. A spektrális mérések során minden mérést háromszor ismételttem, majd ezek átlagértékeivel dolgoztam tovább. Mivel nem minden növényünk fejlődött megfelelően, így végül szinte minden fajnál 20 növényt tudtam vizsgálni. A spektrális indexek és adatfeldolgozás során elsősorban a *Qmini* adataival dolgoztam, csak a nagyobb hullámhossztartományban képezhető indexek esetében használtam az *ASD* adatait.

A kísérlet végén analitikai laboratóriumi mérésekkel az alábbi beltartalmi paramétereket kaptam meg: összes nitrogén tartalom (%), összes kálium tartalom (%), LAI érték, relatív víztartalom (%). Az összes N-tartalmat az alábbiak szerint határoztam meg: a kiszáritott és megőrölt növényi mintát H_2SO_4 oldattal (1 g mintához 10 cm^3 koncentrált oldat) roncsolva 1 napig, majd 10 cm^3 30 V/V%-os H_2O_2 oldatot hozzáadva addig melegítettem, míg elszíntelenedett. A roncsolatot 100 cm^3 -re feltöltöttem desztillált vízzel. Ezután egy szedőlombikba (20 cm^3 2 V/V%-os bórsav-oldatot pipetázva a lombikba, mely brómkrezolzöld-metilvörös keverékindikátort tartalmazott) desztilláltam (10 cm^3 törzsoldathoz 20 cm^3 30 V/V%-os NaOH oldatot adva), majd 1/140 mólos H_2SO_4 -val az oldat eredeti színéig titráltam. Végül a mérőoldat fogyásából kiszámítottam a növényi minta összes N-tartalmát. Az összes kálium tartalom analitikai meghatározásához emissziós lángfotometriai eljárást alkalmaztam.

Ezek közül a fontosabb paramétereket különböző statisztikai módszerekkel kezdtem el összevetni, összefüggéseket keresve az analitikai eredmények és a spektrális adatok között.

A kálium tartalom vizsgálata során a növényi minták analitikai laboratóriumban meghatározott összes kálium-tartalmának (%) eredményeit vettem össze a spektrális indexekkel. Az analitikai labormérések leíró statisztikáját is megvizsgáltam. Az N – K érzékeny hullámhosszakat lineáris korrelációs analízissel azonosítottam.

A spektrális minták közül adott mintákból kialakítottam egy validációs mintaegyüttest. Ezek laborértékeit használva futtattam a PLS-R modellt, keresve a további spektrális érzékenységet mutató tartományokat. Megvizsgáltam többféle matematikai átalakítást, így nem csak a kiinduló reflektancia értékeket vettem össze, hanem a normalizált, illetve az elsőrendű derivált értékeket is, akárcsak a korábbiakban. Mivel a spektrális indexek a legtöbb szakirodalomban eléggé nagy szórást mutattak, hogy mennyire hatásosak a kálium tartalom szempontjából, ezért megnéztem a spektrális görbék integrál értékeit is és ezeket is összevettem a labor eredményekkel. A kapott modelleket vizsgáltam a minták

másik részén, vizsgálva, mennyire megbízható általuk az előrejelzés. A modelleket a determinációs együtthatót (R), a szórásnégyzet, a relatív hiba szempontjából értékeltem.

3.1.2.4 A spektrális adatok kiértékelésének matematikai módszerei

A különféle spektrométerek mérési adatait a radiometriai kalibrációt követően különféle módszerekkel tudjuk kiértékelni, elemezni.

Elemzés céljából összegyűjtöttem a mérések spektrális eredményei esetén a maximumokat, illetve minimumokat, az ezekhez tartozó hullámhosszakkal, megadtam a spektrális görbe integrálját. Kijelölhető a mérés spektrális tartományától eltérő hullámhossz tartomány is, például a PAR tartomány. Ezen szűkítésre is elvégeztem a minimum, maximum, integrál értékeinek kalkulációit.

A reflektancia változásának mértéke a hullámhossz változás függvényében az elsőrendű derivált (FD) kiszámításával mérhető a legkönnyebben. Az elsőrendű derivált függvény használata számos tanulmány szerint segíti a további elemzéseket, mivel „egyszerűsíti” a spektrális görbéket, javítja a csúcsok detektálhatóságát (Nicolai et al., 2007). E révén az „érzékenyebb” hullámhossz tartományok könnyebben azonosíthatóak.

Az elsőrendű derivált az alábbi formula szerint számítható:

$$FD = \frac{R}{\lambda} = \frac{R_{y2} - R_{y1}}{\lambda_{x2} - \lambda_{x1}} \quad (3.16)$$

ahol:

FD – a spektrális görbe elsőrendű deriváltja

R_{y1} , R_{y2} – Az n_1 és n_2 értékpár reflektancia értékei

λ_{x1} , λ_{x2} – Az n_1 és n_2 értékpár hullámhossz értékei

n – pozíció a reflektancia görbén.

Az FD tehát könnyebben megmutatja az egyes hullámhosszak melletti reflektancia értékek változásának mértékét és irányát (Holden & LeDrew, 1998). A tipikus levél ~710 nm-nél fog csúcsot elérni az FD reflektancia szempontjából, a vörös él és a klorofill koncentráció közötti összefüggés miatt (Blackburn 2006). Munkám során minden mért spektrális eredménynél megvizsgáltam az FD görbét.

Illetve PLS-R módszerrel kerestem a további adott beltartalmi paraméterrel korrelációt mutató érzékenyebb tartományokat, és ezek eredményeiből új SR, és ND indexeket képeztem, vizsgálva ezek korrelációját is.

A fentiek mellett a GIS szoftverek is egyre nagyobb hangsúlyt fektetnek a spektrális elemzésekre, klasszifikációs és elemzési megoldásokra. Adott adatfeldolgozásnál megjelentek az objektum orientált elemzések. Mára már a legtöbbjük spektrális adatbázisokkal is dolgozik, egyéb elemzési funkciót is hozzákapcsolva. Jelen kutatásban a QGIS szoftvert használtam adott adatok elemzéséhez, vizsgálatához,

szemléltetéséhez, melyhez az *ORFEO* toolboxot, a *Spectral viewer*, illetve a *Semi-Automatic Classification Plugin (SCP)*-t alkalmaztam.

A statisztikai elemzéseket az *Excel* és ezen kiegészítő moduljával, az *XLSSTAT*-tal, illetve az *SPSS* szoftver (*IBM Corp.*, Armonk, NY, USA) segítségével végeztem. Az *XLSSTAT* érdekessége, hogy nemcsak a nagyobb statisztikai modellek futtatására alkalmas, hanem külön a spektrális analízisekhez kiegészítő lehetőséget is tartalmaz már, melyet akár hiperspektrális „adatkockák” elemzésére fejlesztettek. A változók normál eloszlását a Kolmogorov-Szmirnov-teszt segítségével vizsgáltam. Az adatokat egyirányú varianciaanalízis (ANOVA) tesztnek vettem alá, hogy megvizsgáljam például az eltérő nitrogén adagolás céljából az elemzett paraméterek és a spektrális indexek közötti korreláció mértékét. A spektrális indexek és a beltartalmi paraméterek közötti kapcsolatot Pearson-korrelációs együtthatóval és Duncan Multiple Range teszttel ($p < 0,05$) jellemeztem. Az érzékenyebb hullámhosszok további kereséséhez a PLS-R regressziós modellt alkalmaztam.

Számos szakirodalomban a *SAS* szoftvert javasolják a nagyszámú spektrális adatmennyiség feldolgozásához, melynek például a MAX-R modulja alkalmas a teljes spektrum minden egyes nanométerének bármely adattal történő elemzéséhez, illetve új indexek (2, 3, vagy 4 hullámhosszból képezve) kereséséhez. Ezen módszer elvét saját munkám során is követtem, mivel a szoftverrel nem rendelkezem.

Mivel a spektrális indexek számos távérzékelési adatfeldolgozást segítenek, automatizációs szempontból egyszerűsítik a nagy adatállományokat, viszont kiszámolásuk időigényes lehet, ezért két segédállományt készítettem, amelynek az volt a célja, hogy gyorsítsa a spektrális indexek megadását a későbbi elemzések céljából.

Egyik irányból a terepi spektrométeres mérések esetén egy számológépet hoztam létre, mely a későbbi munkalapjain a beolvasott mért értékekből automatikusan megadja a fontosabb víz indexeket, a fontosabb nitrogén indexeket, a korábbiakban látott klorofill indexeket, valamint előállítja a spektrális adatok elsőrendű derivált értékeit, kalkulálja a RedEdge tartomány minimum és maximum értékét, inflexiós pontját és meredekségét. Amennyiben az analitikai mérések is rendelkezésre állnak, úgy kialakítottam ezen adatok bevitelére is egy munkalapot, melyekkel minden munkalap párjaként vizsgálja az indexek korrelációját, és megadja az alapstatisztikára vonatkozó értékeket. Több, mint 50 spektrális index kalkulációját és adott esetben korrelációját végzi el egyszerre. (M6 számú melléklet)

A képi adatok feldolgozását segítő megoldásként, a *QGIS* nyílt forráskódú rendszerének használatához készítettem egy *JavaScript* kódot, melyet a megfelelő helyi könyvtárba másolva a program 'Raster calculator' algoritmusába épül. Használata során az összes indexet egy legördülő menüben megjeleníti a felhasználó számára, ezután bekéri a szükséges csatornákat és egyéb művelet nélkül regenerálja a kért index szerinti réteget. Ebbe összesen 20 spektrális indexet vittem fel, így mások számára is gyorsíthatóvá válik ezen feldolgozási lépés (CD melléklet). A *script* fájl a *QGIS* felhasználói

mappájának 'processing' (például C:/..AppData.../QGIS3/profiles/default /processing/) mappájába kell másolni, és ezután már elérhető a Processing Tollbox/RasterCalculator részbe épülve.

3.2 Új eszközhordozó rendszereken (UAV) alkalmazott multispektrális érzékelők összehasonlítása és adatfeldolgozási oldalról történő vizsgálata

Összehasonlító elemzéssel távérzékelési szempontból vizsgáltam az új eszközhordozó rendszereken (drónok) hordozott multispektrális kamerák pontosságát összevetve mind a műholdas távérzékelés pontosságával, mind pedig a spektrométeres mérések eredményeivel. A fentiek mellett az adatfeldolgozás módszereit vizsgáltam a közel valós idejű feldolgozás szempontjából, keresve azon lehetőségeket, melyek gyorsabb futtatási időt biztosíthatnak megfelelő pontosság mellett.

3.2.1 Drónokon alkalmazott multispektrális kamera mérési eredményének összehasonlítása a spektrométeres mérési eredményekkel

Távérzékelési oldalról vizsgálva a drónokon alkalmazott multispektrális kamerák kevesebb kalibrációt végeznek a gyakorlatban, elsősorban felszálláskor felvételezett kalibrációs lappal, szemben a terepi spektroszkópiában alkalmazott gyakori kalibrációval. Pedig mindkét rendszert passzív szenzorként alkalmazva ugyanazon kalibrációs igény adódna. Márka függően egyes multispektrális kamerákat már aktív napsugárzás mérővel szerelik fel, ezzel is javítva a pontosságot (például *Parrot Sequoia*), viszont létezik olyan márka is, mely csak egy kalibrációs fájl adatait használja a kalibrációhoz. Ezért különösen fontos a két módszertan pontosság szempontjából történő összevetése.

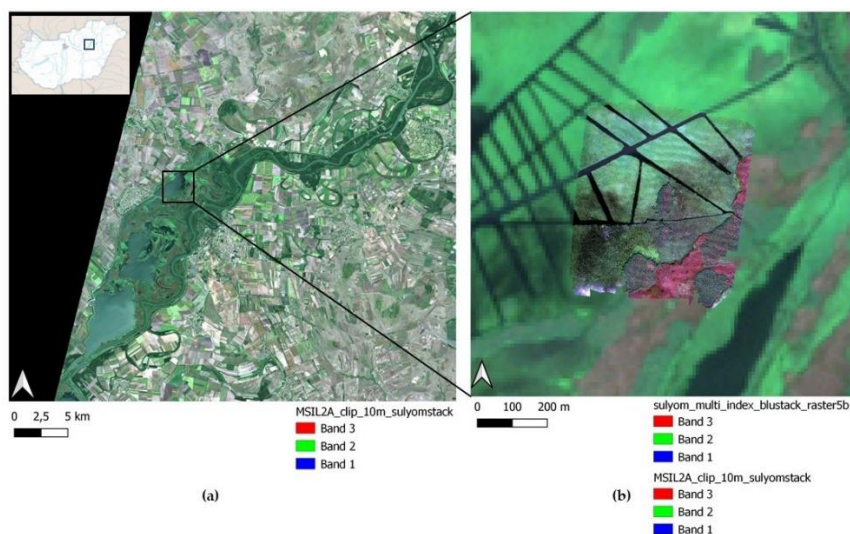
A spektrométeres mérési eredményekkel történő összehasonlításhoz a Harvard Dataverse adatbázisából a Wageningen Egyetem által végzett mérések nyers adatainak egy részét használtam. Az adatbázisból a *Sequoia* kamera állományait vettem össze két kereskedelmi forgalomban lévő spektrométer (*Cropscan*, *Tec5 Handyspec*) reflektancia mérési eredményeivel. A vizsgálat során egy időben, napon belül 7:25 és 20:00 között, 9 eltérő időpontban végezték el a méréseket, felvételezve két burgonya területet, két búzaterületet, egy árpa területet, a nyílt talajfelszínt, illetve több helyszínen, különböző méretű kalibrációs lapokat. Minden mérés során mindkét spektrométerrel és a drónon hordozott *Sequoia* kamerával is egyszerre mértek.

A nyers adatokat előfeldolgoztam, a képi állományból a mérési pontokra kinyertem a reflektancia értékeket, majd csatornánként varianciaanalízissel vizsgáltam az eltéréseket. Azt is külön megvizsgáltam, hogy változnak-e a drónnal mért adatok az eltérő optikai viszonyok között, azaz a napszaknak van-e hatása a mérések pontosságára, vagy kis szórás mellett, pontos távérzékelési eredményként tudjuk-e őket alkalmazni függetlenül a mérés időpontjától.

3.3.2. Drónokon alkalmazott multispektrális kamera mérési eredményének vizsgálata


A vizsgálathoz egy *Micasense Altum* hat csatornás multispektrális kamera mérési eredményeit használtam fel. A terepi mérés 2021. 09. 08-án lett felvételezve egy *DJI Matrice 210 V2 RTK* drónnal, három akkumulátorcserével (*DJI TB55* akkumulátor: 7660 mAh/db, párban használva egy

repüléshez). A felmért terület a Tisza-tó egyik sporthorgász, 25,5 ha területén volt (centroid koordinátái: Lat=N47.659, Lon=E20.717, EPSG=4326)(20. ábra). A mérést 70 méteres magasságban, a *Micasense* gyártói ajánlás szerinti 80%-os képi átfedést alkalmazva, az elkészült képeket 1,6 cm-es térbeli felbontás (GSD = 1,6 cm) jellemezte.



20. ábra - Tisza-tavi vizsgálati terület, Magyarország: (a) Sentinel-2 MSIL2A műholdkép valódi szinkompozitja az előfeldolgozás után; (b) Micasense Altum 5 sávós ortofotójának valódi szinkompozitja az előfeldolgozás után

A vizsgált növényborítási osztályok az alábbiak szerint alakultak: 1. osztály - sulyom (*Trapa natans*), 2. osztály - nád (*Phragmites australis*), 3. osztály - gyékény (*Typha angustifolia*), 4. osztály – víz felszín, 5. osztály - tündérrózsa (*Nymphaea alba*) és a 6. osztály - sás (*Carex acutiformis*). A lerepült terület terepi bejárását követően egy referencia növényborítási vektorréteget (21. ábra) hoztam létre. Az ellenőrzött osztályozás betanítása során ezen referenciaréteg 60% használtam validációként.



21. ábra - Referencia növényborítás képe a terepi bejárás alapján

A felvett UAV-felvételeket a *Pix4D* szoftver segítségével radiometrikusan kalibráltam (a kalibrációs lap felvételeit használva) és ortorektifikáltam. Ezután a *QGIS SCP* plugin segítségével többcsatornás képeket készítettem több változatban, egy 4 csatornás (RGB+NIR, 6 GB méretű), egy 5 csatornás (RGB+RedEdge+NIR, 8 GB méretű) és egy 6 csatornás (5 csatorna+termális, 10 GB méretű) változatot. A felvételezett adatállomány jellemzői: 6 x 940 db nyers kép, az előfeldolgozás után 6 x 1,56

GB egycsatornás ortomozaikolt kép, melyek 620 millió pixel adatpontot tartalmaztak csatornánként. Az adatállomány feldolgozása során alkalmazott munkamenet sematikus ábráját a M8 számú mellékletben láthatjuk.

Mivel az első adatfeldolgozási tesztek során a 4 és 5 csatornás verziók között nem volt jelentős időbeli különbség (míg a 6 csatornás verzió esetében drasztikus időnövekedés volt tapasztalható), így a későbbi vizsgálatokban az 5 csatornás képet használtam.

A területen domináns növénye a sulyom, emellett nagyobb foltokban nád és gyékény található, így viszonylag kis területet tudtam használni a sás és a tündérrózsa betanítására. A tündérrózsa esetében jellemző, hogy elszórtan találjuk. Ezt nehéz kezelni a betanítás során, emiatt a tündérrózsa (5. osztály) esetében két nagyobb "foltot" használtam, a sás esetében pedig csak egyet (6. osztály).

Az összehasonlító, illetve pontossági elemzések mellett az alábbi kérdésekre kerestem a választ:

- A két kisebb osztály (tündérrózsa – 5. osztály, sás – 6. osztály) kizárása esetén növekszik-e a pontosság a négy fő osztály esetében.
- A referencia réteg a nád esetében elnagyolt, azt feltételezve, hogy a teljes foltot nád borítja, míg a valóságban ez nem minden esetben teljesül. Érdekel, melyik megoldás képes jobban közelíteni ezen feltevéshez, és ezáltal a valós felszínborításhoz.
- Az előbbi felvetés logikája mentén a domináns növény esetén eltérő növényesség jellemzi a területet. A növényesség szintén nehezen betanítható, ezért megvizsgáltam, melyik megoldás képes jobban jelezni a valós növényesség eltéréseit.
- Egy elszórtan jelentkező osztály esetében (tündérrózsa), mely megoldás növeli a pontosságot.

Ezen kérdésekre adható válaszok segíthetik az adatfeldolgozási eljárások általánosabb használatát a precíziós mezőgazdaság szempontjából, például az UAV monitoring rendszerrel támogatott tápanyag-visszapótlást, vagy növényvédelmet érintő beavatkozásokat.

3.2.1.1 Összehasonlítása a műholdas távérzékelés mérési eredményeivel

A műholdas távérzékeléssel történő összehasonlítás céljából ugyanezen időpontra, ugyanezen területre vonatkozó *Sentinel-2 MSI2A* műholdképet dolgoztam fel (Copernicus⁶ oldaláról letöltve). Illetve mivel a *Micasense Altum* egy termális csatornát is felvételez, ennek vizsgálatának céljából egy *Landsat-8* műholdkép termális felvételét is bevontam az elemzésbe (EarthExplorer oldaláról letöltve). A *Landsat-8* képet atmoszferikusan korrigáltam, egyúttal a termális csatorna értékeit Celsius fok értékekre váltottam át, és pansharpening eljárással javítottam a térbeli felbontást. A *Sentinel-2 MSI2A* esetén a digitális értékeket spektrális reflektancia adatokra váltottam⁷. Ezután kivágtam a vizsgált és drónnal lerepült területet, hogy csak ezen résszel dolgozzak tovább az elemzési résznél.

⁶ <https://scihub.copernicus.eu/>

⁷ <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/overview>

Majd ugyanazon területek betanítása után az ellenőrzött képosztályozási algoritmusokat futtattam, majd utófeldolgozási lépésként leszűrtem az egyedül álló pixeleket, melyeknek kevesebb, mint 4 szomszédja volt. Az eredményeket pontossági elemzéssel hasonlítottam össze, vizsgálva a pontossági %-ot (osztályszinten és a teljes modellre) és a Kappa index értékét. A pontossági elemzés során az 21. ábra referencia rétegével összevetett eredményeket, illetve a két eljárást egymással szembeni pontosságát hasonlítottam össze.

A spektrális adatok elemzésének céljából 150 pontot jelöltem ki a területen, minden osztályon belül 25-25 ponttal. Az egyező csatornák esetén ezekre kigyűjtöttem a mért reflektancia értékeket, osztályonként átlagoltam és a varianciát vizsgáltam. A spektrális adatokat egy adatbázisba kezdem gyűjteni.

3.2.1.2 Képfeldolgozási algoritmusok értékelése a közel valós idejű adatfeldolgozás szempontjából

Az előfeldolgozás után az alábbi képosztályozási módszereket vizsgáltam az 5 csatornás képen futtatva. A nem ellenőrzött klaszterezést (ISODATA módszerrel), az ellenőrzött képosztályozás közül a legkisebb távolság (MD), a legnagyobb hasonlóság (ML) és a spektrális szög (SAM) algoritmusait, a gépi tanulás megoldásai közül a Random Forest (RF), a mesterséges neurális háló modelljét (ANN) és a Support Vector Machine (SVM) LibSVM modelljét, illetve a mélytanulás esetén a konvolúciós neurális háló (CNN) modellt.

Az nem ellenőrzött, illetve ellenőrzött osztályozási algoritmusokat, illetve a Random Forest gépi tanulás modelljét a *QGIS SCP* plugin és az *ESA SNAP* segítségével futtattam. A felügyelet nélküli klaszterezési osztályozást az ISODATA módszerrel futtattam (Zheng & Sun, 2008; Sirat et al. 2018). Az eljárás a kép képpontjai közötti spektrális távolságot használja, hogy a képpontokat meghatározott számú egyedi spektrális csoportba sorolja. A futtatást a következő beállításokkal végeztem: távolságküszöb 0,01, az osztályok száma 6, az iterációk maximális száma 10, a standard eltérés 0,2, és a minimális osztályméret pixelben 10. A 'seed signature from band values' opció mellett futtattva, a távolsági kalkuláció algoritmusaként pedig a SAM algoritmust választottam. A Random Forest modellt a következő beállításokkal alakítottam be: képzési minták száma = 5000, fák száma = 10 és az 'becsült értékelés' opciót választottam. A plugin egy konfidenciaszintet jellemző rasztert is létrehoz, ahol láthatjuk az osztályozási hibákat, ha a pixelek konfidencia értéke alacsony.

Az ANN osztályozás futtatásához az *ORFEO Toolbox* eszköztárat alkalmaztam. Az ORFEO-ban a következő beállításokkal futtattam: az osztályozási módszer típusa back-propagation volt, a neuron aktivációs függvény típusa szimmetrikus szigmoid, és minden más beállítást alapértelmezettként használtam.

Az SVM modellhez a LibSVM módszert (Chang & Lin, 2011; Haridas, et al. 2015; Li et al., 2019) használtam, amely a 'minimális szekvenciális optimalizációs' (SMO) algoritmust implementálja

kernelizált SVM-re. Az SVM osztályozás beállításaihoz az SVM kernel típusához polinomiális, a modelltípushoz 'csvc' értéket állítottam be, és a paraméterek optimalizációját elvégző opció aktív futtatásával, az összes többi beállítást alapértelmezettként használtam.

A mélytanulási megoldáshoz az *ORFEO-TensorFlow* környezetet használtuk, a CNN modellt Rémi Cresson (2019) tanulmányában ajánlott módon építettem fel és futtattam.

A közel valós idejű automatizációt segítő megoldás szempontjából 2 gépi konfigurációt alakítottam ki egy 4 GB, illetve egy 8 GB DRAM kapacitással (további informatikai paraméterei megegyeztek: I5 CPU kapacitás, *Windows 10* operációs rendszer és a használt *QGIS* szoftver 3.22-es verziója). Ezen memóriára vonatkozó jellemzők állnak legközelebb az automatizáció során használt mikro- és miniszámítógép egységekhez. Ezen konfigurációkon párhuzamosan futtattam az algoritmusokat vizsgálva futtatási idejüket.

Pontosság elemzés céljából a 21. ábra referencia rétegével összevetve vizsgáltam a pontossági %-ot (osztályszinten és a teljes modellre vizsgálva), a Kappa indexet⁸, illetve keresztklasszifikációval a helyes és helytelen pixelek területi arányát. A jobb futtatási eredményeket adó algoritmusok esetében az osztályozást 6 osztály, illetve 4 osztály (a sást és tündérrózsát kizárva) bevonásával is összehasonlítottam, vizsgálva a pontosságra vonatkozó hatásokat.

A felsorolt algoritmusok mellett megvizsgáltam a PCA elemzés lehetőségét, mivel mind a terepi spektroradiométeres, mind pedig a hiperspektrális adatok feldolgozásánál általánosan használt megoldás. Egyik előnye, hogy nagy adatmennyiséget esetén (jelen esetben a térbeli felbontásból adódóan) egy egyszerűsített adatállományt generál, miközben a főbb tulajdonságbeli különbségeket megtartja. Bár képi állományokon egyelőre ritkábban alkalmazzák, megvizsgáltam ennek futtatási jellemzőit és pontosságát, illetve eredményeit bevontam egy *Python*-ra épülő döntési fa szabályrendszer kialakításába.

Kiindulva a valós és hamisszínes képi vizuális elemzések adott osztály esetén tapasztalható vizuális eredményeire, illetve az NDVI leképezést, kombinálva a hőmérséklettel egyedi tulajdonságokat tudtam megfigyelni. Ilyen tanulóterületet, tanulószabályokat viszont nehéz egyelőre megoldani, mivel az osztályozás alapját egy „csatorna lista” értékei adják, melybe ugyan eltérő rétegeket is össze tudunk kapcsolni, de például, a mértékegységet csak egységesen lehet egyelőre beállítani (hacsak nem teljes *Python* kódsorral dolgozunk).

Lehetséges megoldás lehet az egyedileg kialakított döntési fa, melynek háttére egyrészt egyszerű matematikai és logikai operátorok alkalmazása raszteres állományokon (mint a 'Raster calculator' használata során), de ötvözi az adatbázisrendszerek és egyéb programnyelvek esetén ismert 'If' ciklus

⁸ A Kappa index megmutatja annak mértékét, hogy az osztályozási eredmények hogyan viszonyulnak a véletlenül hozzárendelt értékekhez. Az együttható 0 és 1 közötti értékeket vehet fel, ha 0-0,4 közötti ezen eredmény az rossznak tekinthető (a 0-s Kappa azt jelenti, hogy nincs különbség a megfigyelt és a véletlen között). A 0,4 és 0,75 közötti Kappa értékek középeztől jóig terjednek, a 0,75 feletti Kappa pedig kiváló egyezést jelent.

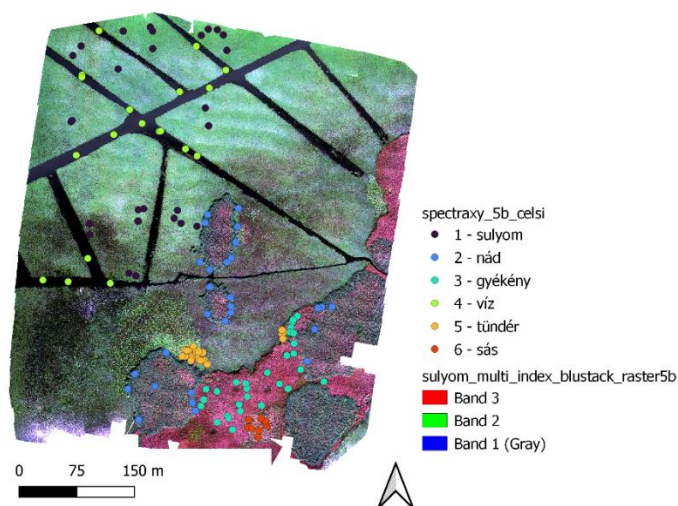
logikai felépítését. Lényegében egy döntési szabályrendszert szerkesztünk, minden új sor egy-egy szabály, melyekbe többféle feltételt egyszerre kialakíthatunk. A futtatás során a rendszer pixelenként vizsgálja az első szabály teljesülését, és amennyiben teljesül, hozzárendeli az általunk megszabott új értéket (egyelőre egész számot), amennyiben pedig nem teljesül továbblép a következő szabályra, és így tovább. Amennyiben egyik szabállyal sem talál egyezést, akkor egy külön osztályba sorolja majd ezen pixeleket. Azaz egy saját döntési logika szerinti újfajta képosztályozást tudunk e révén elérni.

A szabályrendszer létrehozása során 5 egyedi tulajdonságot kerestem minden osztály esetén. Az egyedi tulajdonságok kialakításához egycsatornás rétegeket használtam, így a reflektancia rétegeket, a PCA eredményeit, az NDVI réteget és a termális réteget vontam be az elemzésbe. A reflektancia rétegekre kialakított szabályok kialakítását a valós, illetve hamisszínes egycsatornás és többcsatornás eltérő kompozitok értékelése segítette. Ezen szabályrendszert az első öt osztályra, a sás kizárásával alakítottam ki. Az egyedi tulajdonságok nem estek egybe az alapstatisztikai értékekkel (minimum, maximum, átlag). A döntési fa eljárás osztályozási eredményeit is bevontam a pontosság vizsgálatba. Megvizsgáltam a legkisebb osztály szempontjából a szabályrendszer sorrendjének megváltoztatásával elérhető eredményeket, keresve azon kialakítást, mely révén növelni tudtam a legkisebb osztály osztályozási eredményeinek pontosságát.

A vizsgálathoz a *QGIS* szoftver *SCP* és *ORFEO* plugin-jét, a mélytanuláshoz az *ORFEO-TensorFlow*-t használtam.

3.2.1.2.1 Raszteres képi állományok spektrális vizsgálata

Az osztályozáshoz használt tanulóterületek spektrális adatait összegyűjtöttem, majd átlagoltam és .csv formában kigyűjtöttem egy adatbázisba. Emellett egy pont vektoros állományt hoztam létre, melyhez 150 pontot manuálisan célzottan jelöltem ki az osztályok területén (22. ábra). Ezen rétegre kimentettem a koordinátákat, illetve a spektrális és termális értékeket, majd átlagoltam, és megvizsgáltam ezek szórását, illetve eltérésüket a tanulóterületek előbb gyűjtött adataitól.



22. ábra - Vektorpontok (150 db) elhelyezkedése a célterület adatgyűjtési céljából

A fentiek mellett megvizsgáltam a spektrális távolság összehasonlításához használt 4 fő függvényt: a Jeffries-Matusita távolság függvényét, a spektrális szög függvényét, az euklideszi távolság függvényét, illetve a Bray-Curtis hasonlóság függvényét. A fenti vizsgálatokba mind a *Micasense*, mind pedig a *Sentinel-2* műholdkép adatait bevontam.

4 EREDMÉNYEK

4.1 Terepi alkalmazás fejlesztés eredménye és összehasonlító eredményei

4.1.1 Az elkészült prototípus végleges verziója


Az állvány révén 360°-os állítható elfordulás mellett fix 45°-os szögben, regisztrálható és állítható magasságban képesek vagyunk mérni.



23. ábra - Asztali állvány képe, mely forgatható, a rögzítés 45 fokban tartja a spektroradiométert, a tartórúd több méretben cserélhető

Gyakorlati oldalról vizsgálva a prototípus mérőfej révén közel hasonló pontokat tudunk visszamérni a levélen. Azáltal, hogy passzív szenzorunk aktívvá válik, kevesebb kalibrációt igényel a terepi használata során, mivel fix távolságok, szögek, és állandó fénytani környezet jellemzi. A terepen sokkal gyorsabb mérést tesz lehetővé az állványnál, mivel kevesebb időt vesz igénybe a műszer és a mérendő céltárgy beállítása.

Hasonló eszközök elérhetőek ugyan a nagyobb márkáknál, mint például az ASD cég *Plant Probe* terméke, de áruk rendkívül magas, és a félgömb kialakítást egyik márká sem alkalmazta a korábbiakban, mely ötvözi a diffúz spektroszkópia megközelítéseit. Ezen fejlesztéssel egy elérhetőbb árú megoldást érhetünk el, mely nagyobb pontosságot, egyszerűbb terepi használatot és ismételhető mérési lehetőséget biztosít a kutatóknak.



24. ábra - Az AUTOCAD szoftverben elkészített klipsz mérési adapter modell képe többféle nézetből (balról 3 db kép), végleges, cserélhető verzió (jobbra)

A prototípus végleges verziójában a mérőfej kapott egy alátámasztást, mely révén könnyebben rögzíthető a fényforrás. Cserélhetővé téve a mérőfejet, melyet többféle egyéb kialakításban is tovább lehet fejleszteni (például bogyós termések vizsgálatának céljából), egyúttal segíti a 3D nyomtatás pontosabb kivitelezését. A háromdimenziós modell elérhető bárki számára és továbbfejleszthető, reprodukálható. A CD melléklet tartalmazza a modell *.stl* fájlját.

4.1.2 Csatlakoztatás Raspberry Pi mikroszámítógéppel

A driverek telepítése sikerült, a csatlakoztatott spektroradiométert a *Windows10 IoT* kameraként érzékelték és az áramellátását ellátta.



25. ábra - Raspberry Pi-hez csatlakoztatott Qmini spektroradiométer, internet eléréssel, egérrel és TFT kijelzővel bővítve

4.1.3 Összehasonlító mérések ASD Fieldspec 2 Plant Probe mérőrendszerrel

A két műszer méréseinek egymással szembeni eltéréseinek átlaga 0,08 eredménnyel volt jellemzhető, míg a legnagyobb eltérés 0,48. A két rendszer méréseinek korrelációs együtthatója $R=0,98$. A mérésekre jellemző REP (Red Edge Point) értékeket eltérését összesítve az 6. táblázatban láthatjuk.

6. táblázat - ASD Fieldspec 2 és Qmini méréseinek REP-re vonatkozó összehasonlítása

REP átlag - klipsz (nm)	Eltérések átlaga	Eltérések a REP átlag százalékában (%):
718,005	1,118	0,156
REP átlag - ASD (nm)		
718,156		


Az eredmények alapján megállapítható, hogy a két műszermegoldás megfelelő pontossággal helyettesíti egymást. Eszerint az általunk tervezett és gyártott klipsz megfelelő pontossággal rendelkezik a terepi vizsgálatokhoz.

4.1.4 eltérő megvilágítási környezetben végzett vizsgálatok eredményei

4.1.4.1 LED rendszerek és a HPS rendszer összehasonlítása

A növénykísérleteket megelőző összehasonlító elemzés során a környezeti adatok eredményei szerint a hőmérséklet átlag 10 °C-kal, míg a páratartalomra vonatkozó adatok 20%-kal magasabban alakultak a HPS rendszerrel (*Sylvania GroLux*) kialakított sátor esetén. Ezért ennél a rendszernél külön fogyasztásként jelentkezik a ventiláció, illetve a megnövekedett öntözési igény, melyet a LED rendszer esetén nem kellett üzemeltetnem. A kiegészítő rendszerek révén közel egyező klimatikus viszonyt tudtam kialakítani a későbbi növénykísérletek során.

Mindkét lámpa spektrális adatait az alábbi ábrákon láthatjuk (26. ábra).



26. ábra - KIND K5 és Sylvania Grolux 600W HPS besugárzásának (a.) és fotonfluxusának (b.) összehasonlító mérésének eredményei

A spektrális adatokról látszik, hogy a HPS lámpa központi csúcsai a zöld tartományba (és a vörös első harmadába) esnek, míg a LED rendszer esetén a kék, illetve a piros tartományba. A másik fő eltérés a NIR-ben látható, ahol a HPS rendszernek van egy intenzív csúcsa (820 nm), míg a LED esetében nincs, viszont a távoli vörösben (740 nm) láthatunk emelkedést a LED-nél. Míg a fényintenzitás esetében 50%-kal magasabb irradianciát detektáltam, addig a fotonfluxust vizsgálva már több mint 75%-os volt az eltérés. Megmértem mindkét lámpa esetén a PPF értékét a növény szinten, ebből megadtam a fényátalakítási hatékonyságukat. A rendszer árába a HPS esetén a szükséges IP66 szabványú trafót, reflektort, lámpafoglatot számítottam hozzá (2016-os áron), míg a LED panel esetén nem volt szükség kiegészítőkre. A villamos fogyasztási adatokat 1 hónapos időintervallumon mérve (a 2016-os lakossági díjszabással (40 Ft/kWh) számítottam). Csak a lámpák fogyasztását mutatja a mért érték, míg összességében elmondható, hogy a ventilátorok és a megnövekedett öntözés üzemeltetése is villamos energia fogyasztási többletet jelent. Az így elérhető, pusztán a fogyasztásból keletkező megtakarítással adtam meg a rendszer megtérülését (7. táblázat), az inflációt nem kalkulálva az árakban.

7. táblázat - HPS és LED rendszer összesített adatai a rendszer megtérülés szempontjából

	villamos teljesítmény [J/s=W]	mért PPF [$\mu\text{mol/s}$]	η [$\mu\text{mol/J}$]	Rendszer ára [Ft]	1 havi villamos fogyasztás [mért kWh*40 Ft/kWh]	megtakarítás 1 év alatt [Ft/év]	Megtérülés [év]
HPS	600	593	0,98	85800	25080		
KIND K5	430	816	1,897	299200	7310	213240	1,4

Az adatokból az is látszik, hogy egy LED rendszer ára először nagyobb beruházás. Ezen LED rendszer esetén az is elmondható, hogy egy gazdálkodó számára nem feltétlenül szükséges az állíthatóság, mely számunkra a kísérletek miatt fontos szempont volt. A nem állítható LED rendszerek ára, pedig a fele lett volna az állítható rendszerek árához képest. A megtérülést azon többlet is javítja (a LED javára), mely a nagyobb fotonfluxus révén esetlegesen megnövekedett biomassza produktumként is jelentkezne. A 2022-ben kialakuló energiakrízis miatt megnövekvő villamosenergia díjjal is

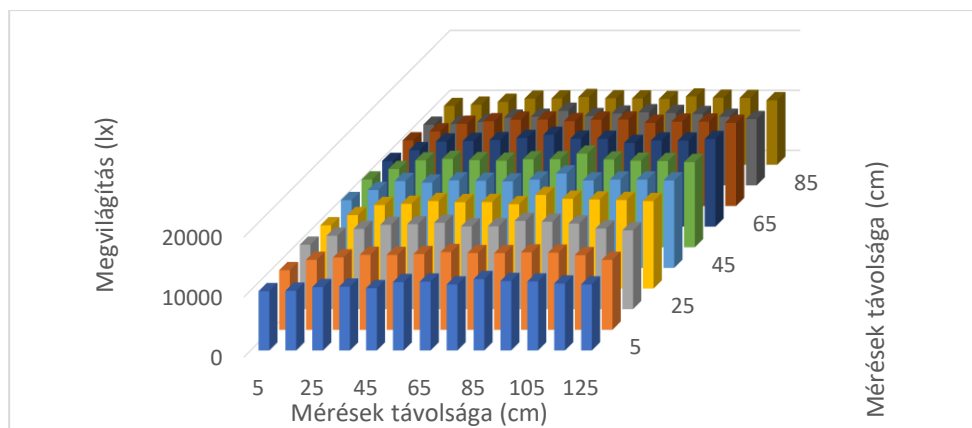
megvizsgáltam a megtérülés számítását. A 2022-es rendszerárak szerint a HPS rendszerek ára kicsit csökkent, míg a *KIND* LED külföldi beszállítása miatt az árfolyamváltozások közel duplájára emelték a rendszer árát (ugyanakkor már a hazai piacon is számos eltérő nagyteljesítményű növényházi LED panel található, mely 2016-ban még nem volt jellemző). A villamos energia piaci árát viszonylag nehéz jelenleg megbecsülni, mivel az adott szolgáltatótól függ és változó. Az MVM Next oldalán közölt 4 nagyobb szolgáltató csúcsidőszaki átlagolt árával kalkuláltam, ami jelenleg 104,75 Ft/kWh (2022. július).

8. táblázat - HPS és LED rendszer összesített adatai a rendszer megtérülés szempontjából (2022-es adatokkal frissítve)

	Rendszer ára [Ft]	1 havi villamos fogyasztás [mért kWh*104,75 Ft/kWh]	Megtakarítás [Ft/év]	Megtérülés [év]
HPS	61000	65678,25		
KIND K5	558000	19143,1	558421,8	~1

A drasztikus energia áremelkedés következtében a fogyasztási különbségből adódó megtérülés egy évre módosult a korábbi közel másfél évről a LED rendszerek javára. Amennyiben a hazai piacról választunk hasonló műszaki paraméterekkel rendelkező nagyteljesítményű növényházi LED rendszert, úgy javul ezen érték.

A LED lámpák fényeloszlásának vizsgálati eredményei az mutatták, hogy a *KIND K5* esetén akár 30%-kal kevesebb fényt biztosít a lámpa a szélek és a sarkok felé. Ezen ok a műszaki kialakítással magyarázható. A LED rendszerek esetén nagy hangsúllyal bír, hogy mivel kicsik a „lámpatestek”, ami ezáltal szűk térszögbe koncentrálni fényáramukat, ezért a gyártók különböző szórólencsékkel látják el a diódákat, mellyel megnövelik ezen térszöget. Tervezéskor számolnak az átfedésekkel, így a szorosan felhelyezett diódák fényáramai egymást is átfedik, így a lámpa adott távolságban vizsgált fényösszetétele egységesebbé válik és növekszik a megvilágítás erőssége. A *Tungsrám Research Modul* esetén a lámpatest olyan kialakítást kapott, hogy a hátsó, oldalsó reflektor felületek hatására és a sík üvegfelület révén egységesebb területi eloszlást érjen el. Ezzel szemben a *KIND* minden dióda fölött 120 fokos szórólencsékkel alakította ki a lámpatestet, ezzel a lámpa középső régiója alatt nagyobb megvilágítást ér el, viszont a szélek felé csökken a megvilágítottság, mely különösen a sarkok felé erősödik (27. ábra).



27. ábra - KIND K5 lámpa alatti terület megvilágítási erejének mérése 50 cm-es távolságból

A lámpa mérésének alapstatisztikai elemzését a következő táblázatban foglaltam össze.

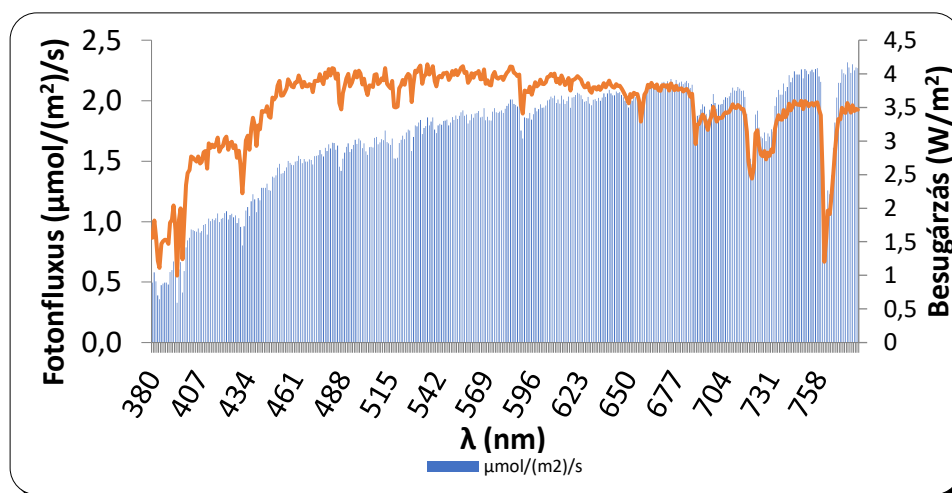
9. táblázat - KIND K5 területi megvilágításának statisztikai összefoglaló táblázata

Várható érték	12955,01
Standard hiba	144,224
Medián	13260
Módusz	14580
Szórás	1644,406
Minimum	9790
Maximum	15750
Darabszám	130
Konfidenciaszint(95,0%)	285,3506

Így a sarkok mentén, illetve a szélek felé a kisebb megvilágítottság kisebb növényi növekedéssel társulhat.


4.1.4.2 Fény jellemzésére alkalmazott mérőszámok megadása a spektrális adatok alapján

Hogy szemléltessem a besugárzás (W/m^2), illetve a fotonfluxus fizikai paraméterek közötti különbséget készítettem egy szemléltető ábrát (28. ábra), melyhez a Nap spektruma szolgáltatja a mérési adatokat.



28. ábra – A Nap besugárzása és fotonfluxusa, mérés időpontja: 2019.08.06., Qmini

Mivel a hosszabb hullámhossz felé haladva kisebb az adott hullámhosszúságú fotonok energiája, így a fenti ábrán is jól láthatjuk, hogy „ugyanannyi” energiát, több mólnyi foton képes csak szolgáltatni, így a fotonok száma a hosszabb hullámhosszak felé növekszik. Többféle lámpatest mért adatainak összehasonlítását a következő ábrán láthatjuk.



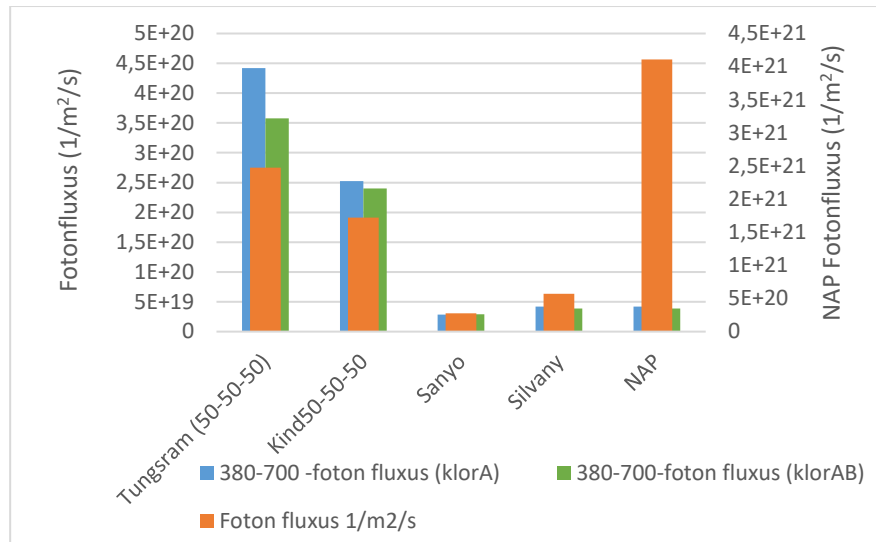
29. ábra - 4 mesterséges világítási rendszer és a Nap (2019.08.09) mért értékei alapján számolt eredmények bemutatása a vezérlőtábla használatának segítségével

A fenti ábrán két HPS rendszert (*SANYO*, *Sylvania Grolux 600W*), illetve két nagyteljesítményű LED rendszer adatait láthatjuk a 380-780 nm közötti mért adatokra összegezve. Az adatok alapján itt is elmondható, hogy a HPS rendszereket hiába nagy villamos teljesítmény jellemzi, a növények számára fontos tartományon belül mindkét vizsgált paraméterben elmaradnak a vizsgált LED rendszerektől. A HPS rendszereknek a NIR tartományban (26. ábra, 800 nm után) van további csúcsa, illetve hőkamerás mérésekkel igazolható, hogy a termális infravörös tartományban is magas kisugárzás jellemzi őket. Ez utóbbi okozza a nagy hőtermelést, mely miatt nagyobb távolságban lehet kihelyezni a lámpát a növényzóna felett és kis légtérfogat esetén kiegészítő hűtést, illetve egyéb klimatizációs beavatkozást igényel.

A vizsgált lámpatestek kalkulált lux értékeit és spektrumuk hullámhossz maximumával vizsgálva elmondható, hogy míg a HPS rendszer besugárzása és fotonfluxusa jóval elmaradt a vizsgált LED rendszerek mért értékével, addig a lux értékben magasabb értéket ért el a *Sylvania Grolux 600W* HPS lámpa (ezt spektrális jellemzői is megerősítik, a zöld tartományban adva a maximumot, míg a LED rendszerek összeállítása általában ezen tartományt minimalizálja). Amennyiben az emberi szem érzékenységével ($V(\lambda)$ függvény) súlyozzuk, még nagyobb lesz ezen különbség.

A vezérlőtábla a teljes beérkező, mért fotonfluxust újrvizsgálja a klorofill-a és b elnyelési tartományai szerint, majd összegzi ezen értékeket. A PAR tartomány ugyan lefedi a vizsgált tartományokat mégis egyre kevésbé alkalmas a pontosabb összehasonlításra. Amint a 29. ábrán is látható,

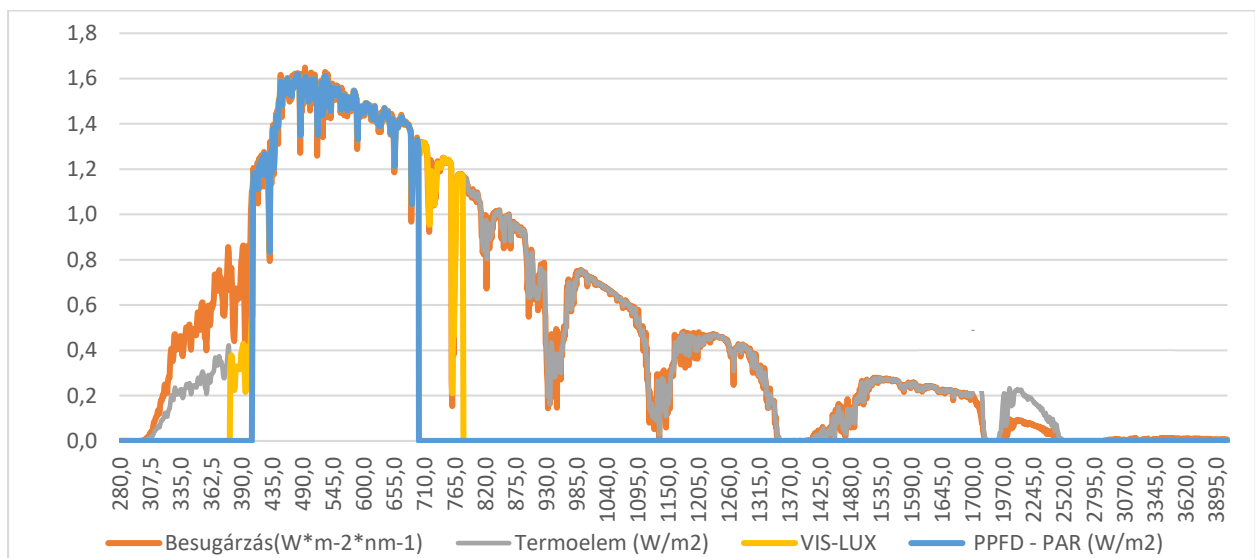
hiába „magas” a HPS PAR aránya, ha a klorofill elnyelési szakaszokat alig érinti, azaz hiába a nagy teljesítmény, a magas lux, a megfelelő besugárzás, ha a klorofill elnyelési sávokban minimális fotonszámot tud előállítani.



30. ábra - Vizsgált fényforrások klorofill A-B-re súlyozott fotonfluxusa

A fent bemutatott spektroradiométerrel mért spektrális adatokat, illetve az ebből kalkulálható fénytani paramétereket használhatjuk egyszerű vezérlésre. Az itt leírt modell egy egyszerű, fizikai megközelítés. Gondolok itt arra, hogy a szenzorfejünk mérete kicsi, mégis ezt vetítjük (m²) terület egységre. Emiatt meghagytam kisebb területi egységben is, hogy későbbiekben, akár mindez egy területi eloszlásban tovább finomítható legyen.

Hogy érzékeltessem az eltérő rendszerek mit is érzékelnek, az alábbi Nap mérés (mérés ideje: 2019. 08.09., helyszín: Budai Kampusz, B épület teteje) modelljének ábráján összehasonlíthatjuk.



31. ábra - Nap mérésén modellezett eltérő szenzorérzékenységek

A vezérlőtábla logikai felépítését, illetve munkatábláit a M4 számú mellékletben lehet részletesebben megtekinteni. A működő teljes vezérlőtábla a CD mellékleten található.

4.1.4.3 Konica Minolta SPAD 502 mérőrendszerrel végzett összehasonlító mérések eredményei

Összesen 165 salátanövény (*Lactuca sativa L.*) levelét vizsgáltam meg, mind a prototípus mérőfejjel, mind pedig a SPAD méterrel, majd ezen értékeket vettem össze az analitikai mérés eredményeivel. Pár növény spektrális reflektancia görbáját a 72. ábrán (M7. melléklet) láthatjuk.


A statisztikai elemzéseket a laboreredményekkel összevetve készítettem el, melyen a SPAD mérés eredményeit is megvizsgáltam. A kétmintás párosított t-próba eredményeit összefoglalva az alábbi táblázatban kiemeltem a fontosabb korrelációra vonatkozó eredményeket.

10. táblázat - Klorofill indexek klipsszel mért értékeinek, illetve a SPAD méter adatainak kétmintás t-próbával történő statisztikai összevetése a laboreredményekkel (kivonat a korrelációs és varianciára vonatkozó eredményekre)

	Várható érték	Szórás	Megfigyelések	Pearson-féle korreláció	R ²
Klorofill a+b	33,85	22,84	165		
CI _{green}	2,39	1,06	165	0,94	0,88
MTCI	0,17	0,02	165	0,99	0,97
MCARI	0,36	0,05	165	-0,83	0,69
NDVI	0,78	0,06	165	0,58	0,33
MCARI2	0,63	0,28	165	0,98	0,97
CCI	12,84	6,49	165	0,92	0,85
CI _{rededge}	0,15	0,014	165	0,99	0,97
SPAD	32,52	12,1	165	0,96	0,93

A statisztikai elemzés szignifikáns ($\alpha=0,05$) és szoros korrelációt mutatott az analitikai összes klorofill tartalom és a klorofill előrejelző indexek között. A legjobb klorofill előrejelző indexnek a CI_{rededge} index bizonyult (R=0,99), míg szorosan követi az MTCI (R=0,98), illetve az MCARI (R=0,98). Ezen három index magasabb korrelációt ért el a SPAD méter által detektált értékeknél, azaz pontosabban előre tudják jelezni a klorofill mennyiségét. Ezáltal azt is bizonyítottam, hogy a spektroradiométer mérés képes helyettesíteni a SPAD métereket.

Ezen kísérlet másik érdekessége a sátrak között tapasztalható különbség. Míg az első 100 növényi minta a *KIND K5* (1-52-ig), illetve a *Tungsram* szabályozható LED rendszer alatt (53-105-ig) növekedett, minden környezeti paraméter közel egységes értékei mentén (mindkét lámpa esetén a beállításokat úgy tettem meg, hogy közel azonos megvilágítási érték jellemezze a növényzónát), addig a 100-165 közötti minták a HPS rendszer alatt fejlődtek. Ez utóbbi sátrnál a környezeti paramétereket (hőmérséklet, páratartalom) csak kiegészítő rendszerekkel tudtam beszabályozni, de mivel a növénynevelő sátor kis légtérű, így a növényi stressz hatásaként értékeltem az eltérő növényi fejlődést, mely meglátszik a növények klorofill-tartalmán is. Ezt a levélfelület indexek is alátámasztották, melyek szintén elmaradtak, vagy nagyobb szórást mutattak a HPS rendszernél.



32. ábra – Klorofill-tartalom változása, illetve a spektrális klorofill index

A lámpák hatásának elemzését is elvégeztem a statisztikai módszerek bevonásával. Míg a két LED rendszer között nem volt szignifikáns eltérés, addig a HPS rendszer és a LED rendszer között igen. A *KIND K5* LED esetében a kismértékű növényi szórást a területi fényellátottság korábban bemutatott különbségei okozták a szélek, és elsősorban a sarkok irányában. A két LED rendszer között azért sem mutatható ki ezen kísérlet során nagyobb eltérés, mivel az állítható spektrum révén közel azonos megvilágítási erősségre voltak szabályozva. Amennyiben 100%-os üzem mellett hasonlítottuk volna össze őket, várhatóan nagyobb különbséget detektáltam volna. A *KIND K5* ugyanis jóval nagyobb fényerőt képes elérni összességében a *Tungsrám* lámpával szemben, viszont ennek elsődleges oka a két lámpa „célnövényének” különbsége, míg a *KIND K5* egy kimondottan fényigényes növény igényeire fejlesztett lámpa, addig a *Tungsrám* általam használt modulja kertészeti növények igényeire lett kialakítva (a cég palettáján ennél nagyobb megvilágítást elérő változat is megtalálható lenne).

4.1.4.4 Beltartalmi paraméterek összevetése a távérzékelési adatokkal

4.1.4.4.1 Spektrális adatok kiértékelését segítő automata segéd tábla eredményei

Az automata adattáblát kétféle változatban készítettem el, egyiket 200-1050 nm-ig terjedő mérésekhez igazítva, míg a másikat 200-2500 nm-ig terjedően. Felépítésének és működésének részleteit a M6 számú mellékletben láthatjuk. A működő teljes számolótábla a CD mellékleten található. Mindkét változat jelenleg 250 mérés egyszeri kezelését teszi lehetővé, de a későbbiekben ez tovább bővíthető (jelenlegi tapasztalatom szerint ezen adatmennyiséget tudott még nagyobb „késések” nélkül is kezelni a szoftver, de természetesen mindez a felhasználó informatikai „számítási kapacitásától” is függ.)

4.1.4.4.2 Vízstressz korrelációja a spektrális adatokkal

A korábbiakban bemutatott vízindexek statisztikai alapelemzését végeztem el először. A Pearson féle R értéket az alábbi táblázatban foglaltam össze. Kiemeltem azon indexeket, melyek a legjobb eredményeket adták.

11. táblázat – A jobb korrelációs eredményeket mutató vízindexek R-értékeinek összefoglaló táblázata

Indexek	R
NDMI	0,91
NDWI	0,913
WI (900/970)	0,79
WI (970/900)	-0,79
MSI	-0,91
LVI2	0,94
1200/850	-0,77
1450/850	-0,92
1650/850	-0,89
(970-900) / (970+900)	-0,79
(970-850) / (970+850)	-0,57
970-880	-0,8
SRWI (860/1240)	0,68
970-920	-0,87
NDWI (960-1240)	0,69
<i>CIrededge</i>	0,43

Láthatjuk, hogy a vízindexek többsége negatív korreláció mellett értelmezhető.

A fenti táblázatban is látszik, hogy emellett PLS-R elemzéssel vizsgáltam a további érzékenyebb tartományokat. Ezen elemzést az elsőrendű derivált értékein is elvégeztem. A legérzékenyebb hullámhosszokból képezhető SR, illetve normalizált változatokat is megvizsgáltam. És ezen indexeket is láthatjuk a fenti, illetve későbbi táblákban. Az alábbi táblázatban az elsőrendű deriváltból képzett legjobb öt Pearson-féle korrelációt mutató indexet mutatom be.

12. táblázat - Elsőrendű deriváltból képzett indexek legmagasabb R értékű eredményeinek összefoglalója

Index	R-érték
MSI	-0,9056
LVI2	0,9398
1450/850	-0,9217
1650/850	-0,8936
970-920	-0,8736

4.1.4.4.3 Nitrogén kezelések korrelációja a spektrális adatokkal

A nitrogén tartalom vizsgálata céljából végzett kísérlet beltartalmi paramétereinek alapstatisztikáját az alábbi táblázatban foglaltam össze.

13. táblázat - Nitrogén és egyéb beltartalmi paraméterek laboreredményeinek alap statisztikai értékeinek összefoglalása

	N % sz.a.	LAI g/m ²	Víz g/m ²
min	0,705	16,1	111,52
max	6,075	52,52	262,57
átlag	3,13	32,728	156,618
szórás	1,436	8,998	30,703
Variációs koefficiens %	45,884	27,4939	19,604
n	81	81	81
Medián	3,035	31,09	152,51

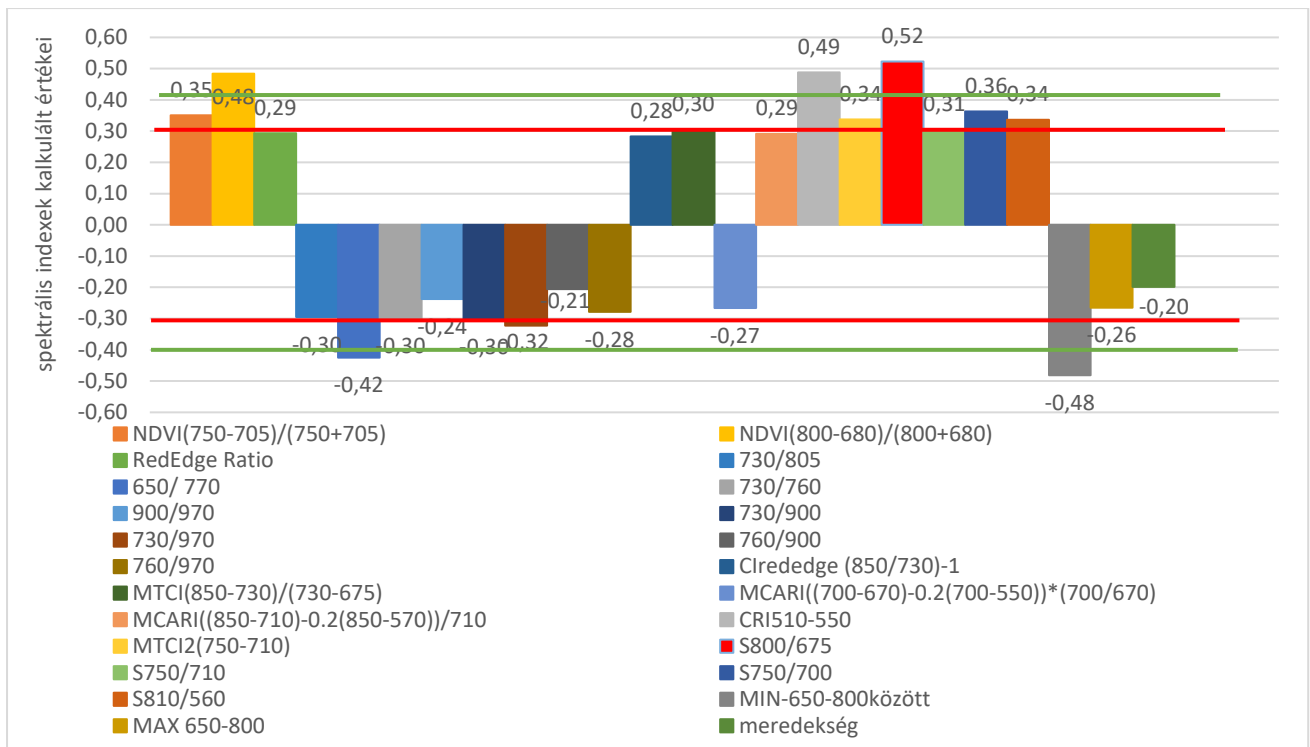
Míg a nitrogén tartalom nagyobb változékonyságot mutat, addig a relatív víztartalom, vagy a levélfelületindex kisebb variációs együtthatóval jellemezhető.

A spektrális indexek elemzésekor elkészítettem az elsőrendű derivált függvényeket. Vizsgáltam a RedEdge inflexiós pontot (REIP), illetve nanométerenként kerestem az „érzékenyebb” tartományokat. Ennek alapjául a SAS szoftver MAX-R módszere adta az alapot, így minden egyes változó (esetünkben az elsőrendű derivált függvény hullámhosszak szerinti mért adatait használtam) Pearson-féle korrelációs együtthatójának halmazából kiválasztottam a magasabb értéket mutató hullámhosszakat. A legnagyobb korrelációs hullámhosszakból manuálisan képeztem szimpla (SR) és normalizált változatokat, és ezek esetén is megvizsgáltam az összefüggés mértékét.

Az spektrális reflektancia függvények elsőrendű derivált függvényeit az 73. ábra (M7 számú melléklet) szemlélteti.

A nitrogéntartalmat a szárazanyag tartalom százalékában mértem és ezzel vettem össze spektrális indexeinket. Az általam keresett „érzékenyebb” hullámhosszak a 800, 710, 675, 560 nm-re estek. Ezen tartományokból újabb indexeket képeztem, illetve a RedEdge tartományt vizsgáltam meg nagyobb fókusszal.

Sajnos egyik index esetében sem mutattak az indexek nagyobb szignifikáns összefüggést (33. ábra), pusztán közepes értékelést értek el.



33. ábra - Nitrogén indexek korrelációs együtthatói a laborban detektált nitrogén szárazanyag-tartalommal

A legjobb korrelációt mutató indexeredményeket a SR-indexek adták, ezek közül minden index magasabb, mint $R = 0,34$ értéket ért el. A legjobb az SR800/675 index lett, mely 52%-os korrelációs értékkel volt jellemezhető, így ez lett vizsgálatunk legjobb megoldása, míg a CRI 510/550 $R = 0,49$, és az NDVI $R=0,48$ eredményt mutatott. Érdekességként kiemelném, hogy a külön vizsgált 650-800 nm közötti tartomány minimum reflektancia értéke is hasonlóan jól korrelált a nitrogén tartalommal ($R = -0,48$), mely a vörös tartományon belül a 671 nm körül jelentkezett a legtöbb esetben (módusz: 671 nm, medián: 669 nm), és véleményem szerint a klorofill-tartalommal (klorofill elnyelési tartományával egybeesik) függ össze.

A lámpák hatásait a növényi növekedésre a nitrogén szárazanyag-tartalom laboreredményeit összevetve az alábbi ábrán szemléltetném az eredményeket, mely szintén alátámasztja, hogy a HPS rendszer alatt fejlődött növényeink jóval nagyobb növekedési szórást mutattak, mint a *Tungsram* LED alatt.

4.1.4.4.4 Kálium tartalom vizsgálatának eredményei

Összegezve az alábbi táblázatban emeltem ki a legjobb eredményt hozó indexeket.


14. táblázat - Kálium tartalom becslésére alkalmazott spektrális értékek legjobb eredményei a korreláció szempontjából

Index	R-érték
NDVI (750-705) / (750+705)	-0,463
SR1385-1705	-0,422
SR1705-1385	0,422
ND1705-1385	0,413
Integrál – 400-1000 nm között	0,426

A spektrális vizsgálatok során megfigyeltem, hogy a SWIR tartomány jobb korrelációt mutat, a szimpla ráció indexek és a normalizált indexek közül is találtam jobbnak bizonyulókat. Legjobb eredményt a 750 – 705 nm-en képzett normalizált index adta. Ezt követte az egyik integrál érték korrelációja. Ebben az esetben megnéztem a teljes spektrum integrálját, illetve szűkebben is megvizsgálva 400-1000 nm, 400-500 nm, 500-600 nm, 600-700 nm, és 600-800 nm közötti tartományokra. Ezek közül a legmagasabb értéket a 400-1000 nm adta, ami abból a szempontból is jó, hogy a kisebb spektroradiométerekkel is mérhető ezen tartomány. Az atomspektroszkópiában gyakran vizsgálják a kálium ionokat a rövidebb tartományokban, például 208 nm, 257 nm-nél. Megvizsgáltam ezen tartományokat is, de nem kaptam megfelelő eredményt, melynek oka az is lehet, hogy a *Qmini* ugyan mér már ezen tartományban, de mérései még túl nagy zajt tartalmaznak, így nem vehető figyelembe. A nagyobb *ASD* spektroradiométer pedig nem is mér ezen tartományban.

Másik szempontból vizsgálva az adatokat, mivel a tápoldatozás során különféle dózisokat adagoltunk, így ezen hatást is megvizsgáltam a parciális legkisebb négyzetek diszkriminancia-analízisével (PLS-DA), hogy a különböző kezelések spektrálisan elválaszthatóak-e egymástól. A megkülönböztető változókat a változó fontossága a vetítésben (VIP) értékek alapján választottam ki, és amennyiben a $VIP > 1,0$ a csoportos megkülönböztetés szempontjából relevánsnak tekinthető.

Az alábbi ábrán pár minta reflektancia spektrumát és az adott hullámhosszak, illetve a laborban mért kálium tartalom korrelációs koefficiensét szemléltetem.



34. ábra – Növények reflektancia görbéinek összevetése a kálium tartalomra vonatkozó korrelációs együtthatóval

Ez alapján 3 tartomány szűkebb vizsgálatára fókuszáltam. Az ezekből kiinduló kalibrációs és predikciós PLS-R modellek R^2 értékei a K-tartalomra vonatkozóan a 0,80, illetve 0,67 közötti eredményt hoztak. A teljes spektrumon futatott PLS-R analízis VIP értékei szintén ezen tartományok esetén voltak a legnagyobbak. Az előbbiekkal szemben a csoportosítás céljából futtatott PLS-DA előrejelzésként alkotott regressziós modellek pontossága nem volt túl pontos és nem adott szignifikáns eredményt. Viszont az elmondható, hogy könnyebben el tudjuk különíteni a szélső értékeket, mint a normál adagolást, azaz a stresszhelyzetek előrejelzéséhez alkalmasak lehetnek. Ezen belül elsősorban a hiányt tudtam nagyobb pontosság mellett előre jelezni a reflektancia értékek alapján, amit az alábbi táblázat is szemléltet. Azon növényeinket, melyek a legkisebb koncentráció mellett kapták a tápoldatot, így nagymértékű kálium hiány is fellépett, ezeket nagyobb valószínűséggel el tudtam különíteni.

15. táblázat- PLS-DA modellek kálium tartalom becslési pontossága a reflektancia értékek alapján

	legkisebb dózis	optimális tápoldat	kétszeres dózis	előrejelzett	összes helyes %
legkisebb dózis	16	8	11	35	45,7
optimális tápoldat	8	9	10	27	33,3
kétszeres dózis	9	16	10	35	28,6
aktuális	33	33	31	97	
aktuálisból helyesen előrejelzett %	48,5	27,3	32,3		

4.2 Drónok a terepi távérzékelés új eszközhordozóihoz kapcsolódó vizsgálatok eredményei

4.2.1 Terepi spektroszkópia és drónfelvételezés összevetése

Az adatokból elsősorban a növény és talajfelszín vizsgálati pontjainak eredményeit láthatjuk a következő ábrákon, a zöld, piros, RedEdge, illetve NIR-csatornák bontásában, a teljes mintaállományra, illetve az egyes szenzorok szerinti bontásban is.



35. ábra – Spektroradiométeres mérések összevetése a Sequoia multispektrális szenzor több időpontban történő méréseivel, a szórást vizsgálva, csatornák szerinti bontásban: a.) zöld tartomány; b.) vörös tartomány c.) RedEdge tartomány d.) NIR tartomány


A zöld, piros és RedEdge-csatorna eredményeiről elmondható, hogy összevetve az összes szenzort (RedEdge esetén a maximális érték 0,13) a szórás viszonylag alacsony szinten alakult, míg a NIR-csatorna esetében megugrik, bár ezen értéket a drón *Sequoia* kamerája befolyásolta leginkább (1,5-1,6-os értékével), míg a spektroradiométerek esetében ezen csatornánál láthatjuk a legkisebb szórást.

A *Sequoia* kamerára jobban fókuszálva az alábbi táblázatban láthatjuk az egyes csatornák maximális variációját, mely szintén kiemeli a NIR-csatorna kiugrását.

16. táblázat - Sequoia kamera több időpontban történő felvételeinek csatornánkénti maximális szórása


	max.szórás
Green	0,000678
Red	0,007089
RedEdge	0,022929
NIR	2.79971

Amennyiben a kamera NIR-csatornájának időbeli lefutását vizsgáltam az alábbi eredményt kaptam.



36. ábra - Sequoia kamera különböző időpontokban jellemző, NIR-csatornában mért reflektancia értékei különböző felszínborítások esetén

Ez alapján egy erőteljes változás rajzolódik ki a délelőtti, illetve délutáni órákban, viszont megvizsgálva ugyanezen lefutást a többi csatorna esetén, ezeknél nem tapasztaltam hasonló trendet. Például a RedEdge-csatorna időbeli változásait szemlélteti a következő ábra, melyen nem látunk a NIR-rel egyező időbeli változást.



37. ábra - Sequoia kamera különböző időpontokban jellemző, RedEdge-csatornában mért reflektancia értékei különböző felszínborítások esetén

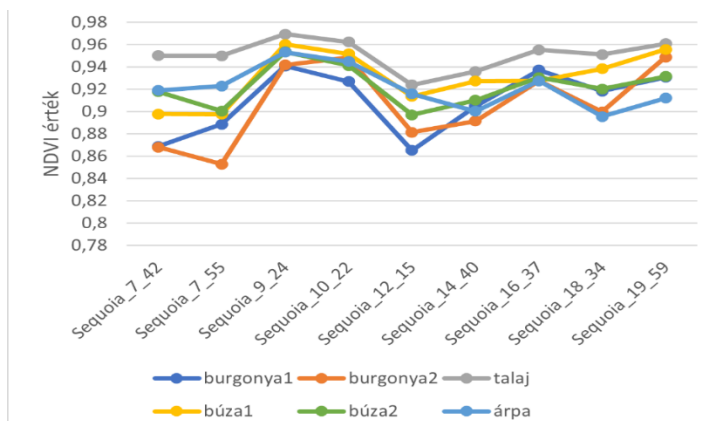
A NIR-csatorna mérési eredményeiben történő ily mértékű változás, melynek minimum, maximum, átlag és variancia értékeit az alábbi táblázatban összesítettem a felszínborítások szerinti bontásban.

17. táblázat - Sequoia kamera NIR-csatornában mért reflektancia értékeinek minimumát, maximumát, átlagát és varianciáját jellemző értékek

	min	max	átlag	variancia
burgonya1	4,026	8,623	6,256	2,636
burgonya2	3,967	8,853	5,977	2,614
talaj	3,956	8,54	6,095	2,659
búza1	4,269	8,9	6,456	2,8
búza2	4,665	9,517	6,562	2,792
árpa	4,698	9,248	6,716	2,756

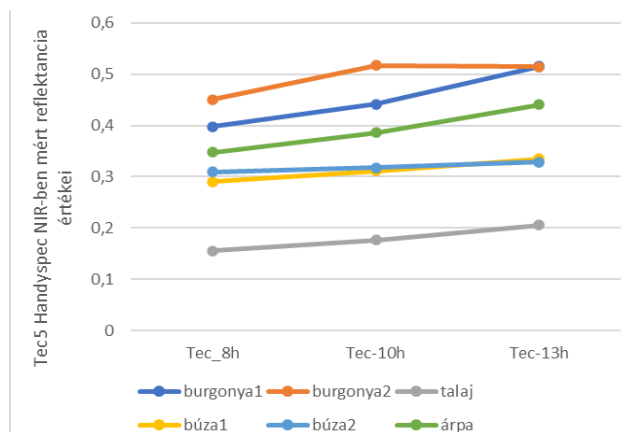
Mivel a minimum és maximum értékek adott esetben napon belül akár kétszeres értéket is elérhetnek, és a további csatornákon nem látszik hasonló változás, így specifikusan csak erre a csatornára érdemes lesz figyelni, és további méréseket, elemzéseket végezni ez irányba. A felszínborítás kevésbé befolyásolja az eredményeket, elsősorban a napszaknak, azaz az optikai hatásoknak tulajdonítanám az eltéréseket.

Véleményem szerint, bár a szórás kismértékben jelzi, a minimum és maximum értékek alapján amiatt fontos ennek további vizsgálata, mivel a NIR-csatorna rendkívül fontos épp a növényvizsgálatok szempontjából. Gondolva akár a spektrális indexekre, melyek többsége alkalmazza kombinációiban ezen csatorna tulajdonságait. A jelen mérés alapján kalkulált NDVI index értékeit láthatjuk az alábbi diagrammon, melyek a drónkamera által napon belüli mérések eltéréseit mutatja.



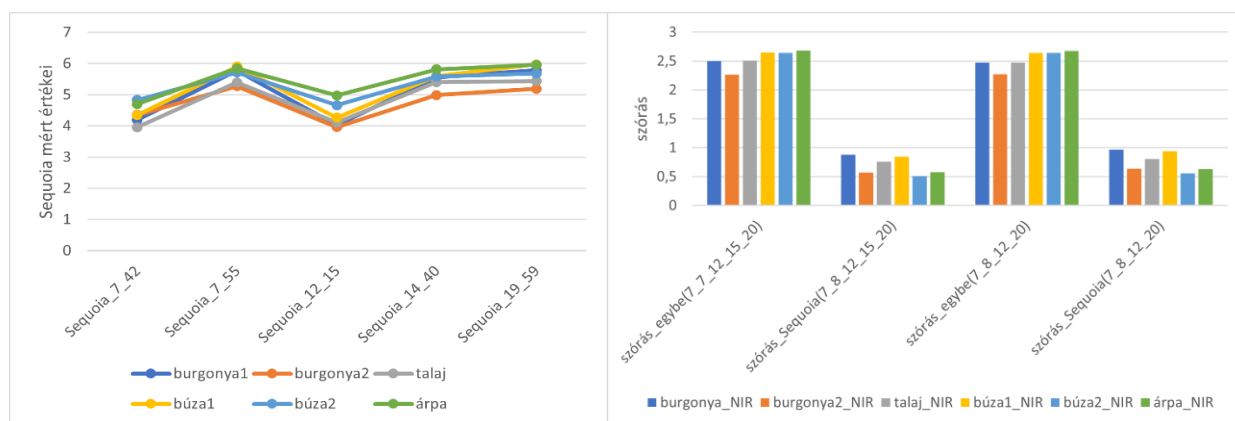
38. ábra - Sequoia kamera mért értékei alapján kalkulált NDVI index értékei különböző felszínborítások esetén

Megvizsgáltam a spektroradiométer időbeliségét is ezen csatornára fókuszáltn, de ezen esetben sem tapasztaltam hasonló eltérést.



39. ábra - Tec5 Handyspec spektrométer NIR-csatornában mért reflektancia értékeinek időbeli eltérései különböző felszínborítás esetén

Véleményem szerint ez nagyobb valószínűséggel valamilyen környezeti, vagy működési módszertannal összefüggő hatás és nem feltétlenül szenzorspecifikus jellemző, bár ennek eldöntése további vizsgálatokat igényel. A legvalószínűbb, hogy optikai hatás okozza, mivel napon belül a fényforrás beesési szöge folyamatosan változik, míg a kamera felvételezési szöge elméletben fix. Ezen hatás miatt fontos a passzív terepi rendszerek gyakori kalibrációja. Ráadásul a *Sequoia* kamera, távérzékelési oldalról vizsgálva, az egyik legjobb kalibrációs megoldást alkalmazza (kalibrációs lap felvétele és aktív napfénymérés). Doctor, et al. (2015) goniométerekkel vizsgálta eltérő spektrális szenzorok mérési eredményein a napszak hatásait. Arra az eredményre jutva, hogy ajánlásuk szerint déli időben célszerű a spektrométerekkel, és esetünk szerint akár a multispektrális kamerákkal is mérni. Ha az előbbi adatsorunk esetén kizárjuk a 9, 10 és 17 órás méréseket, akkor ez is megerősíti ezen felvetést.



40. ábra - Sequoia kamera NIR-csatornában felvételezett adatainak időbeli lefutása és szórása a reggeli, déli és koraesti mérések alapján (kizárva a délelőtti, illetve délutáni méréseket)

A fenti ábrákon látszik, hogy a 9-10 órás és 17 óra körüli méréseket kizárva drasztikusan javult a *Sequoia* NIR-csatornára jellemző eredményeinek szórása (1 alá süllyedve), míg a spektrométeres mérésekkel összevetve is csökkent a mért eredmények közötti eltérés (a korábbi 3 feletti szórás 2,5 körül mozog). Az is látható az ábrán, hogy a három óra körüli mért értékek kizárása alig változtattak meg az eredményeket, így ezen időszak ajánlott az ilyen irányú drónos méréseket a későbbiekben tervezni.

Természetesen ezen eredményt célszerű lesz továbbvizsgálni, és ha ismétlések mellett, más szenzorok esetében is megfigyelhető, akkor nagyobb valószínűség mellett lehet ezen optikai hatás az okozója, így ezek alapján azon módszertani ajánlást tehetjük, hogy lehetőleg déli órákban, esetleg korareggel (8 óra körül), vagy koraeste (19:00-20:00 óra körül) javasolt ezen mérési eszközrendszer használata. Amennyiben a vizsgálat tárgya a növényzettel kapcsolatos többnyire a déli időszak lesz a fő javasolt időintervallum.

4.2.2 Micasense Altum (UAV) kamera eredményeinek értékelése

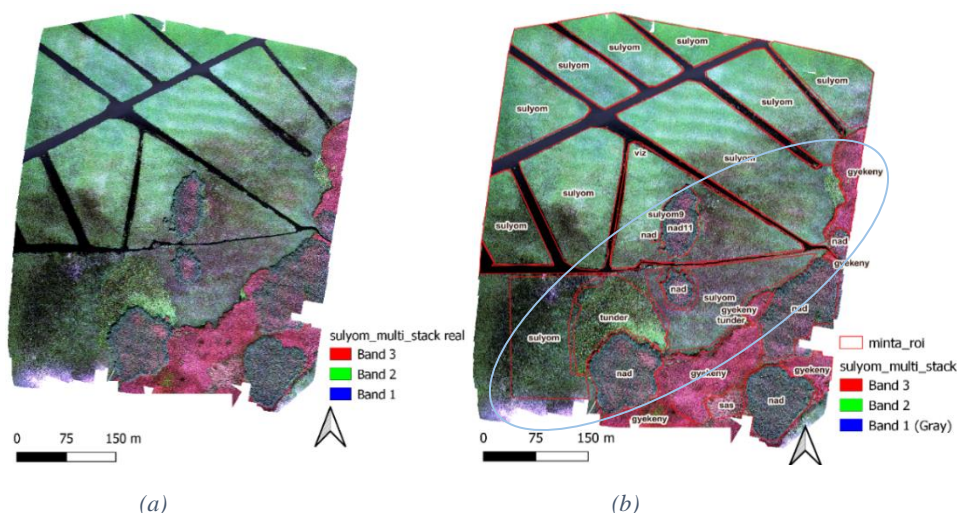
Az ortorektifikáció több, mint 24 órát vett igénybe (egy I5 CPU, 8GB RAM konfiguráció mellett) a Pix4D szoftverrel. Az így elkészült hat csatorna (R, G, B, NIR, RedEdge, LWIR) ortofotója csatornánként 2,3GB-os, teljes terjedelemben 10,4GB-os állományt jelentett, a segédállomány pedig több, mint 20 GB-ot igényelt.

A QGIS SCP pluginjének 'Bandset' legördülő menüjének forráskódját két kódrészlettel kiegészítettem, mellyel már a Micasense kamera jellemző spektrális adatai is elérhetőekké válnak a legördülő menüben, ez elsősorban a jövőbeli munkát segíti és gyorsítja majd. (a kódot a M11. mellékletből bárki hasonlóan alkalmazhatja, és a későbbiekben további drónkamerák jellemzőivel is bővíthető.)

4.2.2.1 Különböző csatornák eredményei

4.2.2.1.1 Valós színes kép és az egyes csatornák értékelése

Az alábbi képeken láthatjuk az eredeti ortofotó valós színes képét (balra), illetve a rávetített referenciaterületeket (jobbra).



41. ábra – a) Valós színes ortofotó a Tisza tavi drónfelmérés alapján; b) referenciaterületek

A kép alapján az alábbiakat emelném ki:

- A 'pirosas' árnyalatú területek a gyékénnyel borított felszíneket jellemzik. A kép közepén jellemző nádfoltok területének belső részén vegyes növényborítást láthatunk, bár szemrevételezés alapján a terepen ezek nádként lettek azonosítva. A valós színes kép alapján itt szintén lehetséges


a gyékény jelenléte. Másik magyarázat lehet, hogy a pirosas árnyalat a szárazabb növényi részekre lesz jellemző, ez pedig mindkét növényre jellemző.

- A világoskék ellipszissel jelzett sáv sulyom borítottsága nem oly mértékben összefüggő, mint ettől feljebb. Mivel a felvételezés egyik kérdése az volt, hogy lehetséges lenne-e a sulyom időbeli változásának vizsgálata, adott esetben nem csak a területi kiterjedés, hanem a sűrűség irányában is, ez ezek alapján lehetségesnek tűnik. Bár ez utóbbit, még nem feltétlenül lesz egyszerű betanítani egy ellenőrzött osztályozási metodika szerint. A valós színes kép alapján a növekvő víz pixelek száma jelzi a kisebb növényi sűrűséget, így ezen területen magas lesz a kevert pixelek aránya, mely nehezíti majd az osztályozást.

Amennyiben nagyobb nagyítású képet (42. ábra) vizsgálunk láthatjuk, hogy a nagy térbeli felbontás mely előnyöket jelent. Egyrészt jelen esetben a sulyom felszínén mesterségesen vágott útvonalakkal teszik átjárhatóvá ezen területet, ezek képzik a vízfelszín szabályos útvonalait. Viszont láthatjuk a vékonyabb fekete vonalakat adott területeken (a kép közép-bal alsó szegmensében), melyek szintén csónakkal megtett útvonalak. Ezen láthatóság pedig hasznos lehet egyéb területeken is, akár az állatállomány vonulási vizsgálataihoz, vagy az illegális tevékenységek leleplezéséhez.

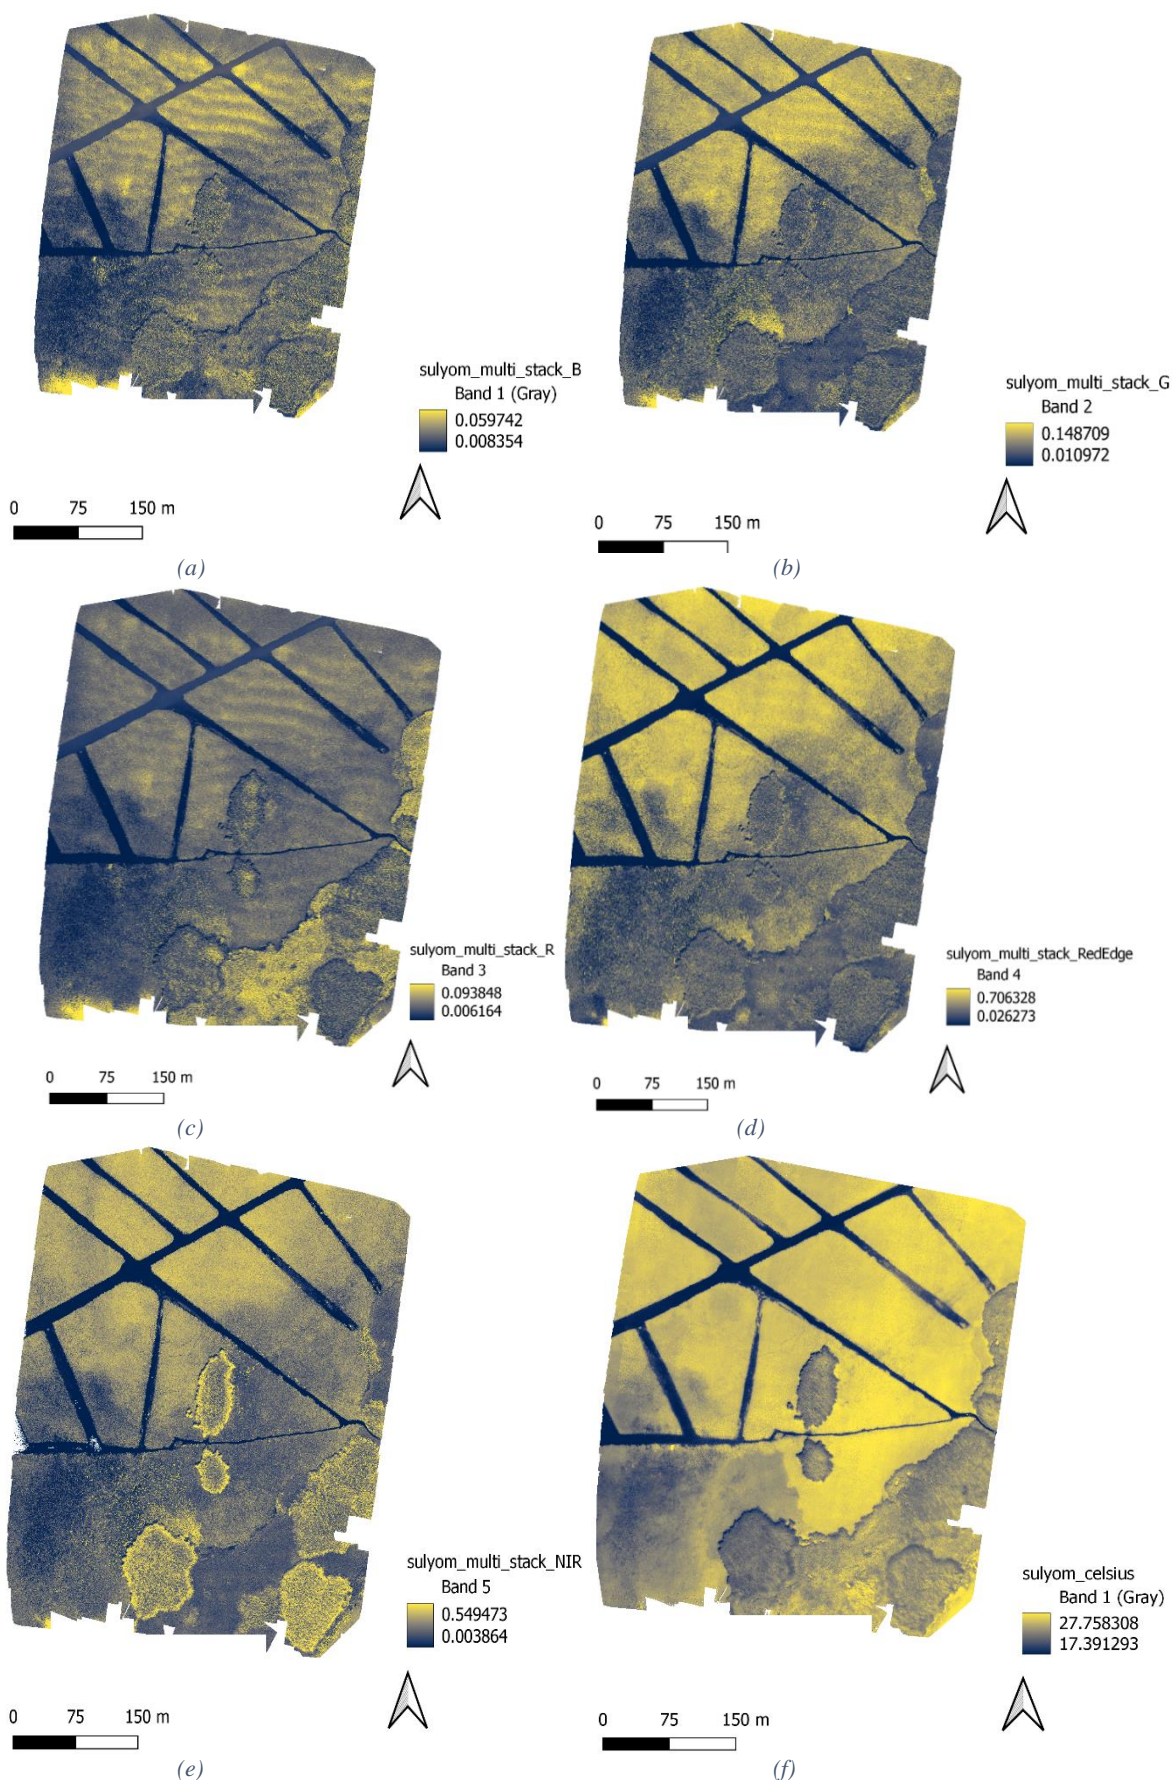
A kép jobb alsó körrel jelzett területén a tündérrózsákat látjuk, mely egyúttal azt is jelenti, hogy ezen repülési paraméterek mellett már jól detektálható ezen kisebb növény is, és egyúttal kidolgozható rá keresési, detektálási módszer, mely a későbbi időbeli terjedést, előfordulást is segítheti.

A 3. tényező, melyet kiemelnék a kép alapján, hogy a piros ellipszisek mentén könnyen megfigyelhető a sulyom újbóli terjedése. Azaz ezen felbontás ennek időbeli detektálását is vizsgálhatóvá teszi jóval nagyobb pontossággal, míg ez műholdas távérzékeléssel nagyon drágán, nehézkesen, és kisebb pontossággal lehetne vizsgálni (az ingyenesen elérhető felbontással pedig szinte lehetetlen).



42. ábra - Micasense Altum Tisza tavi felmérésének képrészlete (zoom)

Az egyes csatornák szerinti hamisszínes vizualizációkat egységes stílusra állítottam az alábbi képeken, így könnyebben tudjuk egymáshoz viszonyítva vizsgálni.



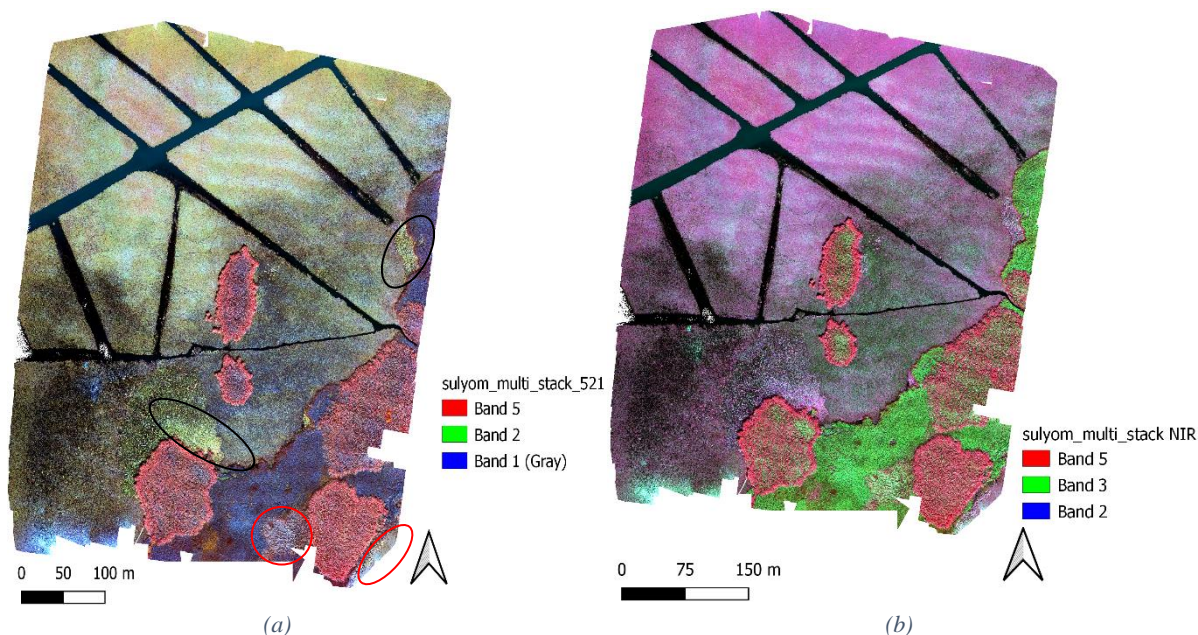
43. ábra - Micasense Altum Tisza tavi felmérésének hamisszínes képei csatornák szerinti bontásban: a) kék-csatorna; b) zöld-csatorna; c) vörös-csatorna; d) RedEdge-csatorna; e) NIR-csatorna; f) termális csatorna

A reflektancia értékekre fókuszáló hamisszínes képek szemrevételezési értékelése során az alábbi megállapításokat emelném ki:

- A valós színes kép esetén is látható volt egy enyhe csíkozottság a sulyom felső harmadában, mely csak a látható tartományok esetén látható, míg a RedEdge, közeli infravörös (NIR), avagy termális csatornák esetén nem jellemző, így ez lehet valamilyen optikai, tükröződés miatti hatás.
- A zöld csatorna hamisszínes képén jellemzően elválnak a sulyom sűrűbb, illetve kevésbé sűrű állománya, emellett a RedEdge és a közeli infravörös csatornán közepes mértékben, míg a kék csatornán kismértékben mutatkozik. A termális csatorna esetén a nagyobb sulyom növény sűrűségén belüli eltérések szintén detektálhatóak, de a közepes változások már nem.
- A nád jellemzően elválnak a közeli infravörös, illetve termális csatornán. A közeli infravörös csatorna ismét megerősíti azon felvetést, hogy az állomány pereme magas vitalitású, viszont azon korábbi felvetésem, miszerint nehéz lesz eldönteni, hogy az állomány belsejében gyékény, avagy csak az elszáradó növényi részek jellemzőek, ezen kép alapján inkább az utóbbi tűnik nagyobb valószínűségűnek. Ezt amiatt gondolom, mivel csak ezen csatornán látszik leginkább a gyékény és nád elválása.
- A sást egyik csatorna sem jelzi kiemelkedően, egyrészt mivel területe kicsi a teljes területhez mérten, ezáltal nem tudunk egyedi tulajdonságot leírni. A tündérrózsa esetén esetleg a zöld, illetve infravörös csatorna nyújthat segítséget, bár ezek esetén elsősorban a vízzel szembeni vitalitás jelenlétét mutatják, nem feltétlenül a növényfajra egyedileg jellemző.

4.2.2.1.2 Hamisszínes többcsatornás képek értékelése

A következőekben a hamisszínes csatornakombinációkat vizsgáltam meg. A csatornák száma az alábbi eredeti sávkészletet jelzi: Band 1 – kék, Band 2 – zöld, Band 3 – piros, Band 4 – RedEdge, Band 5 – közeli infravörös NIR. Az eltérő kompozitok jobban segítik a felszínborítás elkülönítését, mint az eredeti RGB valószínűségi kép, és adott kombináció jobban láthatóvá teheti a különbségeket, mely a képosztályozást is segíti.

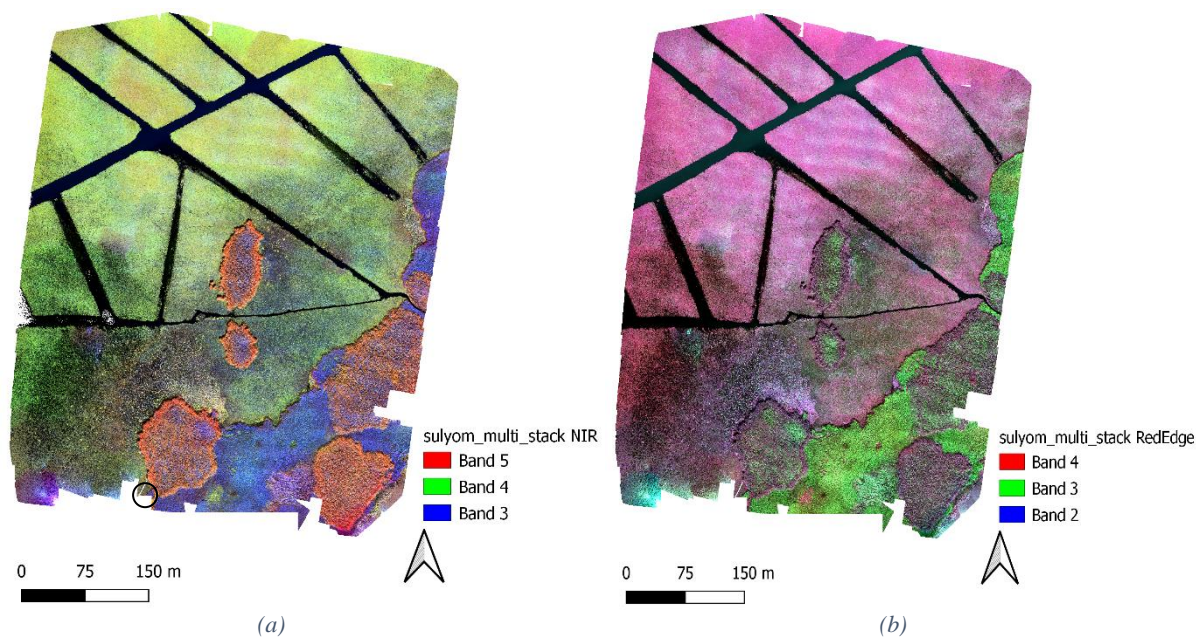


44. ábra - Micasense Altum Tisza tavi felmérésének különböző hamisszínes többszínű csatornás képe eltérő csatorna kompozitok mellett: a) kompozit: NIR - Green - Blue; b) kompozit: NIR - Red - Green;

A balra látható kombináció (kék-zöld-NIR) esetén jól elválik a nád (piros árnyalatú területek), illetve a gyékény (kék árnyalat) borítás területi kiterjedése. Ez is megerősíti, hogy a jobb alsó nádas területen kívül a többi náddal borított terület belsőbb részein hasonló spektrális tulajdonságokat fogunk találni, ami vagy szintén gyékényt jelez, vagy az elhaltabb növényi részeket.

A másik érdekessége ennek a bal oldali képnek, hogy a fekete ellipszisszel jelzett területeken jól kivehető a tündérrózsával fedett vízfelszín, míg a piros ellipszisszel jelzett terület a sással borított felszínt jelzi, mely eddig nehezen vált el különbségként. Egyúttal a sás esetén a kép jobb alsó sarkánál valószínűleg szintén sásos kezdődik. Harmadik érdekessége a képnek, hogy a sulyom sűrűségi különbségei is láthatóvá válnak az árnyalatbeli különbségekben (sötétedő árnyalatok).

A jobb oldali kompozit esetén (zöld-piros-NIR) a gyékény és a nád még inkább elkülöníthető, a nádason belüli „gyékényfoltok” szintén pontosabban kirajzolódnak. A tündérrózsza kevésbé válik el, míg a sás alig tűnik ki. Viszont mindkét kép esetén előnyként emelném ki, hogy a vízfelszín pixelei nagyon jól elkülöníthetőek, köszönhetően az infravörös tulajdonságainak. Az alább következő bal oldali kompoziton (piros-RedEdge-NIR) hasonlóan jó a gyékény-nád elkülöníthetősége, a sás-tündérrózsza szintén elválik a környezetétől, viszont talán ez jelzi legdominánsabban a sulyom sűrűségi változásait (sárgásból zöldes fekete átmenet (bal oldalon), de még a gyékényes területen is láthatunk kisebb sulyom borítást (fekete körrel jelezve). Ez utóbbit a RedEdge-csatornára épülő kompozit is jelzi (jobbra), viszont ezen kompozit esetén dominánsan 3 színárnyalatot láthatunk: sötét fekete a vízfelszín, lilás az élőbb növényzet, míg zöldes az elhaltabb növényzet. A dominánsan tündérrózsával borított terület enyhén fehéres árnyalatú.



45. ábra - Micasense Altum Tisza tavi felméréseinek különböző hamisszínes többcsatornás képe eltérő csatorna kompozitok mellett: a) kompozit: NIR - RedEdge - Red; b) kompozit: RedEdge - Red - Green;

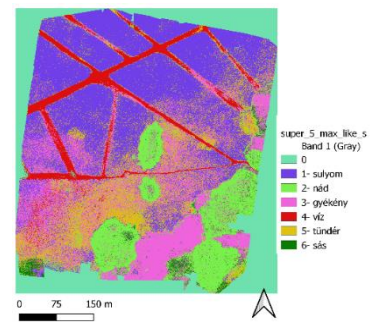

Összességében tehát elmondható, hogy a közeli infravörös csatornából előállított csatorna kombinációk mindenképpen segítik a felszínborítás elkülönítését, míg a RedEdge-csatorna akkor ajánlott a felmérések során, amennyiben a növény állapotáról szeretnénk pontosabb képet kapni. Ez azt is jelenti, hogy ezen céljaink mentén érdemes a szenzort megválasztani, mivel a csatornák száma, azaz a beépített detektorok száma nagyban befolyásolni fogja a távérzékelési szenzor árát.

4.2.2.2 Műholdképekkel történő összevetés

Az 20. ábrán már láthattuk a térbeli felbontásból adódó különbségeket. A spektrális indexek közül az NDVI értéket kalkuláltam, mely segítette az összehasonlítást. Minden képi állományon ugyanazon képosztályozási algoritmusok eredményeit a következőekben foglalom össze.



4.2.2.2.1 Sentinel-2 műholdképpel történő összevetés

Az alábbi eredményeket szemléltető képeken a bal oldalon láthatjuk a Sentinel-2 osztályozott eredményeit, az ezen szereplő keret a drónfelvételnél megfelelő területet mutatja, a jobb felső sarokban pedig a drón által felvételezett, majd osztályozott képet láthatjuk.





- seged_keret
 senti_clip_super_maxlike
 Band 1 (Gray)
 0 - Unclassified
 1 - sulyom
 2 - nad
 3 - gyekeny
 4 - viz
 5 - tunder
 6 - sas

- super_5_max_like_s
 Band 1 (Gray)
 0
 1 - sulyom
 2 - nád
 3 - gyekény
 4 - víz
 5 - tunder
 6 - sas



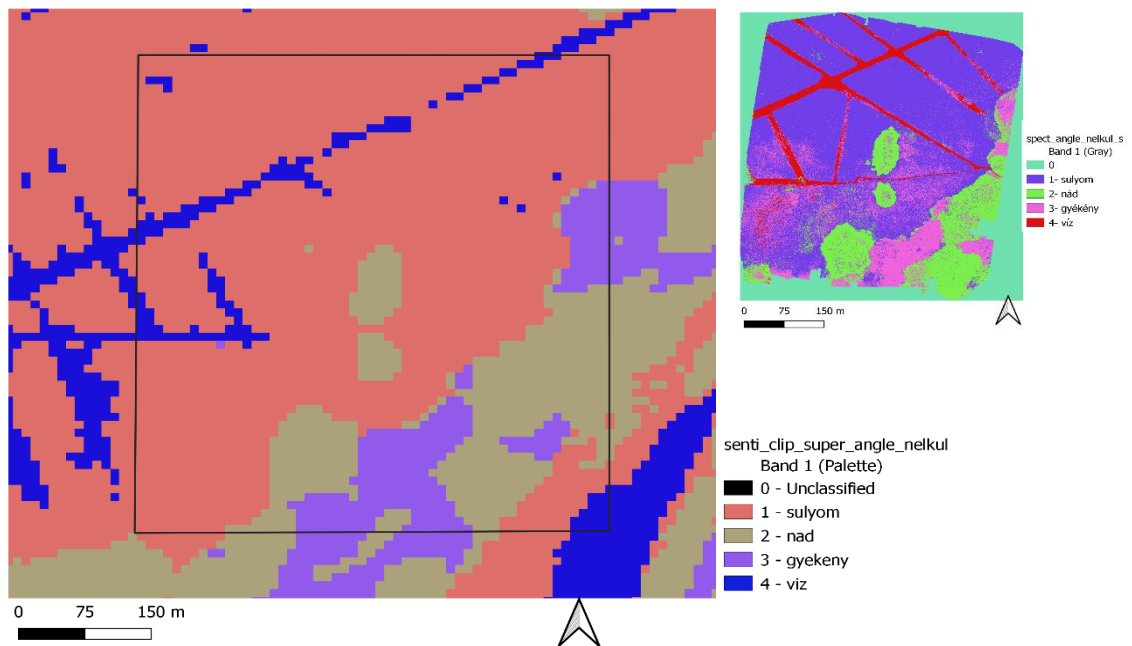
- seged_keret
 senti_clip_super_min
 Band 1 (Gray)
 0 - Unclassified
 1 - sulyom
 2 - nad
 3 - gyekeny
 4 - viz
 5 - tunder
 6 - sas

- super_5_min_dist_s
 Band 1 (Palette)
 0
 1 - sulyom
 2 - nád
 3 - gyekény
 4 - víz
 5 - tunder
 6 - sas



- seged_keret
 senti_clip_super_spect.angle
 Band 1 (Gray)
 0 - Unclassified
 1 - sulyom
 2 - nad
 3 - gyekeny
 4 - viz
 5 - tunder
 6 - sas

- super_5_spect_angle_s
 Band 1 (Gray)
 0
 1 - sulyom
 2 - nád
 3 - gyekény
 4 - víz
 5 - tunder
 6 - sas




46. ábra - Sentinel műholdkép képosztályozási algoritmusok szerinti eredményei, jobb felső sarokban a drónképek ugyanazon algoritmus szerinti osztályozott eredményeivel

Láthatjuk, hogy a drónfelvétel nagymértékben megnövekedett területi felbontása révén sokkal részletesebb felvételezést és elemzést tudunk elérni szemben egy műholdképpel. Ez ugyan alapvető tény, mégis amiatt tartom fontosnak kiemelni, mivel számos olyan szolgáltatóval találkozunk a piacon, akik műholdas rendszerre épülő adatszolgáltatást kínálnak a gazdálkodók részére döntéstámogatási céllal. Ugyanakkor azt is kiemelném, hogy a növényzethatárok nagymértékben egybeesnek.

A Sentinel-2 osztályozási eredményei 6 osztály mellett felcserélték a növényborítást (pl. a maximális hasonlóság algoritmus eredményeként a sás lett a domináns, míg a minimális távolság esetén a tündérrózsa). Ennek az az oka, hogy a spektrális adatok közel esnek egymáshoz (erre később még részletesebben kitérek).


A műholdképen lefuttatott osztályozási módszerek pontosságát megvizsgálva az alábbi diagrammokon láthatjuk ezek eredményeit.



47. ábra – Sentinel-2 műholdkép osztályozási algoritmusainak pontossági %-a ; b) Sentinel-2 műholdkép osztályozási eredményeinek pontossági eredménye a Kappa indexsel megadva

Három dolgot emelnék ki a fentiekből, egyrészt összességében ugyan magasabb pontosságot érünk el, ennek az a logikai háttere, hogy nagyobb területi egységekben vett átlagos értékek alapján kisebb lesz a teljes terület varianciája, viszont ez egyúttal elfedi a terület nagy felbontás melletti részletesebb adatmennyiségét (ezek nagyobb számossága, nagyobb differenciákat is felfedhetnek). Másik érdekesség, hogy a kis osztályainkat (sás, tündérrózsa) alig differenciálható, a sást ugyan a minimális távolság függvénye, a drónkép osztályozási módszerekkel együttesen véve is, a legjobb eredmény mellett adta vissza. Harmadszor pedig a teljes modellre vetítve ebben az esetben is nagymértékben javult az osztályozási pontosság a kevesebb osztály mellett. Ezt a területi felbontás is magyarázza, mely esetén nem is igazán elvárható a kisebb osztályokra való „érzékenység”.

A műholdkép osztályozási eredményeit, illetve a drónképek eredményeit egymással is összevettem pontosság szempontjából, melyeket az alábbiakban összegeznék, ekkor a drónképet vettem referenciaként.



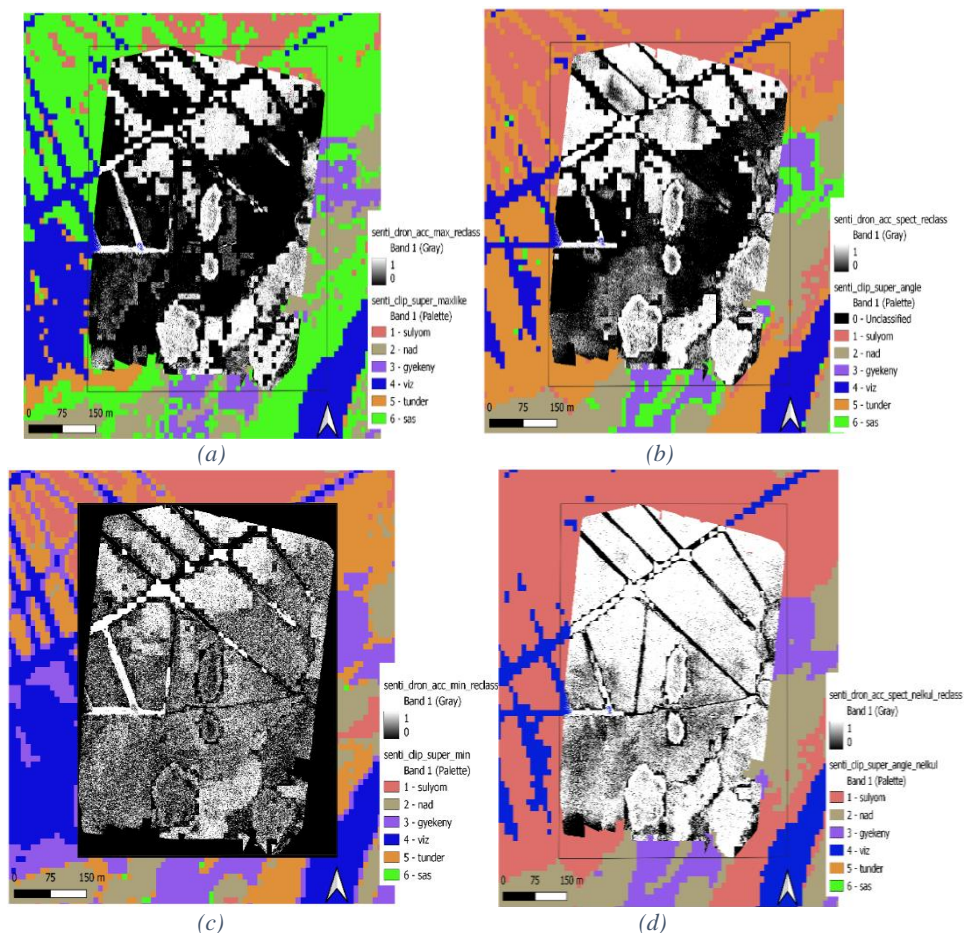
48. ábra – a) Sentinel-2 műholdképosztályozási algoritmusainak pontossági %-a a drónkép osztályozási eredményét referenciaként használva; b) Sentinel-2 műholdkép osztályozási algoritmusainak pontossága Kappa indexsel kifejezve, a drónkép osztályozási eredményét referenciaként használva

Elsősorban két dolgot szerettem volna ezzel igazolni, egyrészt a térbeli felbontásbeli különbség okán, csak közepes mértékben képes a műholdképelemzés pontosságban lekövetni egy drónfelvételen végzett elemzést. Másrészt az algoritmusok közül a spektrális szög módszere mutatta ezen összevetésben is a legnagyobb pontosságot, mely esetén kevesebb osztály mellett már közel jó eredménnyel helyettesíthetőek egymással.

Az SCP plugin a pontosságvizsgálati elemzés .csv kiterjesztésű eredményei mellett egy, a hibamátrix adatait tartalmazó .tif állományt is ki tud menteni a folyamat során. Ez ugyan a hibamátrix adott értékeit, osztályait segít vizualizálni (így csak a hibamátrix adatainak táblázata mellett értelmezhető), viszont amennyiben újraosztályozzuk ezt az állományt úgy térben is tudjuk szemléltetni a helyes, illetve hibás osztályokat, amelyeket például későbbiekben az 55. ábra oszlopdiaagrammján szemléltettem.

Az alábbi képeken láthatjuk a Sentinel-2 képekre vetített eredményeket, az újraosztályozott változatokban a 3 algoritmus szerint. A fehér szín jelenti a helyesen mindkét változatban (drón – műhold) ugyanazon osztályba sorolt pixeleket, míg az eltérést a fekete szín mutatja. Ezen módszer véleményem

szerint egyrészt abban segít, hogy lássuk azon területi egységeket, melyeknél az osztályozás betanításakor tovább érdemes javítani a betanítást, egyúttal láthatóvá válnak a nehezen osztályozható területek, de azt is jól jelzi mely esetekben helyettesíti a nagyfelbontású drónképet egy műholdkép és mely esetekben nem. Ezáltal kutatási célunk szerint tudunk majd dönteni, mikor célszerűbb egy nagyfelbontású drónképpel dolgozni, és mely esetben elegendő a műholdas távérzékelés eszköztára.



49. ábra - A Sentinel-2 műholdkép és a drónfelvétel osztályozott eredményeinek hibamatrix eredményének újraosztályozott képei, melyen fehér szín jelzi az egyezően osztályozott pixeleket, míg feketével az eltéréseket: a) legnagyobb hasonlóság algoritmus mellett; b) spektrális szög algoritmus esetén 6 osztály mellett; c) legkisebb távolság algoritmus eredményei; d) spektrális szög algoritmusának eredményei 4 osztály esetén)

A képek alapján elmondható, hogy a műholdképes elemzés a „nagyobb” növényhatárokat rendre egyformán leosztályozta, mint a drónfelvétel. Ahogy a diagrammokból is látszott a négy osztállyal végzett spektrális szög algoritmus hozza a legszorosabb eredményt. Ez az újraosztályozott hibamatrix eredményképén is látható, mivel ekkor értem el a legmagasabb arányú helyes osztályozást. A három fő algoritmus esetén is a spektrális szög mutat nagyobb egyezést, míg mindnél kitűnik, hogy a műholdas elemzés alapján a legnehezebb azon vizes területek megfelelő osztályozása, melyek felszínén, már megjelenik az ismételt sulyomborítás, illetve a kép alsó harmadában, ahol a sulyom sűrűsége nagyban csökken, romlik az osztályozás pontossága.

4.2.2.3 Képosztályozási algoritmusok eredményei

4.2.2.3.1 Futtatási időre vonatkozó eredmények

Az 18. táblázat a tanulmányban használt algoritmusok futási idejét mutatja. Minden esetben csak az adott algoritmus futási idejét láthatjuk, ugyanannak az ortorektifikált, 5 csatornás képnek a megfelelő beállításai után.


18. táblázat - Képosztályozási algoritmusok futtatási és pontossági eredményeit összefoglaló táblázat

Osztályozási megoldás		8GB DRAM	4GB DRAM	Pontosság Kappa Index
		futási idő (h)		
nem ellenőrzött	klaszterezés (ISODATA)	9,7	>24h	0,4
mély tanulás	Konvolúciós neurális háló (CNN)	>24h	-	0,68
gépi tanulás	Random Forest (RF)	7,4	>24h	0,65
	Support Vector Machine (SVM)	10,6	>24h	0,64
	Mesterséges neurális háló (ANN)	10,2	>24h	0,64
ellenőrzött képosztályozás	Legkisebb távolság (MD)	1,2	6,5	0,52
	Legnagyobb hasonlóság (ML)	1,2	6,5	0,6
	Spektrális szög (SAM)	1,2	6,5	0,65
	Főkomponens analízis (PCA)	3,5	8,5	0,56
	Döntési fa	0,5	2	0,56

A leggyorsabb futási időt a "döntési fa", majd a felügyelt osztályozások mutatták. Bár ez utóbbi lépés megköveteli a gyakorlóterületek előkészítését (ami növeli a teljes futási időt, különösen a spektrális adatgyűjtés esetében), azonban ha ugyanazt a területet szeretnénk automatikusan, ugyanazon érzékelővel többször is osztályozni, ezt a lépést is csak az első alkalommal kell elvégezni. Az eredmények szerint a gépi tanulás, illetve mélytanulási megoldások jelenleg túl hosszú futási időt igényelnek a valós idejű adatfeldolgozáshoz. Az *ORFEO* egyik nagy előnye az a megközelítés, hogy megbecsüli a teljes memóriaszükségletet, majd a memóriakészlet alapján részekre osztja a feladatot. A tesztelt gépi tanulási algoritmusok esetében ez most átlagosan 23350 MB memóriát eredményezett a teljes futtatáshoz.

4.2.2.3.2 Klaszterezés eredményei

A klaszterezés jelen esetben nem hozott megfelelő eredményt. Mivel ráadásul hosszú futási időt igényel, így véleményem szerint nem minden esetben érdemes futtatni ezen osztályozást a drónok által felvételezett képeken.

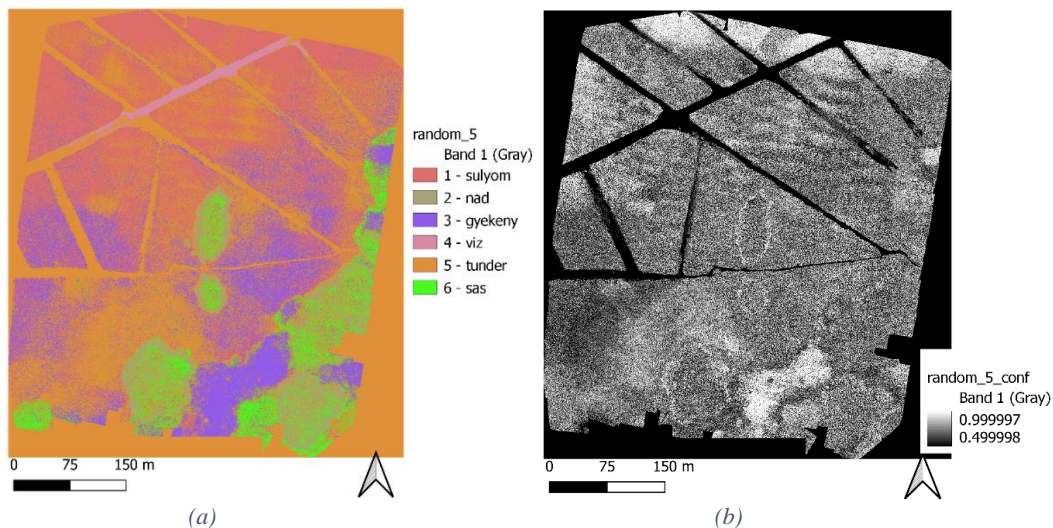


50. ábra - Micasense Altum Tisza tavi felmérésének klaszterezés módszerével kapott osztályozási eredményei; a) legkisebb távolság algoritmus mellett kapott eredmény; b) spektrális szög algoritmus mellett kapott eredmény

Annyit emelnék ki, hogy egyrészt a növényi sűrűséget valamelyest elkülöníti mind a véletlenszerű, mind a spektrális adatok alapján. A növényfajták elválasztása szempontjából a spektrális szög algoritmus bizonyult pontosabbnak (lásd 50.b. ábra), de nem minden fajtát tudtam volna újraosztályozással sem meghatározni.

4.2.2.3.3 Random Forest eredményei

A Random Forest jelen esetben nem hozott megfelelő eredményt, ráadásul hosszú futási időt igényelt.

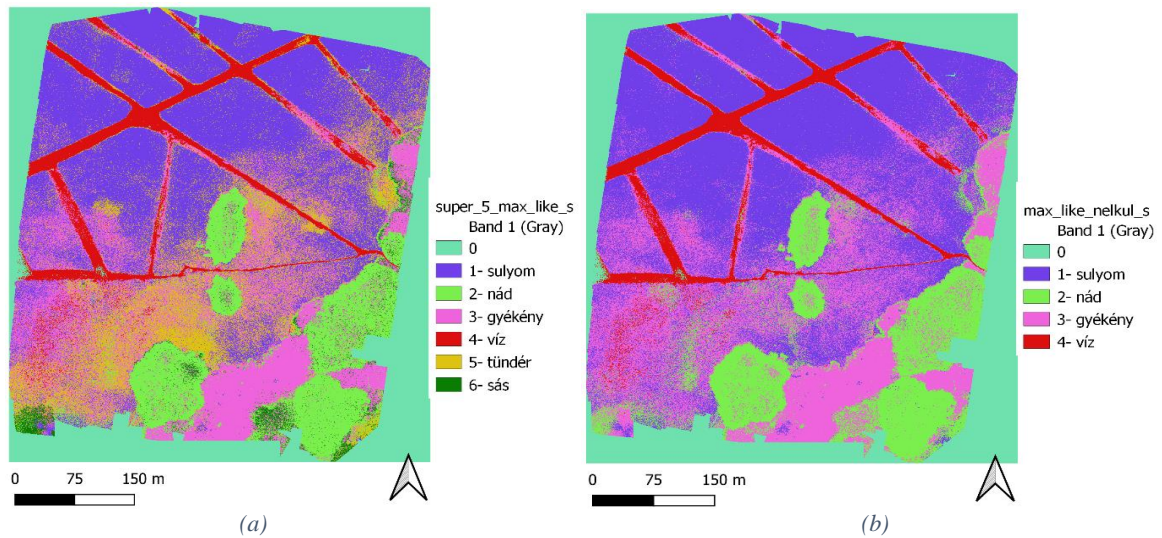


51. ábra - Micasense Altum Tisza tavi felmérésének a) Random Forest osztályozással lefutott eredményei; b) a modell konfidencia eredményei

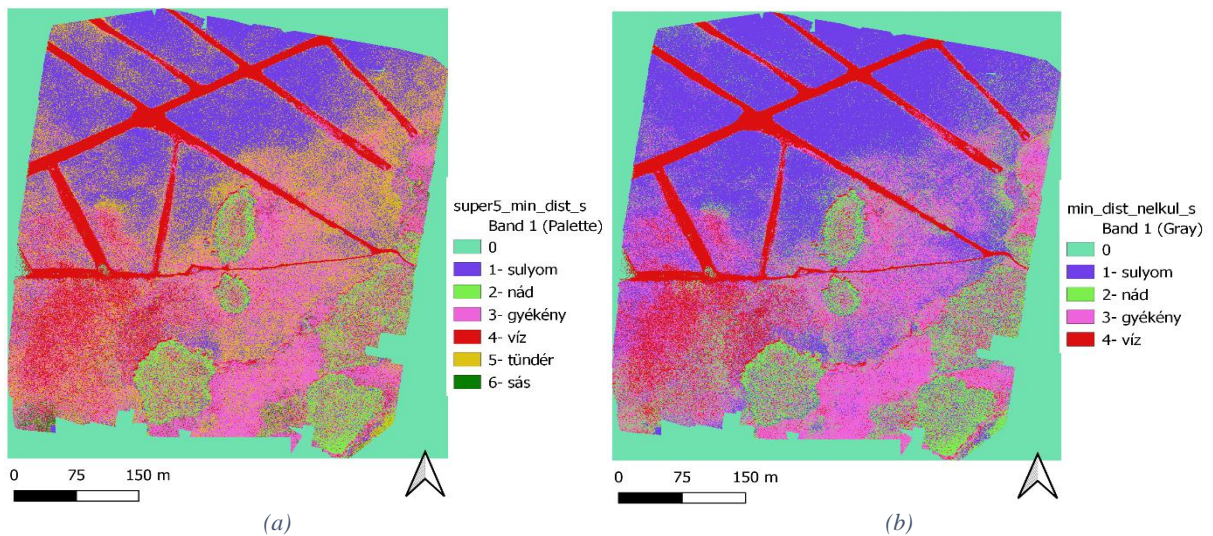
4.2.2.3.4 Ellenőrzött képosztályozás eredményei

Informatikai oldalról elmondható, hogy ezen eljárás a legstabilabban futtatható, mind időben mind tárhely szempontjából, így a nagy felbontású többsatornás drónképek esetén is stabil elemzési megoldást jelent majd, ráadásul egyszerűen összekapcsolható Python környezetben bármely adatbázisba mentéssel, így a spektrális jellemzők is nagy számban gyűjthetővé válnak. Az eredmény képeit az alábbiak

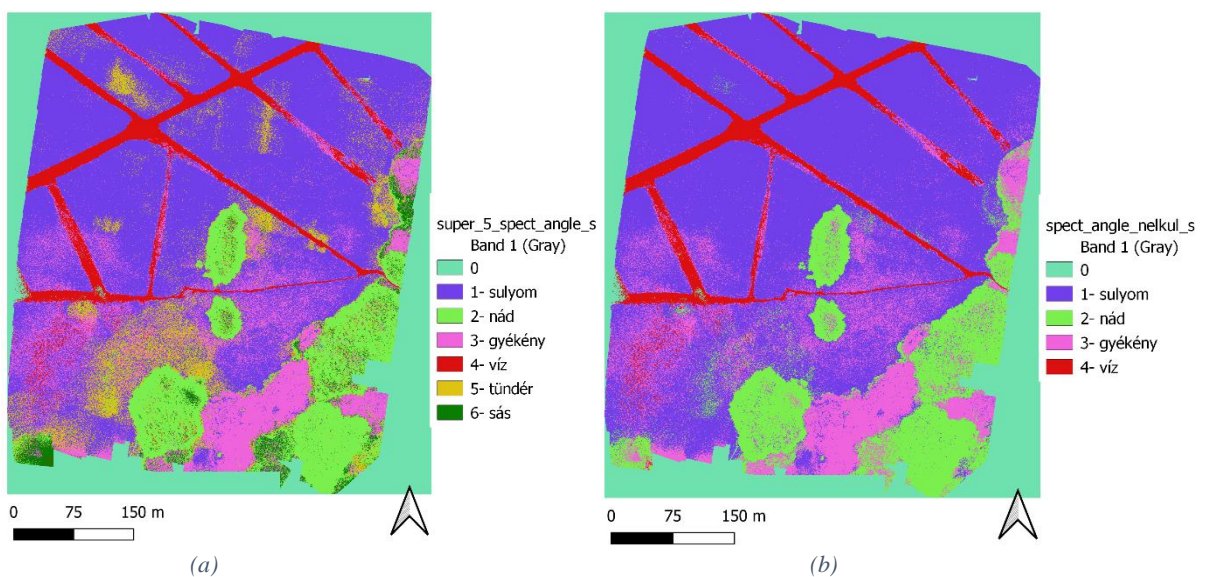
láthatjuk. A 6 osztályos képre jellemző fontosabb adatokat (pl. pixelszám, terület (m²)) táblázatokba foglaltam, melyet az M9 számú mellékletben lehet megtekinteni.



52. ábra - Micasense Altum Tisza tavi felmérése 'legnagyobb hasonlóság' algoritmusával végzett ellenőrzött osztályozási eredménye: a) 6 osztállyal; b) 4 osztállyal



53. ábra - Micasense Altum Tisza tavi felmérése 'legkisebb távolság' algoritmusával végzett ellenőrzött osztályozási eredménye: a) 6 osztállyal; b) 4 osztállyal



54. ábra - Micasense Altum Tisza tavi felmérése 'spektrális szögtávolság' algoritmusával végzett ellenőrzött osztályozási eredménye: a) 6 osztállyal; b) 4 osztállyal

A képek vizuális vizsgálata alapján kiemelném, hogy a három algoritmus közül a 'legkisebb távolság' módszere mutatja a legtöbb növényborítással összefüggő hibát. Viszont ezen algoritmus tudja a leginkább elválasztani a víz pixeleit az egyéb felszínborítástól. Így a későbbiekben minden vízfelszínnel összefüggő kutatási cél esetén jobban ajánlott ezen algoritmus alkalmazása a többivel szemben. Ezen tulajdonságot összekapcsolhatjuk akár a vízinövények terjedését célzó kutatásokkal is, így akár a növényi sűrűséget vizsgáló elemzésekkel. Viszont a parti területek vizsgálata során már kevésbé eredményes, itt mind a maximális valószínűség, mind a spektrális szög módszere jóval eredményesebb.


Amennyiben a domináns növényfaj elválasztását célozzuk meg, úgy a spektrális szög adja a legjobb eredményt, de mindegyik esetén elmondható, hogy az ilyen céloknál előnyösebb csak a főbb osztályok vizsgálatával futtatni a képosztályozást, mivel pontosabb eredményt kapunk.

Az ellenőrzött osztályozások térbeli pontosságának keresztosztályozással történő eredményeit, a helyes pixelek osztályonkénti térbeli összegét a 55. ábrán foglaltam össze.



55. ábra - A teljes referenciaterrülettel vizsgált helyes, illetve helytelen pixelek területi összegének m²-ben vizsgált eredményei


Ezt az alábbi diagrammon vizsgáltam a 6 osztály bevonásával, illetve a 4 osztály esetén jellemző területi eloszlás alakulását, a helyes pixelek arányát % értékben kifejezve.



56. ábra - A 3 eltérő ellenőrzött osztályozási algoritmus eredményeinek területalapú összevetése és adatainak szórása (balra 6 osztállyal, jobbra 4 osztállyal)

A fentiek alapján elmondható, hogy az osztályok számának csökkentése javította a legdominánsabb sulyom növényborítás pontosságát, legalábbis abban a tekintetben, hogy a három algoritmus eredményének szórása csökkent. A spektrális szög, illetve maximális hasonlóság függvényei a nád (2), víz (4) és sás (6) esetén nagyon hasonló eredményre jutottak.

A képosztályozási megoldások eredményeinek keresztclasszifikációval, illetve keresztvalidációval vizsgált pontossági elemzésének eredményeit az alábbi diagramok szemléltetik.



57. ábra - Eltérő ellenőrzött osztályozási algoritmusok 6 osztállyal futtatott eredményeinek pontosság vizsgálatának eredményei; a) Az osztályozó algoritmusok pontossági %-a osztályok szerint bontásban, illetve a teljes modellre vizsgálva; b) az osztályozó algoritmusok Kappa-index eredményei az osztályok és a teljes modell esetén


Látható, hogy a fő osztályok (1, 2, 4) esetében a ML és SAM modellünk megbízható pontossággal viselkedik (a Kappa index kiváló, 0,75 feletti eredményt mutat), míg a 3, 5, 6 osztályok esetében a modell általános pontossága nem kielégítő. Ezt valószínűleg nem a vizsgált területek mérete okozza, hanem ezek spektrális értékei nagyon hasonlóak voltak az 1. és 2. osztályhoz (különösen a 2. osztály (nád) esetében feltételezhető, hogy a belső területet vegyes növényzet borítja), ami megnehezítette a pontos előrejelzést. A tündérrózsa (5. osztály) esetében pedig a korábban említett növényi jellemzők szintén megnehezítik a betanítást. A teljes modell esetében jó Kappa index eredményeket láthatunk, amelyek közül a ML és a SAM algoritmus adta a legmagasabb pontosságot.

Mivel jelen vizsgálatban a kép bal alsó sarka felé eső területeken látszott, hogy a sulyom sűrűsége nagymértékben csökken, így itt egy vegyes spektrumot kaptam, ahol a víz, illetve növényzettel borított pixelek adott esetben nagy számban vegyesen voltak megtalálhatóak, ami rontotta a pontosságot. Ezt ellenőrzött osztályozással amennyiben poligont jelölünk ki tanulóterületként, úgy nem lehetséges elválasztani. Van arra lehetőség, hogy a betanítás során pixeleket jelölünk ki tanulóterületként, ebben az esetben viszont egy ekkorra felbontású kép esetén olyan nagyszámú pixelre lenne szükségünk minden egyes osztály esetén, mely időben nagymértékben megnövelné a betanítás időintervallumát.

Erre az lehet idővel megoldás, hogy például konkrét spektrális értékek szerinti pixeleket keresünk, melynek spektrális adatait akár egy adatbázisból gyűjtjük. Erre a Python környezetben van már algoritmus, hogy adott raszteres állomány, adott csatornájára vonatkozó, adott szabálynak megfelelő

pixeleket keressen a program, beállítástól függően akár több 100, avagy 1000 darabot is kérhetünk osztályonként. Viszont ezen algoritmusok többsége egyelőre még további fejlesztésre szorul, mivel leginkább egyes értékeket tudunk többnyire beállítani, azaz egy csatorna adott értékét képesek már megkeresni véletlenszerűen a képen, de többcsatornás kép adatmátrixában még kevésbé eredményesek. Ilyen eszköz például a *QGIS*, *SCP* pluginjének '*Multiple ROI creation*' fejlesztése, de az *ORFEO* toolboxban is találunk egyre több ilyen irányú eszközt, mely utóbbinál egyre inkább objektumorientált megközelítést használva keres egy összetett tulajdonság egyezést. Ezen irányú fejlesztéseket egyrészt a hiperspektrális kamerák képelemzése motiválja, másrészt a nagy térbeli felbontást elérő állományok is, köztük a jelen vizsgálatban bemutatott drónfelvételek.

A keresztvalidációs pontossági elemzést a sás és tündérrózsa nélkül, 4 osztály mellett is lefuttatva az eredményeket az alábbi diagrammokon összegeztem.



(a)

(b)

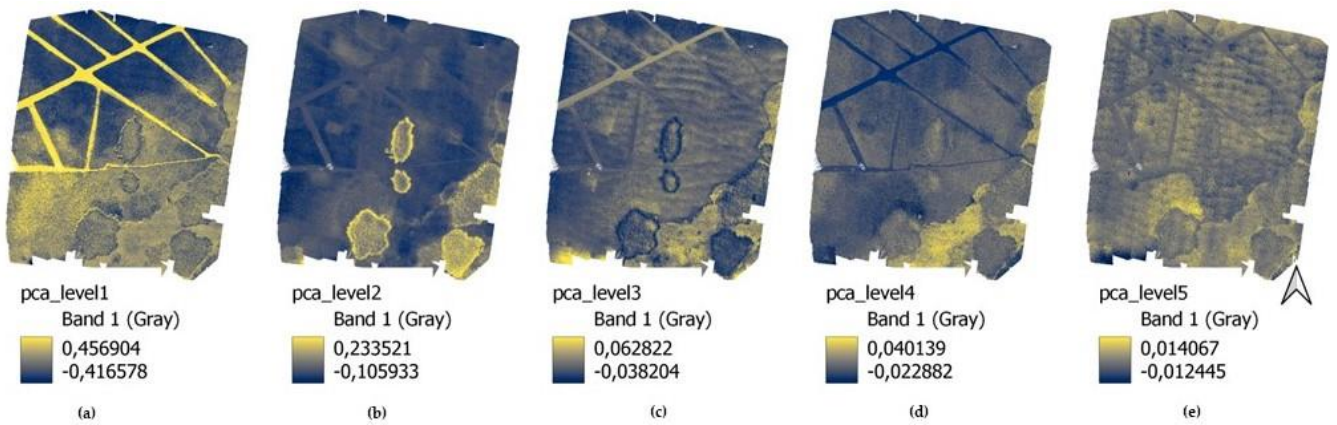
58. ábra - Eltérő ellenőrzött osztályozási algoritmusok 4 osztállyal futtatott pontosság vizsgálatának eredményei; a) Az osztályozó algoritmusok pontossági %-a az osztályok szerint bontásban, illetve a teljes modellre vizsgálva; b) az osztályozó algoritmusok Kappa-index eredményei az osztályok és a teljes modell esetén

Ez alapján a 2. osztály (nád) kivételével a pontosság mindhárom másik osztály esetén nőtt, viszont a teljes modellre vetítve a spektrális szög módszere romlott, ez magyarázható azzal, hogy romlott a spektrális adatok egyezése, míg a minimális távolság módszere javult.

Véleményem szerint ez amiatt fontos, hogy a céljaink szerint érdemes megválasztani, hogy kevesebb vagy több osztállyal dolgozunk-e. Például, ha adott fajok térbelisége a vizsgálatunk tárgya, úgy az összes osztállyal érdemes dolgozni, míg amennyiben csak egyes faj vagy egy paraméter kiterjedésének időbeliségét szeretnénk vizsgálni, akkor célszerű csökkenteni az osztályok számát.

4.2.2.3.5 Főkomponens analízis (PCA) eredményei

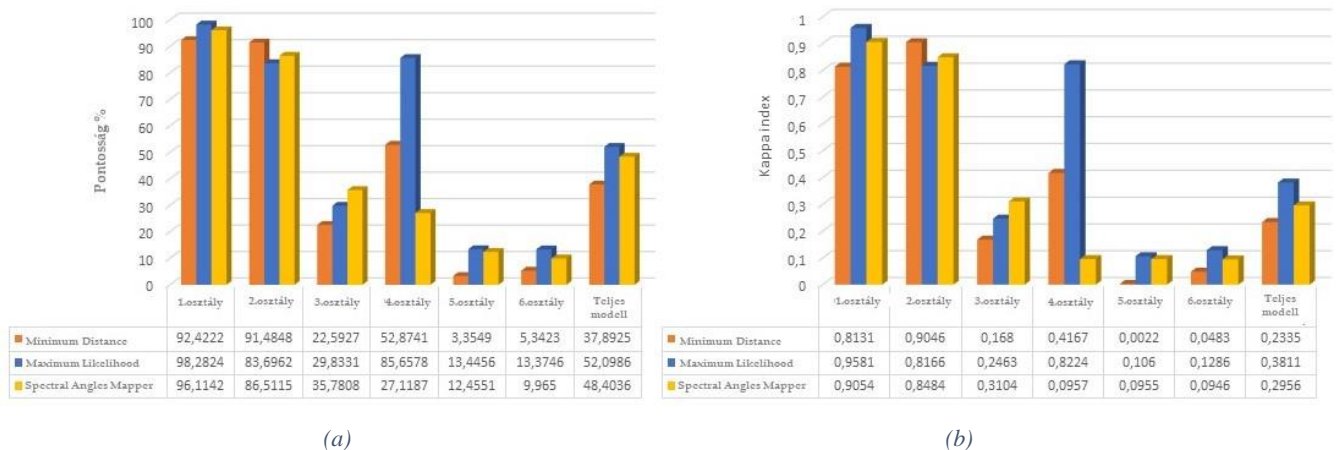
A PCA főkomponens elemzés eredményeit az alábbi ábrán láthatjuk.



59. ábra - A PCA-elemzés eredményeinek képei: (a) PCA 1.szint. (b) PCA 2.szint. (c) PCA 3.szint. (d) PCA 4.szint. (e) PCA 5.szint


Vizuális értékelésem: a) ábrán az intenzív sárga szín a vízfelszint (4. osztály), míg a sötétkék a sulyom sűrű borítását (1. osztály) mutatja. Így a későbbiekben a vízfelszint borító vízi növényzet sűrűségének vizsgálatához is segítséget nyújthat. A (b) ábrán az intenzív sárga a 2. osztálynak (nád) felel meg; a (c) ábrán a sötétkék a nádat, míg a sárga a gyékényt (3. osztály) mutatja. Ez utóbbi a (d) képen még intenzívebben megjelenik. Az (e) többnyire már nem használatos, bár a legintenzívebb sárga (a kép első harmadának közepén) a tündérrózsa fő területének felel meg.

A pontosság vizsgálatát mind a referenciával szemben, mind pedig az UAV eredményekkel összevetve az alábbiakban láthatjuk.



60. ábra - a) A PCA-elemzés és a referenciaréteg általános pontossága (%); b) A PCA-elemzés és a referenciaréteg Kappa-indexének eredményei

Az eredményeken látható, hogy a SAM algoritmus pontossága jelentősen romlott, de a MD a 6. osztály kivételével minden osztály esetében javult (pl. a 2. osztály esetében 48%-ról 91%-ra). A legnagyobb pontosságot a ML érte el. Az előző képosztályozás osztályeredményeihez képest a pontosság ugyanolyan vagy kissé alacsonyabb volt. A legdominánsabb 1. osztály esetében mind a ML, mind a SAM pontossága minimálisan javult, míg a modell teljes pontossága csökkent.




61. ábra - a) A PCA és az UAV "eredeti" osztályozásának általános pontossága %; b) A PCA és az UAV "eredeti" osztályozásának Kappa indexei

Ha az UAV osztályozási eredményeket vesszük alapul a pontossági elemzéshez, akkor a MD és a ML esetében nagyon magas pontosságot láthatunk. A modell teljes pontossága esetében is a legmagasabb értékeket kaptuk.


4.2.2.3.6 A döntési fa eredményei

A futtatások során érdemes volt figyelni az elemzés fókuszára, és a szabályok sorrendjét ennek megfelelően változtathatjuk. Ha például a tündérrózsát vizsgálnánk meg jobban, akkor az első öt osztályra vonatkozó szabálykészletünk sorrendjének megváltoztatásával javítani tudtam az eredményeket. Ha ezt a szabályt az 5. helyen vizsgáltam, akkor 863,34 m² -t, míg a 3. helyen 876 m² -t, az 1. helyen pedig 915,75 m² -t válogatott le. Ez utóbbit használtam a pontossági elemzés elvégzéséhez, mind az osztályozott UAV-képekkel, mind pedig a referenciareteggel szemben.



62. ábra - Egyedi döntési szabályrendszer mellett futtatott képosztályozás eredménye, a zöld pixelek jelzik a tündérrózsával borított felszínt

A pontossági elemzés eredményeit a 66. ábrán foglaltam össze.



63. ábra - a) A tündérrózsára vonatkozó döntési fa pontossági értékelésének (%) eredményei; b) A tündérrózsára vonatkozó döntési szabályok Kappa indexének eredményei


Ezeket az eredményeket összehasonlítva az eredeti ellenőrzött képosztályozás pontosságával megállapítottam, hogy szinte minden osztály esetében ugyanolyan jó vagy jobb eredményeket kaptunk (kivéve a 2. osztály (nád)). Ennek oka a korábbiakban már említett nehézség, hogy a valóságban a poligonon kialakított tanítóterület (illetve referencia) azt feltételezi, hogy a nádas teljesen kitölti ezen térrészt, míg a valóságban valószínűbb a belső részeket borító vegyes növényzet. A döntési szabályrendszer valószínűleg realisabban képes elkülöníteni az egyedi tulajdonságok összekapcsolása révén, mint a poligon-alapú felügyelt osztályozási módszerek.

Általánosságban elmondható, hogy az 1., 3., 4. osztályok teljes pontossága (%-ban) és a Kappa index értéke jó előrejelzési megbízhatóságot mutatnak, különösen a referenciaréteghez viszonyítva. Az 5. osztály esetében, míg a legpontosabb eredményt korábban ebben az osztályban a SAM algoritmus érte el a referenciával szemben (teljes pontosság 22,4% volt), ugyanez az érték most 67,7%-ra nőtt.

A teljes modell esetében azonban nem látható az egyes osztályokra jellemző magas érték. Eredményeimből levezetve ez a 6. osztály hiányának és annak köszönhető, hogy ebben az esetben kaptam a legtöbb egyik osztályba sem sorolt képpontot. Ha a pixelek nem felelnek meg egyik szabálynak sem, akkor egy külön osztályban maradnak, amelyet tovább lehet vizsgálni, vagy további szabályok kidolgozásához lehet felhasználni. Például jelen tanulmányban, ahol a sulyom (1. osztály) ritkult, ezek a pixelek az osztályozás után nem kerültek az 1. osztályba. A jövőben tehát ezt a módszert használhatjuk a növénytakaró sűrűségének könnyebb feltérképezésére. De a vízfelszínen lévő növénytakaró is külön vizsgálható (jelen futtatáskor is leválogatta az algoritmus), és nyomon követhető lesz annak időbeli változása.

4.2.2.3.7 A vizsgált képi raszteres állományok spektrális adatainak jellemzői


A többcsatornás raszteres állományok spektrális adatait a következő ábrán mutatnám be a Sentinel-2 műholdkép és a Micasense kamera adott pixelre jellemző mért eredményeit szemléltetve (64. ábra).



64. ábra - QGIS által kalkulált spektrumkép: a) Sentinel-2 műholdkép spektrumképe, b) a Micasense Altum 5 optikai csatornájának spektruma)

A spektrális értékek egymással szembeni távolság függvények eredményeit táblázatosan összegeztem, melyből a nád, illetve sulyom többi osztállyal szembeni eredményeit az M11 számú mellékletben lehet megtekinteni. A vizsgálat több osztály esetében is spektrális hasonlóságot jelzett (például a sás, nád esetében), mely később hatással volt az osztályozás pontosságára.


A két távérzékelési megoldás spektrális adatainak szórását adott osztályra vonatkozóan az alábbi ábrán foglaltam össze.



65. ábra – A spektrális adatok osztályokra jellemző adatgyűjtési eredményeinek szórása


A szórás esetén mindenképp kiemelném, hogy a tanulóterületek poligonjairól, átlagolva gyűjtött spektrális adatok nem mutattak nagyobb szórást, azaz megfelelő pontosságúnak tekinthető a drónokon alkalmazott multispektrális kamera spektrális adatgyűjtése a műholdas távérzékeléssel. A szórás egyedül a NIR tartományban emelkedett és mutatott nagyobb különbségeket, de még ennél a csatornánál is 0,052 a legmagasabb érték.

A spektrális görbék (66. ábra) másik korábban már az osztályozás során is említett érdekessége talán a gyékény alacsony NIR értéke, mely valószínűleg a nagyobb arányú elszáradt növényi résznek tudható be, illetve itt is látszik, hogy a sás, nád, és gyékény nagyon hasonló spektrális osztályokat jelent jelenleg, mely magyarázza adott algoritmus melletti felcserélésüket.




66. ábra - Az osztályok spektrális adatainak átlagértéke a drón Micasense Altum, illetve a Sentinel-2 műholdkép alapján

A gyűjtött pontok spektrális görbéit, illetve szórását az alábbi diagrammokon láthatjuk.



67. ábra - 150 db vektoros pont által gyűjtött spektrális átlagok osztályok szerinti bontásban

A spektrális adatok esetén elmondható, hogy a sás valamiért nem jellemző „lefutású” a NIR tartományban, először felvetődhet, hogy vízpixeleket is kijelölhettem az adatgyűjtés során, viszont amennyiben ellenőriztem ugyanezen pontok termális adatait, abból mégis úgy tűnik, hogy nem víz adat „rontotta” el, mivel a legmagasabb hőmérséklet jellemzi. Elsősorban valamilyen egyéb, idegen anyagra gondolnék eszerint, és egyszeri, jelen mérésre vonatkozó sajátosságnak tudom be.



68. ábra - 150 pont spektrális adatgyűjtési eredményének szórása

A szórás minden spektrális csatorna esetén 0,2 érték alatt alakult, a termális értékek mutattak nagyobb szórást, de ez is elfogadható mértékben.

5 KÖVETKEZTETÉSEK, JAVASLATOK

A távérzékelés terepi módszerei napjaink egyik legjobban fejlődő tudományterülete. Mivel eszközeit számos iparágban tudjuk hasznosítani, ezért használatuknak egyszerűbb, sokoldalúbb alkalmazása különösen fontos.

Mivel a piacon viszonylag drágán lehet kiegészítő eszközöket beszerezni a spektrométeres rendszerekhez, ezért bemutattam, hogyan tudunk egy 3D nyomtatóval olyan levélvizsgáló eszközt készíteni, mely segíti a későbbi munkánkat. Láthattuk, hogy nem volt szignifikáns eltérés az így alkotott, „aktívvá” vált mérőrendszer és például a gyakorlatban leggyakrabban alkalmazott *ASD Fieldspec 2* között. A 3D-s modellt bárki tovább alakíthatja, így sokak számára egyszerűbb megoldást jelenthet, ráadásul használata is könnyebbé teszi a mérési munkát.

A mérési adapter fényforrásaként a jövőben a halogéntól eltérő például LED fényforrások is alkalmazhatóak, melyek ilyen teljesítménynél alig járnak hőtermeléssel. A jövőben megvizsgálható ezen fényforrások alkalmazása is. Amennyiben ezen fényforrások nem befolyásolják a mért adatokat, akkor számos további méretcsökkentési lehetőség is felmerülhet.

A *Raspberry Pi*-vel történő integrációt tovább kell a jövőben fejleszteni. Ez driverek szintjén sikerült, viszont futtató programját még ki kell alakítani, hogy hogyan kezelje a spektrométert:

- Egyik lehetőség a *Waves* program integrációja az IoT operációs rendszerbe, mely révén futtatható válik *Raspberry Pi*-n.
- Amennyiben az előbbi irányt nem lehet megvalósítani, új egyedi kezelőszoftvert kell fejleszteni.

Azt is láthattuk, hogy a reflektancia mérések megfelelő alkalmazása révén olyan egyéb műszereket is mostanra képesek vagyunk kiváltani, mint például a SPAD-méterek. Munkámban bemutattam, hogy ugyanolyan, vagy akár szorosabb korrelációt is el tudunk érni adott klorofill indexek révén, mint a SPAD méterrel.

A fénytani paraméterek esetén véleményem szerint egyre nehezebb a különféle szenzorok szerinti mért adatokat (elsősorban mértékegységük, és mérési módszereik eltérése miatt) összevetni, automatizált vezérlésekben alkalmazni őket. Ez félreértéseket jelenthet akár a gyakorlati szakemberek, akár kutatók, kutatóterületek között. Az újabb technológiák, illetve ezek fejlődését, terjedését szintén adott esetekben nehezítik. Munkám során egy komplexebb, jelenleg vezérlőtáblába szerkesztett modellt dolgoztam ki, mely összesíti a fizikai egyenleteket, és ezek alapján, a fizikai elvből kiindulva adja meg a spektrális adatok alapján a megvilágítást, illetve fotonfluxust leíró mérőszámokat. A későbbiekben véleményem szerint növényvizsgálatok szempontjából egyszerűbb egy ilyen rendszer és modell alkalmazása, mint háromféle szenzor, eltérő megközelítéssel. Ráadásul így a mérés sem függ a fényforrás típusától (ld.: 3. táblázat), mivel nem kvantummérőként mér és korigál, hanem fizikai alapon a spektrumot alkalmazva. Mivel az alapmodell a napsugárzásra épült, azaz 200 nm-től 4000 nm-ig, így

bármikor szélesíthető a vizsgált tartomány a technológia fejlődésével együtt. Ráadásul egy spektroradiométer mérési tartománya a legtöbb fénytani-, illetve növényvizsgálat szempontjából elegendő egyelőre. Amennyiben a mérések során helymeghatározási adatokat is rögzítünk, úgy további térinformatikai szoftverekkel vagy térbeli adatbázissal is összeköthető.

A későbbiekben ezen modellt egy programmá átalakítható, mely szintén egyszerre futtatható többféle vezérlő automatikában, így segítve a fényvezérlések fejlesztését. Véleményem szerint a növényvizsgálatok során alkalmazott mérési módszerek lassan nem képesek majd ez utóbbi feladatokat megfelelően ellátni. Ráadásul idővel a fotometriai megközelítés szerintem nem is megfelelő a növényvizsgálatok során, mivel ezen szabványok, szenzorok, elvek minden esetben az emberi szem látásán alapulnak, mely teljesen más érzékenységgel rendelkezik. Az a továbbiakban szintén a vezérlés automatizálásának egyik fontos feladata lesz, hogy mely Nap spektrumot választunk referenciaként, melyhez az aktuálisan mért adatot ki kell egészíteni egy szabályozható világítási rendszernek.

A továbbiakban láthattuk, hogy a spektrális adatok a beltartalmi paraméterek előrejelzésében is fontos szerepet játszanak. A bemutatott számolótábla nagymértékben gyorsítja az adatfeldolgozást, ezzel segítve a felhasználó további elemzéseit, illetve idővel egyes részei vezérlőszoftverbe integrálhatók. Itt ugyan még további kutatásra van szükség, mivel munkám során azt tapasztaltam, hogy számos index, melyet a korábbi kutatások jó eredmény mellett mutattak be, nem minden esetben teljesítettek ugyanolyan jól. Ezen belül a klorofill után a víztartalom hozott jobb eredményt, míg a nitrogén és kálium közepes korrelációt jeleztek. Mivel a szakirodalmak jobb eredményeket érnek el a nitrogén előrejelzése során, lehetséges, hogy jelen vizsgálatot is tovább kellene folytatni, hogy nagyobb elemszámmal, vagy hosszabb időintervallumon belül jelentkezik-e magasabb korreláció. Mivel egyéb beltartalmi paraméterek is ugyanúgy fontosak a precíziós gazdálkodásban (kálium, foszfor, minőségi beltartalmi paraméterek: pl. fehérje-, keményítő tartalom). A kálium tartalom koncentrációs becslése ugyan nem hozott megfelelő, szignifikáns eredményt, azért az elmondható, hogy PLS-DA modellel a kálium-hiányos állapot viszonylag jól előrejelezhető a reflektancia mérések alapján. A spektrális indexeket, illetve a reflektancia értékek vizsgálata szempontjából a 405, 705, illetve az 1360 nm körüli régiókat érdemesebb a későbbiekben tovább vizsgálni (bár az utolsó nehezen vagy nagyon drága műszerrel elérhető a terepen).

A későbbi, beltartalmi előrejelzésekhez szükségünk lesz, vagy egy jóval nagyobb korrelációt stabilan mutató vegetációs indexre, vagy jóval komplexebb modellek is egyre nagyobb figyelmet kaphatnak, belőlük is kialakulhat majd idővel egy megbízható előrejelzési rendszer (ezek esetében az informatikai gépigény lehet majd egy kulcstényező). Véleményem szerint adott beltartalmi paraméterek esetén olyan megoldás is lehetséges, hogy adott nagylabor mérések adják a kalibrációhoz, validációhoz szükséges „referenciát”. De így is jóval kevesebb labormérés elegendő lehet majd. Másik, és a gyakorlati oldal számára kedvezőbb megoldás lehet, ha idővel akár több spektrális index együttes alkalmazása alapján szabályozunk és jelzünk előre. Harmadik megoldás lehet, ha itt is megjelennek igazolt

referenciák, mellyel egyszerűbb a mért értékek összevetése. Viszont mivel egy élő növényre épülő mérés mért adatainak értelmezése sokkal több paramétertől függ, mint egy „roncsolt” minta, így nem egyszerű a megfelelő referenciaanyag kiválasztása. Véleményem szerint az mindenképpen fontos lenne ezen területen is, hogy minél több nyílt adatbázis legyen elérhető, mely bekapcsolhatóvá tenné a gépi tanulás szélesebb lehetőségeit.

Azt is kiemelném, hogy eredményeink szerint a lineáris regresszív modellek előrejelzési pontossága javult, ha inkább a biomasza-alapú tápanyagtartalmat vettem figyelembe, a koncentrációk helyett. A SWIR régió reflexiójáról kiderült, hogy segítik a növények N – (P) – K állapotának előrejelzését a látható (VIS) vagy a közeli infravörös (NIR) régió reflektanciájával együtt, különösen a kálium és foszfor esetében. A P, és K specifikus spektrális algoritmusok viszont további pontosítást és vizsgálatot igényelnek.

Egyúttal azt is kiemelném, hogy fenntartási, üzemeltetési és automatizációs szempontból is nézve a szabályozható, nagyteljesítményű LED világítási rendszerek véleményem szerint a jövő növényházainak megfelelőbb műszaki megoldásai, szemben a HPS rendszerekkel. A fénytani paraméterek jelen munkában is kiemelt szemléletváltozása, nagyobb növényi fókusza és kiszélesítése, elsősorban a biológia oldalra koncentrálva, pedig elengedhetetlen lesz.

A dolgozat második felében a drónokon alkalmazott távérzékelési szenzorok adatfeldolgozását mutattam be és vizsgáltam. Egyrészt látnunk kell, hogy bár mostanra képesek vagyunk elérni a cm-es pontosságot ezen rendszerekkel, de véleményem szerint a túl nagy adatmennyiség nehezíti ezek gyors feldolgozását, így egy valós idejű megoldás eléréséhez erre valamilyen megoldást kell majd találni (akár újfajta adattömörítés, akár csak célirányosabb spektrális adatok rögzítésével). Az is sokat gyorsítana az adatfeldolgozáson, ha a fotogrammetria eszközszerkezete beintegrálódna a GIS szoftverekbe, míg így egyelőre szükséges mindkét szoftver fajta használata. Az adatfeldolgozás képosztályozási algoritmusai közül a spektrális szög bizonyult a legpontosabb megoldásnak. Míg azt is bemutattam, hogy mindig a vizsgálat célja szerint lesz érdemes a keresési osztályok bővítése, avagy szűkítése. Véleményem szerint fontos azt is látni, hogy többféle réteget, avagy paramétert tudunk együttesen, egyedi döntési szabályrendszer alapján is bevonni a képosztályozás lépésébe. Ami egyelőre még érdekes eredményt jelentett számomra, hogy a PCA elemzés is bevonható az elemzési lépésbe, így ennek további fókuszáltabb vizsgálata véleményem szerint fontos lesz a jövőben.

Bizonyítani szerettem volna, hogy a precíziós mezőgazdaság egyre nagyobb felbontást megkövetelő elvárásait jobban el tudjuk majd látni, és megfelelő pontosság mellett a drónokon hordozott szenzorokkal, mint a műholdas távérzékelésben elérhető lehetőségeinkkel. A műholdas távérzékelés adatfeldolgozása viszont továbbra is alkalmas lesz a drónok által előállított adatmennyiség feldolgozására, viszont véleményem szerint az adatfeldolgozást segíti a vektoros adatpontokon történő gyűjtés és elemzés, illetve a térbeli adatbázisba szervezés megoldása.

. Az olyan célú vizsgálatok esetén, ahol akár növénybetegségeket, kártevők detektálását, avagy ilyen méretű elváltozásokat, speciális növényi részeket szeretnénk analízis alá vetni, akkor a drónos felvételezés már akár 70 méteres magasságnál is eléri ezt, míg a műholdas távérzékelés esetén nem. Emellett a terepi kézi mérésekkel ellentétben jóval gyorsabban képesek vagyunk így információt gyűjteni adott területről.

Mivel felmerült, hogy a növényborítottság időbeli változásának későbbi módszereinek kidolgozását is segíti ezen felmérés, így erre is igazolást nyertünk, hogy alkalmas ezen módszer ennek elvégzésére.

A valós idejű képfeldolgozás szempontjából a döntési fa módszere érte el a leggyorsabb futási időt, melyet annak tulajdonítok, hogy egyszerű rétegek felhasználásával tudtam egy komplex szabályrendszert kidolgozni (például a többi elemzésben használt 8 GB-os 5 csatornás képpel szemben az „egyszerű” rétegek esetében 1 GB alatti (NDVI, termális csatorna) vagy 1-2 GB közötti fájl méretű (vörös, zöld, NIR, PCA) rétegekre dolgoztam ki jelen szabályokat. Ez utóbbi magyarázhatja a drasztikusan alacsonyabb futási időt is, miközben láthattuk, hogy a pontosság nem feltétlenül romlott. Mellett a módszer nagy előnye, hogy egyszerre sok különböző paramétert tesztelhetünk vele. Ahogy növeljük a paraméterek számát, úgy kapunk egyre pontosabb előrejelzési megoldást.

Távérzékelési szempontból a drónokon alkalmazott szenzorok kalibrációja ugyan kissé elmarad a terepi rendszereknél alkalmazott gyakorlattól, mégis eredményeik megfelelő pontossággal képesek helyettesíteni a terepi spektroradiométeres méréseket, vagy kombináltan is alkalmazhatóak. A multispektrális szenzorok esetén viszont a NIR-csatorna napon belüli felvételezését tovább érdemes vizsgálni. Egyelőre egy módszertani ajánlást fogalmaztam meg, hogy törekedjünk a déli órákban történő felvételezésre, mivel véleményem szerint a Nap állás változásai befolyásolják ezen csatorna mért értékeit. A jövőben ezen irányt tovább kell vizsgálni, ki kell zárni a szenzorspecifikus tényezőt, illetve meg kell vizsgálni, hogy a kamera szögének változtatásával, milyen irányban változik ezen eredmény, mely szintén akár egy későbbi módszertani ajánlasként beépíthető. Amennyiben pedig többféle körülmény befolyásolja a drónos multispektrális felvételek NIR tartományban mért értékeit, úgy az is megoldás lehet, hogy a RedEdge érzékelővel lesz célszerűbb dolgozni, a spektrális indexeket is eszerint újravizsgálva.

Véleményem szerint azt is érdemes lenne megvizsgálni a drónok által hordozott rendszerek esetén, hogy a repülési (felvételezési) magasság változása esetén a mért eredmények egyeznek-e, avagy változnak-e és amennyiben igen, milyen mértékben (a jövőben szeretném ezt is megvizsgálni).

Véleményem szerint a jövőbeni terepi rendszerek egymást kiegészítve lesznek fontosak. A spektroradiométerek elsősorban az üvegházi rendszerek, avagy nagyobb gépekre/robotokra szerelve az automatizácót és a vezérlést fogják tudni nagymértékben segíteni, akár beépítve ezen rendszerekbe. Míg a drónok a nagyobb területi felmérések monitoring feladatait már most megfelelő pontossággal ellátják.

Egyéb beavatkozási képességük, avagy a valós idejű vezérléshez viszont itt még az előbbieken összefoglalt fejlesztések szükségesek lesznek. De az is elképzelhető, hogy a drónokon alkalmazott szenzorok kalibrációit is segíthetik a terepi spektrometriás mérések.

Eredményeim alapján, a cm-es pontosságú UAV-képző elérésével fel kell készülni a gyorsan növekvő adatmennyiségre. Informatikai oldalról ez a növekvő futási időn keresztül érzékelhető. A képosztályozó algoritmusok értékelése alapján elmondható, hogy a felügyelt osztályozásban a SAM algoritmus bizonyult a legpontosabbnak a multispektrális adatfeldolgozás során. Mivel azonban a PCA analízis (különösen a vizuális kiértékelés után) meglepően jól feltérképezte a számomra legérdekesebb felszínborítási osztályokat, a jövőben szeretném ezt a módszert még pontosabban és több paraméterrel tovább vizsgálni. Egyúttal elmondható, hogy a PCA-elemzés segítheti a jövőben az UAV-képfeldolgozást, futási ideje valamivel ugyan magasabb, mint a felügyelt osztályozásoké, de segíthet más összetett modellalkotási folyamatot (pl. a növénytakaró sűrűségének változásait), és az eredményezett egyszerűsített adathalmaz miatt az erre épülő egyéb algoritmusok gyorsabbakká válnak egyúttal. Eredményeim szerint a PCA eredményeken alapuló osztályozásokhoz a MD és a ML algoritmusok ajánlottak.

Emellett szeretném tovább vizsgálni a döntési szabályok *Python*-alapú megoldásait is, bevonva ezeket egy sokoldalúbb modellalkotási folyamatba (pl. a növénytakaró sűrűségében bekövetkező változások feltérképezésébe, vízfelszín változásainak vizsgálatába). A rövid futási idő, a jó osztályszintű általános pontosság és az egyszerű GIS-be vagy más rendszerekbe való integrációja nagyban segítheti a jövőbeli, valós idejű fejlesztéseket.

Összességében az UAV rendszerek szenzoradatainak növekvő mennyisége már olyan - elsősorban időbeli - adatfeldolgozási nehézségeket vetnek fel, amelyek nem igazán teszik lehetővé a közel valós idejű rendszerekhez való kapcsolódást (miközben ez egyre inkább elvárás). Ráadásul az ilyen adatfeldolgozás csak kalibrálás, ortorektifikálás és egyéb előfeldolgozási megoldások után indítható el, amelyből az ortorektifikálás hasonló gépkonfigurációk esetén szintén 12-24h-t vett igénybe. Természetesen felhő alapú gyors adatátvitellel vagy nagyobb memóriakapacitással, illetve kisebb területi egységekre bontott elemzéssel gyorsítható. Így nagyobb figyelmet kellene fordítani olyan módszerek (pl. PCA, döntési szabályok) további kutatására, amelyek egyszerűbb adatrepresentációjuk révén gyorsabb futási időt érnek el kellő pontossággal.

5.1 Új és újszerű tudományos eredmények

1. Az általam tervezett, kifejlesztett és tesztelt optikai levélmérőadapter (klipsz) összehasonlító mérések alapján, megfelelő terepi használhatósággal rendelkezik, amely jelentősen javítja a kontaktáló növényi spektrometriás mérések eredményességét.
2. Kidolgoztam egy egységesített, spektrometriákra adaptált adatgyűjtési és adatkonverziós módszertant, amely jelentősen javítja a spektrális mérések közötti átjárhatóságot, átláthatóságot és

összehasonlíthatóságot, különös tekintettel a SPAD méterek, CRededge indexek, Lux-, és PAR mérőrendszereket, valamint a klorofill-, illetve víztartalomra vonatkozó kémiai labormérések esetére.

3. Bebizonyítottam, hogy a drónos multispektrális kamerarendszer kielégítő pontossággal helyettesíti a terepi spektroradiométeres kalibrációs méréseket, amennyiben az adatgyűjtés a nap maximális delelési magassága idején vagy annak közelében történik.

4. Bebizonyítottam, hogy a drónos multispektrális kamerarendszer nagyobb pontossággal helyettesíti a műholdas távérzékelés által elérhető méréseket, A részletesebb terepi elemzések, ezáltal a közel valós idejű beavatkozások fejlesztésébe is ezen módszertant lesz célszerű integrálni.

5. Kidolgoztam egy közel valós idejű, drónos képfeldolgozási eljárást hagyományos és mesterséges intelligenciát alkalmazó képosztályozási módszerek alkalmazásával döntéstámogató gyorsfelmérés és anomália detektálás céljából.

6 ÖSSZEFOGLALÁS / SUMMARY

Munkámmal szerettem volna gyakorlati oldalról segíteni a terepi távérzékelési megoldások felhasználását. Ezen célból vezérelve a spektrométerekkel való gyakorlati terepi munka fejlesztésére fókuszáltam, illetve a drónokon alkalmazott távérzékelési megoldásokkal és adatfeldolgozással foglalkoztam részletesebben.

Véleményem szerint mindkét terepi távérzékelési terület a jövőben elengedhetetlen lesz, mind a monitoring, mind a precízebb mezőgazdasági beavatkozások szempontjából, egyúttal könnyen összekapcsolhatóak az automatizált rendszer megoldásokkal. Véleményem szerint mindkét eszkörendszer segíti azon szemléletváltást, melynek célja, hogy a fizikai paraméterekkel szemben a biológiai, növényi életfolyamatokra fókuszálva (ezekre „válaszolva”) végezzük a mezőgazdasági beavatkozásokat. Ennek elérése még ugyan hosszabb út lesz, de véleményem szerint épp a terepi távérzékelési megoldások fejlesztése és az informatika nagyobb bevonása lehet majd ezek megoldása.

Munkámmal segíteni akartam egyrészt a spektrométerek terepi használatát egy állvány rendszer bemutatásával, illetve egy bárki számára megvalósítható klipsz eszköz létrehozásával. Kísérletekkel és mérésekkel igazolva, hogy ezek használata mellett is pontos méréseket tudunk biztosítani. Összehasonlító elemzéseimmel igyekeztem igazolni, hogy számos eszkörendszerrel képesek lehetünk egy spektrométerrel kiváltani (pl. SPAD mérő).

Adatfeldolgozási oldalról pedig 2 számológéppel szeretném segíteni a későbbi adatfeldolgozás gyorsabb elvégzésének lehetőségét, mely továbbfejlesztve nyílt forráskódú programként bárkit segíthet a kiértékelés során. Egyúttal célom volt előremozdítani a fénytani paraméterek növényvizsgálatok céljából történő mérését, rávilágítva és bizonyítva a jelenleg használt, többféle eltérő megközelítés növények szempontjából vizsgált gyengeségeire, pontatlanságaira, egyúttal fizikai alapokra helyezve a paraméterek megadásának, átszámításának lehetőségét.

Véleményem szerint ezzel elérhető egy spektrális alapokon nyugvó, fizikai megközelítés, mely egységesebb vizsgálati megoldást és összehasonlíthatóbb eredményeket jelent, egyúttal az automatizációt és a világítási vezérléseket is segíti, és a növényi fotoszintézis szempontjaira helyezi inkább a hangsúlyt.

Mivel véleményem szerint a terepi rendszerek másik fontos területe a drónokon hordozható eszközök, míg tapasztalataim szerint sokak számára kérdéses ezek méréseinek pontossága, illetve az adatfeldolgozás, emiatt ezen irányba is egy összefoglaló képet nyújtottam a jelenleg alkalmazható adatkiértékelési folyamatokról. Összehasonlító méréseimmel igazolni akartam, hogy a műholdas távérzékeléssel szemben mennyivel részletesebb adatelemzést tudunk mostanra elérni. Bár tapasztalatom szerint szükséges lesz valamilyen optimalizációra a megnövekedett adatmennyiség miatt, mely szerintem így nem teszi most még lehetővé más rendszerek valós idejű vezérlését (gondolok ezalatt a felvételezett távérzékelési adatok azonnali kiértékelt eredményeire építhető vezérléstechnikára), ennek ellenére

kutatási, és monitoring céllal egy sokkal szélesebb, mára már megfelelően pontos és terepi felbontását tekintve óriási lehetőségeket jelent. Az adatfeldolgozás bemutatása mellett egy újfajta megközelítést is bemutattam, melyet fókuszáltabb elemzések során tapasztalataim szerint előnyösebben és pontosabb eredménnyel tudunk alkalmazni. Így bemutattam egy egyedileg létrehozható döntési szabályrendszerre épülő képosztályozási megoldást, mely a 'ha-akkor' logikára épülve, többféle eltérő paraméter együttes és egyidejű vizsgálatát teszi ezáltal lehetővé.

With my work, I'd like to help the usability of remote sensing solutions in the field from a practical point of view. Guided by this goal, I focused on the development of practical field work with spectroradiometers, and I dealt in more detail with remote sensing solutions and data processing applied to drones.

In my opinion, both areas will be essential in the future, both in terms of monitoring and more precise agricultural interventions, and at the same time, they can be easily connected to automated system solutions. In my opinion, both systems of tools help the change of attitude, the aim of which is to focus biological and plant life processes in agricultural interventions instead of physical parameters. Achieving this will still take a long time, but in my opinion, the development of field remote sensing solutions and the greater involvement of IT will be the solution.

With my work, I wanted to help the field use of spectroradiometers by presenting a stand system and by creating a clip device that can be implemented by anyone. It has been proven by experiments and measurements that we can provide accurate measurements even when using them. With my comparative analyses, I tried to prove that we can replace many instrument systems with a spectroradiometer (e.g. SPAD meter).

On the data processing side, I would like to use 2 spreadsheets to help with the possibility of faster data processing, which, if further developed as an open source program, can help anyone during the evaluation. At the same time, my goal was to advance the measurement of photometric parameters for the purpose of plant tests, highlighting and proving the weaknesses and inaccuracies of the currently used, several different approaches from the point of view of plants, and at the same time putting the possibility of entering and recalculating the parameters on a physical basis.

In my opinion, this allows for a physical approach based on spectral foundations, which means a more uniform test solution and more comparable results, at the same time it helps automation and lighting controls, and it focuses more on the aspects of plant photosynthesis.

Since, in my opinion, another important field of field systems is the devices that can be carried on drones, while according to my experience, the accuracy of their measurements and data processing are questionable for many, this is why I wanted to provide a summary of the currently applicable data evaluation processes in this direction as well. With my comparative measurements, I wanted to prove

how much more detailed data analysis we can now achieve compared to satellite remote sensing. Although, according to my experience, some optimization will be necessary due to the increased amount of data, which, in my opinion, does not yet allow the real-time control of other systems (I am thinking of the control technique based on the immediately evaluated results of the recorded remote sensing data), nevertheless, for research and monitoring purposes, a much wider, it now offers enormous possibilities in terms of its sufficiently precise and field resolution. In addition to the presentation of data processing, I also wanted to develop and present a new kind of approach, which, according to my experience, can be applied more advantageously and with more accurate results during more focused analyses. This is how I presented an image classification solution based on an individually created decision rule system, which, based on the 'if-then' logic, enables the joint and simultaneous examination of several different parameters.

7 MELLÉKLETEK

M1 melléklet: Irodalomjegyzék

- ÁBRAHÁM, GY., DR. WENZELNÉ GERŐFY, K., ANTAL, Á., KOVÁCS G. (2014). *Műszaki Optika*. ISBN 978-963-313-202-9
- AGARWAL, A., EL-GHAZAWI, T., EL-ASKARY, H., LE-MOIGNE, J. (2007). Efficient Hierarchical - PCA Dimension Reduction for Hyperspectral Imagery. *IEEE Int. Symp. Signal Process. Inf. Technol.* 353–356 p. <https://doi.org/10.1109/ISSPIT.2007.4458191>.
- ALEXAKIS, D. D., TAPOGLOU, E., VOZINAKI, A. E. K., TSANIS, I. K. (2019). Integrated Use of Satellite Remote Sensing, Artificial Neural Networks, Field Spectroscopy, and GIS in Estimating Crucial Soil Parameters in Terms of Soil Erosion. *Remote Sens.* 11: 1106 p. <https://doi.org/10.3390/rs11091106>.
- AMPATZIDIS, Y., PARTEL, V., COSTA, L. (2020). Agroviz: Cloud-based application to process, analyze and visualize UAV-collected data for precision agriculture applications utilizing artificial intelligence. *Comput. Electron. Agric.* 174: 105457 p. <https://doi.org/10.1016/j.compag.2020.105457>.
- ANG, K.L.-M., SENG, J.K.P. (2021). Big Data and Machine Learning With Hyperspectral Information in Agriculture. *IEEE Access.* 9: 36699–36718 p. <https://doi.org/10.1109/ACCESS.2021.3051196>.
- APAN, A., HELD, A., PHINN, S., AND MARKLEY, J. (2004). Detecting sugarcane ‘orange rust’ disease using EO-1 Hyperion hyperspectral imagery. In *J. Remote Sensing.* 25:489-498 p. <https://doi.org/10.1080/01431160310001618031>
- ATHANASIS, N., THEMISTOCLEOUS, M., KALABOKIDIS, K., CHATZITHEODOROU, C. (2018). Big Data Analysis in UAV Surveillance for Wildfire Prevention and Management. In *Information Systems, Proceedings of the EMCIS 2018*, Limassol, Cyprus, 4–5 October 2018, Lecture Notes in Business Information Processing, Themistocleous, M., Rupino da Cunha, P., Eds., Springer: Hillerød, Denmark. 341: 47–58 p. https://doi.org/10.1007/978-3-030-11395-7_5.
- ASNER, G. P. (1998). Biophysical and Biochemical Sources of Variability in Canopy Reflectance. *Remote Sensing of Environment*, 64: 234-253 p.
- BALÁZSIK, V., TÓTH, Z. (2019). Az UAV Technológia Pontosság Kérdései. In *Proceedings of the Conference: Drón Felhasználói Fórum, Budapest, Hungary, 8 November 2019*. <https://doi.org/10.13140/RG.2.2.33934.92481>.
- BAUCKHAGE, C., KERSTING, K. (2013). Data mining and pattern recognition in agriculture. *Künstl. Intell.* 27: 313-324 p.

- BAURIEGEL, E., BRABANDT, H., GÄRBER, U., HERPPICH, W. B. (2014). Chlorophyll fluorescence imaging to facilitate breeding of *Bremia lactucae*-resistant lettuce cultivars. *Comput. Electron. Agric.* 105: 74-82 p. <https://doi.org/10.1016/j.compag.2014.04.010>
- BAUMGARTNER, S., BOGNÁR, G., LANG, O., HUEMER, M. (2021). Neural Network Based Data Estimation for Unique Word OFDM. In Proceedings of the 2021 55th Asilomar Conference on Signals, Systems, and Computers, Pacific Grove, CA, USA, 30 October–2 November 2021, 381–388 p. <https://doi.org/10.1109/IEEECONF53345.2021.9723229>.
- BAURIEGEL, E., GIEBEL, A., GEYER, M., SCHMIDT, U., HERPPICH, W. B. (2011). Early detection of *Fusarium* infection in wheat using hyper-spectral imaging. *Comput. Electron. Agric.* 75: 304-312 p. <https://doi.org/10.1016/j.compag.2010.12.006>
- BAZI, Y., MELGANI, F. (2018). Convolutional SVM Networks for Object Detection in UAV Imagery. *IEEE Trans. Geosci. Remote Sens.* 56: 3107–3118 p. <https://doi.org/10.1109/TGRS.2018.2790926>.
- BEHMANN, J., MAHLEIN, A. K., PAULUS, S., KUHLMANN, H., OERKE, E. C., PLÜMER, L. (2015). Calibration of hyperspectral close-range pushbroom cameras for plant phenotyping. *ISPRS J. Photogramm. Remote Sens.* 106: 172-182 p. <https://doi.org/10.1016/j.isprsjprs.2015.05.010>
- BEHMANN, J., MAHLEIN, A. K., RUMPF, T., RÖMER, C., PLÜMER, L. (2014). A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precis. Agric.* 16: 239-260 p. <https://doi.org/10.1007/s11119-014-9372-7>
- BERDUGO, C., ZITO, R., PAULUS, S., MAHLEIN, A.K. (2014). Fusion of sensor data for the detection and differentiation of plant diseases in cucumber. *Plant Pathol.* 63: 1344-1356 p. <https://doi.org/10.1111/ppa.12219>
- BERGSTRÄSSER, S., FANOURLAKIS, D., SCHMITTGEN, S., CENDRERO-MATEO, M. P., JANSEN, M., SCHARR, H., RASCHER, U. (2015). HyperART: non-invasive quantification of leaf traits using hyperspectral absorption-reflectance-transmittance imaging. *Plant Methods* 11: 1 p. <https://doi.org/10.1186/s13007-015-0043-0>
- BOCK, C. H., PARKER, P. E., COOK, A. Z., GOTTWALD, T. R. (2008). Visual rating and the use of image analysis for assessing different symptoms of citrus canker on grapefruit leaves. *Plant Dis.* 92: 530-541 p. <https://doi.org/10.1094/PDIS-92-4-0530> [Abstract]
- BOCK, C. H., POOLE, G. H., PARKER, P. E., GOTTWALD, T. R. (2010). Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *Crit. Rev. Plant Sci.* 29: 59-107 p. <https://doi.org/10.1080/07352681003617285>

- BOU KHEIR, R., BØCHER, P.K., GREVE, M.B., GREVE, M.H. (2010). The application of GIS based decision-tree models for generating the spatial distribution of hydromorphic organic landscapes in relation to digital terrain data. *Hydrol. Earth Syst. Sci.* 14: 847–857 p. <https://doi.org/10.5194/hess-14-847-2010>.
- BRABANDT, H., BAURIEGEL, E., GÄRBER, U., HERPPICH, W. B. (2014). ΦPSII and NPQ to evaluate *Bremia lactucae*-infection in susceptible and resistant lettuce cultivars. *Sci. Hortic.* (Amsterdam) 180: 123-129 p. <https://doi.org/10.1016/j.scienta.2014.10.012>
- BRAVO, C., MOSHOU, D., WEST, J., MCCARTNEY, A., RAMON, H. (2003). Early disease detection in wheat fields using spectral reflectance. *Biosystems Eng.* 84: 137-145 p. [https://doi.org/10.1016/S1537-5110\(02\)00269-6](https://doi.org/10.1016/S1537-5110(02)00269-6)
- BÜRLING, K., HUNSCHE, M., NOGA, G. (2011). Use of blue-green and chlorophyll fluorescence measurements for differentiation between nitrogen deficiency and pathogen infection in wheat. *J. Plant Physiol.* 168: 1641-1648 p. <https://doi.org/10.1016/j.jplph.2011.03.016>
- BUSEMEYER, L., RUCKELSHAUSEN, A., MÖLLER, K., MELCHINGER, A. E., ALHEIT, K. V., MAURER, H. P., HAHN, V., WEISSMANN, E. A., REIF, J. C., WÜRSCHMANN, T. (2013). Precision phenotyping of biomass accumulation in triticale reveals temporal genetic patterns of regulation. *Sci. Rep.* 3: 2442 p. <https://doi.org/10.1038/srep02442>
- CAMARGO, A., SMITH, J. S. (2009). Image pattern classification for the identification of disease causing agents in plants. *Comput. Electron. Agric.* 66: 121-125 p. <https://doi.org/10.1016/j.compag.2009.01.003>
- CAMPBELL, J. B. (2007). *Introduction to Remote Sensing*, 4th Ed. Guilford, New York.
- CARTER, G. A., AND KNAPP, A. K. (2001). Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. *Am. J. Bot.* 88: 677-684 p. <https://doi.org/10.2307/2657068>
- CECCATO, P., et al. (2001). Detecting Vegetation Leaf Water Content Using Reflectance in the Optical Domain. *Remote Sensing of Environment.* 77: 22-33 p.
- CHAERLE, L., HAGENBEEK, D., DE BRUYNE, E., VALCKE, R., VAN DER STRAETEN, D. (2004). Thermal and chlorophyll-fluorescence imaging distinguish plant-pathogen interactions at an early stage. *Plant Cell Physiol.* 45: 887-896 p. <https://doi.org/10.1093/pcp/pch097>
- CHAERLE, L., HAGENBEEK, D., DE BRUYNE, E., VAN DER STRAETEN, D. (2007). Chlorophyll fluorescence imaging for disease-resistance screening of sugar beet. *Plant Cell Tiss. Org.* 91: 97-106 p.
- CHAERLE, L., VAN DER STRAETEN, D. (2000). Imaging techniques and the early detection of plant stress. *Trends Plant Sci.* 5: 495-501 p. [https://doi.org/10.1016/S1360-1385\(00\)01781-7](https://doi.org/10.1016/S1360-1385(00)01781-7)

- CHANG, C. C., LIN, C. J. (2011). LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technol.* 2: 1–27 p. <https://doi.org/10.1145/1961189.1961199>.
- CHEN, K., REICHARD, G., AKANMU, A., XU, X. (2021). Geo-registering UAV-captured close-range images to GIS-based spatial model for building façade inspections. *Autom. Constr.* 122: 103503 p. <https://doi.org/10.1016/j.autcon.2020.103503>.
- COBB, J. N., DECLERCK, G., GREENBERG, A., CLARK, R., MCCOUCH, S. (2013). Next-generation phenotyping: requirements and strategies for enhancing our understanding of genotype-phenotype relationships and its relevance to crop improvement. *Theor. Appl. Genet.* 126: 867-887 p. <https://doi.org/10.1007/s00122-013-2066-0>
- CONGEDO, L. (2021). Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. *Journal of Open Source Software*, 6(64): 3172 p. <https://doi.org/10.21105/joss.03172>
- CRESSON, R. (2018). A Framework for Remote Sensing Images Processing Using Deep Learning Techniques. *IEEE Geosci. Remote Sens. Lett.* 16: 25–29 p. <https://doi.org/10.1109/LGRS.2018.2867949>.
- DAMMER, K., GARZ, A., HAMDORF, A., HOFFMANN, M., USTYZHANIN, A., SCHIRRMANN, M., LEITHOLD, P., LEITHOLD, H., VOLK, T., TACKENBERG, M. (2014). FUNGIPRECISE – a German project for precise real-time fungicide application in winter wheat. Pages 1-13 in: Proceedings of the 12th International Conference on Precision Agriculture.
- DANKS, C., BARKER, I. (2000). On-site detection of plant pathogens using lateral-flow devices. *EPPO Bull.* 30: 421-426 p. <https://doi.org/10.1111/j.1365-2338.2000.tb00922.x>
- DEL FIORE, A., REVERBERRI, M., RICELLI, A., PINZARI, F., SERRANTI, S., FABBRI, A. A., BONIFAZI, G., FANELLI, C. (2010). Early detection of toxigenic fungi on maize by hyperspectral imaging analysis. *Int. J. Food Microbiol.* 144: 64-71 p. <https://doi.org/10.1016/j.ijfoodmicro.2010.08.001>
- DELALIEUX, S., VAN AARDT, J., KEULEMANS, W., COPPIN, P. (2007). Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: non-parametric statistical approaches and physiological implications. *Eur. J. Agron.* 27: 130-143 p. <https://doi.org/10.1016/j.eja.2007.02.005>
- DOCTOR, K., BACHMANN, C., GRAY, D., MONTES, M., FUSINA, R. (2015). Wavelength dependence of the bidirectional reflectance distribution function (BRDF) of beach sands. *Appl. Opt.* 54: 243-255 p. <https://doi.org/10.1364/AO.54.00F243>
- DOUCHKOV, D., BAUM, T., IHLOW, A., SCHWEIZER, P., SEIFFERT, U. (2013). Microphenomics for interaction of barley with fungal pathogens. Pages 123-148 in: Genomics of Plant Genetic

- Resources. R. Tuberosa et al., eds. Springer Science+Business Media, Dordrecht, The Netherlands. https://doi.org/10.1007/978-94-007-7575-6_5
- ELMASRY, G., WANG, N., ELSAYED, A., NGADI, M. (2007). Hyperspectral imaging for nondestructive determination of some quality attributes for strawberry. *J. Food Eng.* 81: 98-107 P. <https://doi.org/10.1016/j.jfoodeng.2006.10.016>
- ELEK, I., CSERÉP, M. (2021). Processing Drone Images with the Open Source Giwer Software Package. In Proceedings of the Future Technologies, Virtual, 28–29 October 2021, Lecture Notes in Networks and Systems, Kacprzyk, J., Ed., Springer: Hillerød, Denmark. 359: 201–209 p. https://doi.org/10.1007/978-3-030-89880-9_15.
- FAN, B., LI, Y., ZHANG, R., FU, Q. (2020). Review on the Technological Development and Application of UAV Systems. *Chin. J. Electron.* 29: 199–207 p. <https://doi.org/10.1049/cje.2019.12.006>.
- FANTA-JENDE, P., STEININGER, D., BRUCKMÜLLER, F., SULZBACHNER, C. (2020). A versatile UAV near real-time mapping solution for disaster response - Concept, ideas and implementation. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* XLIII-B1-2020: 429–435 p. <https://doi.org/10.5194/isprs-archives-XLIII-B1-2020-429-2020>.
- FEKETE, A., CSERÉP, M. (2021). Tree segmentation and change detection of large urban areas based on airborne LiDAR. *Comput. Geosci.* 156: 104900 p. <https://doi.org/10.1016/j.cageo.2021.104900>.
- FIORANI, F., RASCHER, U., JAHNKE, S., SCHURR, U. (2012). Imaging plants dynamics in heterogenic environments. *Curr. Opin. Biotechnol.* 23:227-235. <https://doi.org/10.1016/j.copbio.2011.12.010>
- FIORANI, F., AND SCHURR, U. (2013). Future scenarios for plant phenotyping. *Annu. Rev. Plant Biol.* 64:267-291. <https://doi.org/10.1146/annurev-arplant-050312-120137>
- FISCHER, W. A. (1975). History of remote sensing. Pages 27-50 in: Manual of Remote Sensing. R. G. Reeves, ed. American Society of Photogrammetry, Falls Church, VA.
- FRANKE, J., AND MENZ, G. (2007). Multi-temporal wheat disease detection by multispectral remote sensing. *Precis. Agric.* 8:161-172. <https://doi.org/10.1007/s11119-007-9036-y>
- FURBANK, R. T., AND TESTER, M. (2011). Phenomics – technologies to relieve the phenotyping bottleneck. *Trends Plant Sci.* 16:635-644. <https://doi.org/10.1016/j.tplants.2011.09.005>
- GEBBERS, R., AND ADAMCHUK, V. I. (2010). Precision agriculture and food security. *Science* 327:828-831. <https://doi.org/10.1126/science.1183899>

- GITELSON, A. A., KAUFMAN, Y. J., STARK, R., AND RUNDQUIST, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sens. Environ.* 80:76-87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)
- GLAZEBROOK, J. (2005). Contrasting mechanisms of defense against biotrophic and necrotrophic pathogens. *Annu. Rev. Phytopathol.* 43:205-227. <https://doi.org/10.1146/annurev.phyto.43.040204.135923>
- GOMEZ, S. (2014). Infection and spread of *Peronospora sparsa* on *Rosa* sp. (Berk.) - a microscopic and a thermographic approach. Dissertation, University of Bonn, Germany.
- GÓMEZ-CANDÓN, D., DE CASTRO, A.I., LÓPEZ-GRANADOS, F. (2014). Assessing the accuracy of mosaics from unmanned aerial vehicle (UAV) imagery for precision agriculture purposes in wheat. *Precis. Agric.* 15: 44–56 p. <https://doi.org/10.1007/s11119-013-9335-4>.
- GRANIER, C., AND VILE, D. (2014). Phenotyping and beyond: modelling the relationships between traits. *Curr. Opin. Plant Biol.* 18:96-102. <https://doi.org/10.1016/j.pbi.2014.02.009>
- GRIEVE, B., HAMMERSLEY, S., MAHLEIN, A.-K., OERKE, E.-C., AND GOLDBACH, H. (2015). Localized multispectral crop imaging sensors: Engineering & validation of a cost effective plant stress and disease sensor. Pages 1-6 in: *Sensors Applications Symposium (SAS)*, 2015 IEEE, April 2015. <https://doi.org/10.1109/SAS.2015.7133588>
- GRIZONNET, M., MICHEL, J., POUGHON, V., INGLADA, J., SAVINAUD, M., CRESSON, R., ET AL. (2017). Orfeo ToolBox: Open source processing of remote sensing images. *Open Geospat. Data Softw. Stand.* 2: 15 p. <https://doi.org/10.1186/s40965-017-0031-6>.
- GUO, Q., ZHU, Z. (2014). Phenotyping of Plants. *Encyclopedia of Analytical Chemistry*. 1–15 p.
- GUEYMARD, C.A., (2004). The sun's total and spectral irradiance for solar energy applications and solar radiation models. *Solar Energy* 76(4):423-453
- HARIDAS, N., SOWMYA, V., SOMAN, K.P. (2015). GURLS vs LIBSVM: Performance Comparison of Kernel Methods for Hyperspectral Image Classification. *Indian J. Sci. Technol.* 8: 1–10. <https://doi.org/10.17485/ijst/2015/v8i24/80843>.
- HILLNHÜTTER, C., AND MAHLEIN, A.-K. (2008). Early detection and localization of sugar beet diseases: new approaches. *Gesunde Pflanz.* 60:143-149.
- HILLNHÜTTER, C., MAHLEIN, A.-K., SIKORA, R. A., AND OERKE, E.-C. (2011). Remote sensing to detect plant stress induced by *Heterodera schachtii* and *Rhizoctonia solani* in sugar beet fields. *Field Crops Res.* 122:70-77. <https://doi.org/10.1016/j.fcr.2011.02.007>
- HILLNHÜTTER, C., SCHWEIZER, A., KÜHNHOLD, V., AND SIKORA, R. A. (2010). Remote sensing for the detection of soil-borne plant parasitic nematodes and fungal pathogens. Pages 151-165 in: *Precision crop protection—The challenge and use of heterogeneity*. E.-C. Oerke, R.

- Gerhards, G. Menz, and R. A. Sikora, eds. Springer, Dordrecht. https://doi.org/10.1007/978-90-481-9277-9_10
- HOGNOGI, G. G., POP, A. M., MARIAN-POTRA, A. C., SOMEȘFĂLEAN, T. (2021). The Role of UAS–GIS in Digital Era Governance. A Systematic Literature Review. *Sustainability*. 13: 11097 p. <https://doi.org/10.3390/su131911097>.
- HUANG, W., LAMB, D. W., NIU, Z., ZHANG, Y., LIU, L., AND WANG, J. (2007). Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging. *Precis. Agric.* 8:187-197. <https://doi.org/10.1007/s11119-007-9038-9>
- HUANG, Y., CHEN, Z., YU, T., HUANG, X., GU, X. (2018). Agricultural remote sensing big data: Management and applications. *J. Integr. Agric.* 17: 1915–1931 p. [https://doi.org/10.1016/S2095-3119\(17\)61859-8](https://doi.org/10.1016/S2095-3119(17)61859-8).
- HÜCKELHOVEN, R. (2007). Cell wall-associated mechanisms of disease resistance and susceptibility. *Annu. Rev. Phytopathol.* 45:101-127. <https://doi.org/10.1146/annurev.phyto.45.062806.094325>
- INZERILLO, L., ACUTO, F., DI MINO, G., UDDIN, M.Z. (2022). Super-Resolution Images Methodology Applied to UAV Datasets to Road Pavement Monitoring. *Drones*. 6: 171 p. <https://doi.org/10.3390/drones6070171>.
- ISO 23539:2005 (CIE S010/E:2004) Photometry - The CIE system of physical photometry
- JACKSON, H. R., AND WALLEN, V. R. (1975). Microdensitometer measurements of sequential aerial photographs of field beans infected with bacterial blight. *Phytopathology* 65:961-968. <https://doi.org/10.1094/Phyto-65-961>
- JACQUEMOUD, S., AND USTIN, S. L. (2001). Leaf optical properties: a state of the art. Pages 223-232 in: Proceedings of the 8th International Symposium Physical Measurements & Signatures in Remote Sensing, 8–12 January 2001, CNES, Aussois, France.
- JANSEN, M., GILMER, F., BISKUP, B., NAGEL, K. A., RASCHER, U., FISCHBACH, A., BRIEM, A., DREISSEN, G., TITTMANN, S., BRAUN, S., DE JAEGER, I., METZLAFF, M., SCHURR, U., SCHARR, H., AND WALTER, A. (2009). Simultaneous phenotyping of leaf growth and chlorophyll fluorescence via GROWSCREEN FLUORO allows detection of stress tolerance in *Arabidopsis thaliana* and other rosette plants. *Funct. Plant Biol.* 36: 902-14 p. <https://doi.org/10.1071/FP09095>
- JENSEN, R.R., HARDIN, P.J., YU, G. (2009). Artificial neural networks and remote sensing, *Geogr. Compass*. 3: 630–646 p. <https://doi.org/10.1111/j.1749-8198.2008.00215.x>.
- JENSEN, J. R. (2007). Pages 355-408 in: Remote sensing of the environment: an earth resource perspective. 2nd ed. D. Kaveney, ed. Prentice Hall, Upper Saddle River, NJ.

- JONES, H. G. (1992). Plant and microclimate, 2nd ed. Cambridge University Press, Cambridge, UK.
- JONES, H. G., STOLL, M., SANTOIA, T., DE SOUSA, C., CHAVES, M. M., AND GRANT, O. M. (2002). Use of infrared thermography for monitoring stomatal closure in the field: Application to grapevine. *J. Exp. Bot.* 53: 2249-2260 p. <https://doi.org/10.1093/jxb/erf083>
- JUNG, A., VOHLAND, M. (2022). Hyperspectral Remote Sensing and Field Spectroscopy: Applications in Agroecology and Organic Farming. 99–121 p. In: De Marchi, M., Diantini, A. (Szerk.) *Drones Information Technologies in Agroecology and Organic Farming Contributions to Technological Sovereignty, 1st ed.*. CRC Press: Boca Raton, USA. <https://doi.org/10.1201/9780429052842>.
- KALLIMANI C., DEHKORDI R. H., VAN EVERT F., KOOISTRA L., RIJK B. (2020). UAV-based Multispectral & Thermal dataset for exploring the diurnal variability, radiometric & geometric accuracy for precision agriculture, <https://doi.org/10.7910/DVN/RYA2ZQ>, Harvard Dataverse, V1
- KONANZ, S., KOCSÁNYI, L., AND BUSCHMANN, C. (2014). Advanced multi-color fluorescence imaging system for detection of biotic and abiotic stresses in leaves. *Agriculture* 4:79-95. <https://doi.org/10.3390/agriculture4020079>
- KUSKA, M., WAHABZADA, M., LEUCKER, M., DEHNE, H.-W., KERSTING, K., OERKE, E.-C., STEINER, U., AND MAHLEIN, A.-K. (2015). Hyperspectral phenotyping on microscopic scale – towards automated characterization of plant-pathogen interactions. *Plant Methods* 11:28. <https://doi.org/10.1186/s13007-015-0073-7>
- LAMARI, L. (2008) Assess 2.0 Image Analysis Software for Plant Disease Quantification. American Phytopathological Society, St. Paul. ISBN: 9780890543696
- LENTHE, J.-H., OERKE, E.-C., AND DEHNE, H.-W. (2007). Digital infrared thermography for monitoring canopy health of wheat. *Precis. Agric.* 8:15-26. <https://doi.org/10.1007/s11119-006-9025-6>
- LI, Y., MELGANI, F., HE, B. (2019). Fully Convolutional SVM for Car Detection in UAV Imagery. *In Proceedings of the IGARSS 2019—2019 IEEE International Geoscience and Remote Sensing Symposium*, Yokohama, Japan, 28 July–2 August 2019, pp. 2451–2454. <https://doi.org/10.1109/IGARSS.2019.8898661>.
- LICCIARDI, G., MARPU, P.R., CHANUSSOT, J., BENEDIKTSSON, J.A. (2012). Linear Versus Nonlinear PCA for the Classification of Hyper-spectral Data Based on the Extended Morphological Profiles. *IEEE Geosci. Remote Sens. Lett.* 9: 447–451 p. <https://doi.org/10.1109/LGRS.2011.2172185>.

- LIU, J., XIANG, J., JIN, Y., LIU, R., YAN, J., WANG, L. (2021). Boost Precision Agriculture with Unmanned Aerial Vehicle Remote Sensing and Edge Intelligence: A Survey. *Remote Sens.* 13: 4387 p. <https://doi.org/10.3390/rs13214387>.
- LUO, F., JIANG, C., YU, S., WANG, J., LI, Y., REN, Y. (2019). Stability of Cloud-Based UAV Systems Supporting Big Data Acquisition and Processing. *IEEE Trans. Cloud Comput.* 7: 866–877 p. <https://doi.org/10.1109/TCC.2017.2696529>.
- MAHLEIN, A.-K., OERKE, E.-C., STEINER, U., AND DEHNE, H.-W. (2012). Recent advances in sensing plant diseases for precision crop protection. *Eur. J. Plant Pathol.* 133:197-209. <https://doi.org/10.1007/s10658-011-9878-z>
- MAHLEIN, A.-K., RUMPF, T., WELKE, P., DEHNE, H.-W., PLÜMER, L., STEINER, U., AND OERKE, E.-C. (2013). Development of spectral vegetation indices for detecting and identifying plant diseases. *Remote Sens. Environ.* 128:21-30. <https://doi.org/10.1016/j.rse.2012.09.019>
- MAHLEIN, A.-K., STEINER, U., DEHNE, H.-W., AND OERKE, E.-C. (2010). Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. *Precis. Agric.* 11:413-431. <https://doi.org/10.1007/s11119-010-9180-7>
- MAHLEIN, A.-K., STEINER, U., HILLNHÜTTER, C., DEHNE, H.-W., AND OERKE, E.-C. (2012). Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet disease. *Plant Methods* 8:3. <https://doi.org/10.1186/1746-4811-8-3>
- MARTINELLI, F., SCALENGHE, R., DAVINO, S., PANNON, S., SCUDERI, G., RUISI, P., VILLA, P., STROPPIANA, D., BOSCHETTI, M., GOULART, L. R., DAVIS, C. E., AND DANDEKAR, A. M. (2014). Advanced methods for plant disease detection. A review. *Agron. Sustain. Dev.* 35:1-25. <https://doi.org/10.1007/s13593-014-0246-1>
- MCCREE, K.J. (1972). TEST OF CURRENT DEFINITIONS OF PHOTOSYNTHETICALLY ACTIVE RADIATION AGAINST LEAF PHOTOSYNTHESIS DATA, *AGRIC, METEOROL.* 10: 43-453 p.
- MEHL, P. M., CHEN, Y.-R., KIM, S. M., AND CHAN, D. E. (2004). Development of hyperspectral imaging technique for the detection of apple surface defects and contaminations. *J. Food Eng.* 61:67-81. [https://doi.org/10.1016/S0260-8774\(03\)00188-2](https://doi.org/10.1016/S0260-8774(03)00188-2)
- MEWES, T., FRANKE, J., AND MENZ, G. (2011). Spectral requirements on airborne hyperspectral remote sensing data for wheat disease detection. *Precis. Agric.* 12:795-812. <https://doi.org/10.1007/s11119-011-9222-9>
- MITTAL, P., SHARMA, A., SINGH, R., SANGAIAH, A.K. (2022). On the performance evaluation of object classification models in low altitude aerial data. *J. Supercomput.* 78: 14548–14570 p. <https://doi.org/10.1007/s11227-022-04469-5>.

- MOORE, G. K. (1979). What is a picture worth? A history of remote sensing. *Hydrolog. Sci. B.* 24: 477-485 p.
- MOSHOUB, D., BRAVO, C., WEST, J., WAHLEN, S., MCCARTNEY, A., AND RAMON, H. (2004). Automatic detection of 'yellow rust' in wheat using reflectance measurements and neural networks. *Comput. Electron. Agric.* 44: 173-188 p. <https://doi.org/10.1016/j.compag.2004.04.003>
- MURCHIE, E. H., LAWSON, T. (2013). Chlorophyll fluorescence analysis: a guide to good practice and understanding some new applications. *J. Exp. Bot.* 64:3983-3998.
- NASROLLAHI, K., MOESLUND, T. B. (2014). Super-resolution: A comprehensive survey. *Mach. Vis. Appl.* 25: 1423–1468 p. <https://doi.org/10.1007/s00138-014-0623-4>.
- NEUMANN, M., HALLAU, L., KLATT, B., KERSTING, K., AND BAUCKHAGE, C. (2014). Erosion band features for cell phone image based plant disease classification. Pages 3315-3320 in: Proceeding of the 22nd International Conference on Pattern Recognition (ICPR), Stockholm, Sweden, 24-28 August 2014.
- NEWTON, A. C., HACKETT, C. A. (1994). Subjective components of mildew assessment on spring barley. *Eur. J. Plant Pathol.* 100: 395-412 p. <https://doi.org/10.1007/BF01874807>
- NILSSON, H. E. (1991). Hand-held radiometry and IR-thermography of plant diseases in field plot experiments. *Int. J. Remote Sens.* 12:545-557. <https://doi.org/10.1080/01431169108929671>
- NILSSON, H.-E. (1995). Remote sensing and imaging analysis in plant pathology. *Can. J. Plant Pathol.* 17:154-166. <https://doi.org/10.1080/07060669509500707>
- NUTTER, F. W., JR. (2001). Disease assessment terms and concepts. Pages 312-323 in: Encyclopedia of Plant Pathology. O. C. Maloy and T. D. Murray, eds. John Wiley and Sons, Inc., New York.
- NUTTER, F. W., JR., GLEASON, M. L., JENCO, J. H., AND CHRISTIANS, N. C. (1993). Assessing the accuracy, intra-rater repeatability, and inter-rater reliability of disease assessment systems. *Phytopathology* 83:806-812. <https://doi.org/10.1094/Phyto-83-806>
- OERKE, E. C., FRÖHLING, P., STEINER, U. (2011). Thermographic assessment of scab disease on apple leaves. *Precis. Agric.* 12: 699-715 p. <https://doi.org/10.1007/s11119-010-9212-3>
- OERKE, E. C., MAHLEIN, A. K., STEINER, U. (2014). Proximal sensing of plant diseases. Pages 55-68 in: Detection and Diagnostic of Plant Pathogens, Plant Pathology in the 21st Century. M. L. Gullino and P. J. M. Bonants, eds. Springer Science and Business Media, Dordrecht, the Netherlands.
- OERKE, E. C., STEINER, U., DEHNE, H. W., AND LINDENTHAL, M. (2006). Thermal imaging of cucumber leaves affected by downy mildew and environmental conditions. *J. Exp. Bot.* 57: 2121-2132 p. <https://doi.org/10.1093/jxb/erj170>

- OFLI, F., MEIER, P., IMRAN, M., CASTILLO, C., TUIA, D., REY, N., BRIANT, J., MILLET, P., REINHARD, F., PARKAN, M., ET AL. (2016). Combining Human Computing and Machine Learning to Make Sense of Big (Aerial) Data for Disaster Response. *Big Data*, 4: 47–59 p. <https://doi.org/10.1089/big.2014.0064>.
- Optical radiation physics and illuminating engineering - Part 10: Photobiologically effective radiation, quantities, symbols and action spectra, DIN 5031-10:2018, Beuth, Berlin 2018 Parlevliet, J. E. 1979. Components of resistance that reduce the rate of epidemic development. *Annu. Rev. Phytopathol.* 17: 203-222 p. <https://doi.org/10.1146/annurev.py.17.090179.001223>
- PATEL, H.H., PRAJAPA, P. (2018). Study and Analysis of Decision Tree Based Classification Algorithms. *Int. J. Comput. Appl.* 6: 74–78 p. <https://doi.org/10.26438/ijcse/v6i10.7478>.
- PAULUS, S., BEHMANN, J., MAHLEIN, A.-K., PLÜMER, L., AND KUHLMANN, H. (2014). Low-cost 3D systems: suitable tools for plant phenotyping. *Sensors (Basel Switzerland)* 14:3001-3018. <https://doi.org/10.3390/s140203001>
- PAULUS, S., DUPUIS, J., MAHLEIN, A.-K., AND KUHLMANN, H. (2013). Surface feature based classification of plant organs from 3D laserscanned point clouds for plant phenotyping. *BMC Bioinformatics* 14:238. <https://doi.org/10.1186/1471-2105-14-238>
- PEÑUELAS J, FILELLA I, BIEL C, SERRANO L, SAVE R. (2015). The reflectance at the 950–970 mm region as an indicator of plant water status. *International Journal of Remote Sensing*. 1993,14: 1887–1905 p.
- PETHYBRIDGE, S. J., NELSON, S. C. (2015). Leaf doctor: a new portable application for quantifying plant disease severity. *Plant Dis.* 99: 1310-1316 p.
- POLAND, J. A., BALINT-KURT, P. J., WISSER, R. J., PRATT, R. C., AND NELSON, R. J. (2009). Shades of gray: the world of quantitative disease resistance. *Trends Plant Sci.* 14:21-29. <https://doi.org/10.1016/j.tplants.2008.10.006>
- POLDER, G., VAN DER HEIJDEN, G. W. A. M., VAN DOORN, J., AND BALTISSEN, T. A. H. M. C. (2014). Automatic detection of tulip breaking virus (TBV) in tulip fields using machine vision. *Biosystems Eng.* 117:35-42. <https://doi.org/10.1016/j.biosystemseng.2013.05.010>
- PUNITHA, P.A., SUTHA, J. (2020). Object based classification of high resolution remote sensing image using HRSVM-CNN classifier. *Eur. J. Remote Sens.* 53: 16–30 p. <https://doi.org/10.1080/22797254.2019.1680259>.
- QIN, J., BURKS, T. F., RITENOUR, M. A., AND BONN, W. G. (2009). Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. *J. Food Eng.* 93:183-191. <https://doi.org/10.1016/j.jfoodeng.2009.01.014>

- RIKER, A. J., AND RIKER, R. S. (1936). Introduction to research on plant diseases - a guide to the principles and practice for studying various plant-disease problems. John S. Swift Co., Inc., Buffalo Grove, IL.
- ROBINSON, R. A. (1969). Disease resistance terminology. *Rev. Appl. Mycol.* 48:593-606.
- ROSSINI, M., ALONSO, L., COGLIATI, S., DAMM, A., GUANTER, L., JULIETTA, T., MERONI, M., MORENO, J., PANIGADA, C., PINTO, F., RASCHER, U., SCHICKLING, A., SCHÜTTEMEYER, D., ZEMEK, F., AND COLOMBO, R. (2014). Measuring sun-induced chlorophyll fluorescence: an evaluation and synthesis of existing field data. Pages 1-5 in: 5th International Workshop on Remote Sensing of Vegetation Fluorescence, 22-24 April 2014, Paris.
- ROUSSEAU, C., BELIN, E., BOVE, E., ROUSSEAU, D., FABRE, F., BERRUYER, R., GUILLAUMES, J., MANCEAU, C., JAQUES, M.A., BOUREAU, T. (2013). High throughput quantitative phenotyping of plant resistance using chlorophyll fluorescence image analysis. *Plant Methods* 9: 17 p. <https://doi.org/10.1186/1746-4811-9-17>
- RUMPF, T., MAHLEIN, A. K., STEINER, U., OERKE, E. C., DEHNE, H. W., PLÜMER, L. (2010). Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. *Comput. Electron. Agric.* 74: 91-99 p. <https://doi.org/10.1016/j.compag.2010.06.009>
- SANKARAN, S., MISHRA, A., EHSANI, R., DAVIS, C. (2010). A review of advanced techniques for detecting plant diseases. *Comput. Electron. Agric.* 72:1-13. <https://doi.org/10.1016/j.compag.2010.02.007>
- SCHOLES, J. D., ROLFE, S. A. (2009). Chlorophyll fluorescence imaging as tool for understanding the impact of fungal diseases on plant performance: a phenomics perspective. *Funct. Plant Biol.* 36:880-892. <https://doi.org/10.1071/FP09145>
- SCHULZE-LEFERT, P., AND PANSTRUGA, R. (2003). Establishment of biotrophy by parasitic fungi and reprogramming of host cells for disease resistance. *Annu. Rev. Phytopathol.* 41:641-667. <https://doi.org/10.1146/annurev.phyto.41.061002.083300>
- SEELAN, S. K., LAGUETTE, S., CASADY, G. M., SEIELSTAD, G. A. (2003). Remote sensing applications for precision agriculture: a learning community approach. *Remote Sens. Environ.* 88:157-169. <https://doi.org/10.1016/j.rse.2003.04.007>
- SHANG, X., SONG, M., WANG, Y., YU, C. (2021). Target-Constrained Interference-Minimized Band Selection for Hyperspectral Target Detection. *IEEE Trans. Geosci. Remote Sens.* 59: 6044–6064 p. <https://doi.org/10.1109/TGRS.2020.3010826>.
- SIRAT, E.F., SETIAWAN, B.D., RAMDANI, F. (2018). Comparative Analysis of K-Means and Isodata Algorithms for Clustering of Fire Point Data in Sumatra Region. *In Proceedings of the*

- 4th International Symposium on Geoinformatics (ISyG), Malang, Indonesia, 10–12 November. pp. 1–6. <https://doi.org/10.1109/ISYG.2018.8611879>.
- ŚLEDZIOWSKI, J., TREFENKO, P., GIZA, A., FORCZMAŃSKI, P., ŁYSKO, A., MAĆKÓW, W., STĘPIEŃ, G., TOMCZAK, A., KURYLCZYK, A. (2022). Application of Unmanned Aerial Vehicles and Image Processing Techniques in Monitoring Underwater Coastal Protection Measures. *Remote Sens.* 14: 458 p. <https://doi.org/10.3390/rs14030458>.
- SNAP—ESA Sentinel Application Platform v8.0.0. Available online: <https://step.esa.int> (letöltés dátuma: 2020.10.25.).
- STAFFORD, J. V. (2000). Implementing precision agriculture in the 21st century. *J. Agric. Eng. Res.* 76:267-275. <https://doi.org/10.1006/jaer.2000.0577>
- STEDDOM, K., HEIDEL, G., JONES, D., RUSH, C. M. (2003). Remote detection of rhizomania in sugar beet. *Phytopathology* 93:720-726. <https://doi.org/10.1094/PHYTO.2003.93.6.720>
- STEDDOM, K., BREDEHOEFT, M. W., KHAN, M., RUSH, C. M. (2005). Comparison of visual and multispectral radiometric disease evaluations of *Cercospora* leaf spot of sugar beet. *Plant Dis.* 89:153-158. <https://doi.org/10.1094/PD-89-0153>
- STEINER, U., BÜRLING, K., OERKE, E. C. (2008). Sensorik für einen präzisierten Pflanzenschutz. *Gesunde Pflanz.* 60:131-141. <https://doi.org/10.1007/s10343-008-0194-2>
- TAIZ, L. & ZEIGEL, E. (2010). *Plant Physiology*, Fifth Edition. Publisher: Sinauer Associates Inc. Sunderland, Massachusetts, US. ISBN: 0878938664
- TORRES, P. A., LOPEZ, G. R. (2013). Measuring Daily Light Integral in a Greenhouse Ariana Department of Horticulture and Landscape Architecture, Purdue University, Barbedo, J. G. A. 2013. Digital image processing techniques for detecting, quantifying and classifying plant diseases. *SpringerPlus.* 2: 660 p. <https://doi.org/10.1186/2193-1801-2-660>
- TSOUROS, D.C., BIBI, S., SARIGIANNIDIS, P.G. (2019). A Review on UAV-Based Applications for Precision Agriculture. *Information*, 10: 349 p. <https://doi.org/10.3390/info10110349>.
- TUCKER, C. C., CHAKRABORTY, S. (1997). Quantitative assessment of lesion characteristic and disease severity using digital image processing. *J. Phytopathol.* 145: 273-278 p. <https://doi.org/10.1111/j.1439-0434.1997.tb00400.x>
- UDDIN, MD. P., MAMUN, MD. A., AFJAL, M. I., HOSSAIN, A. (2021). Information-theoretic feature selection with segmentation-based folded principal component analysis (PCA) for hyperspectral image classification. *Int. J. Remote Sens.* 42:1, 286–321 p. <https://doi.org/10.1080/01431161.2020.1807650>.
- VOIGT, C. A. (2014). Callose-mediated resistance to pathogenic intruders in plant defense-related papillae. *Front. Plant Sci.* 5:168 <https://doi.org/10.3389/fpls.2014.00168>.

- WAHABZADA, M., MAHLEIN, A. K., BAUCKHAGE, C., STEINER, M., OERKE, E. C., KERSTING, K. (2015). Metro maps of plant disease dynamics—automated mining of differences using hyperspectral images. *PLoS One* 10:e0116902. <https://doi.org/10.1371/journal.pone.0116902>
- WAHABZADA, M., PAULUS, S., KERSTING, K., MAHLEIN, A.K. (2015). Automated interpretation of 3D laserscanned point clouds for plant organ segmentation. *BMC Bioinformatics*. 16: 248 p. <https://doi.org/10.1186/s12859-015-0665-2>
- WALTER, A., LIEBISCH, F., HUND, A. (2015). Plant phenotyping: from bean weighing to image analysis. *Plant Methods* 11: 14 p. <https://doi.org/10.1186/s13007-015-0056-8>
- WANG, H., DUAN, Y., SHI, Y., KATO, Y., NINOMIYA, S., GUO, W. (2021). EasyIDP: A Python Package for Intermediate Data Processing in UAV-Based Plant Phenotyping. *Remote Sens*. 13: 2622 p. <https://doi.org/10.3390/rs13132622>.
- WANG, P., WANG, L., LEUNG, H., ZHANG, G. (2021). Super-Resolution Mapping Based on Spatial-Spectral Correlation for Spectral Imagery. *IEEE Trans. Geosci. Remote Sens*. 59: 2256–2268 p. <https://doi.org/10.1109/TGRS.2020.3004353>.
- WANG, X., ZHANG, M., ZHU, J., GENG, S. (2008). Spectral prediction of *Phytophthora infestans* infection on tomatoes using artificial neural network (ANN). *Int. J. Remote Sens*. 29: 1693-1706 p. <https://doi.org/10.1080/01431160701281007>
- WARD, E., FOSTER, S. J., FRAAIJE, B. A., MCCARTNEY, H. A. (2004). Plant pathogen diagnostics: immunological and nucleic acid-based approaches. *Ann. Appl. Biol.* 145: 1-16 p. <https://doi.org/10.1111/j.1744-7348.2004.tb00354.x>
- WEST, J. S., BRAVO, C., OBERTI, R., LEMAIRE, D., MOSHOU, D., MCCARTNEY, H. A. (2003). The potential of optical canopy measurement for targeted control of field crop diseases. *Annu. Rev. Phytopathol.* 41: 593-614 p. <https://doi.org/10.1146/annurev.phyto.41.121702.103726>
- WEST, J. S., BRAVO, C., OBERTI, R., MOSHOU, D., RAMON, H., MCCARTNEY, H. A. (2010). Detection of fungal diseases optically and pathogen inoculum by air sampling. Pages 135-149 p. in: Precision Crop Protection—The Challenge and Use of Heterogeneity. E.-C. Oerke, R. Gerhards, G. Menz, and R. A. Sikora, eds. Springer, Dordrecht, Netherlands. https://doi.org/10.1007/978-90-481-9277-9_9
- WIJEKOON, C. P., GOODWIN, P. H., HSIANG, T. (2008). Quantifying fungal infection of plant leaves by digital image analysis using Scion Image software. *J. Microbiol. Methods* 74: 94-101 p. <https://doi.org/10.1016/j.mimet.2008.03.008>
- WILLKOMM, M., BOLTEN, A., BARETH, G. (2016). Non-destructive monitoring of rice by hyperspectral in-field spectrometry and UAV-based remote sensing: Case study of field-grown

rice in north Rhine-Westphalia, Germany. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* XLI-B1: 1071–1077 p. <https://doi.org/10.5194/isprs-archives-XLI-B1-1071-2016>.

YAO, X., YANG, H., WU, Y., WU, P., WANG, B., ZHOU, X., WANG, S. (2019). Land Use Classification of the Deep Convolutional Neural Network Method Reducing the Loss of Spatial Features. *Sensors*. 19: 2792 p. <https://doi.org/10.3390/s19122792>.

ZAWIESKA, D., MARKIEWICZ, J., TUREK, A., BAKUŁA, K., KOWALCZYK, M., KURCZYŃSKI, Z., OSTROWSKI, W., PODLASIAK, P. (2016). Multi-criteria GIS analyses with the use of UAVs for the needs of spatial planning. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* XLI-B1: 1165–1171p. <https://doi.org/10.5194/isprs-archives-XLI-B1-1165-2016>.

ZHENG, C., SUN, D.-W. (2008). 2 - Image Segmentation Techniques. *In Computer Vision Technology for Food Quality Evaluation*, Sun, D-W., Ed., Academic Press: Cambridge, CA, USA, pp. 37–56. <https://doi.org/10.1016/B978-012373642-0.50005-3>.

M2 melléklet: Ábrajegyzék

1. ábra - A távérzékelés térbeli felosztása (Forrás: Jung, 2011)	5
2. ábra - Távérzékelési szenzorok hullámhossz szerinti érzékenysége (Forrás: Balázsik, V. Fotogrammetria I. (2010))	6
3. ábra - Különböző felszínek reflektancia görbéi (Forrás: Jung, 2011.)	9
4. ábra - A hiperspektrális adatfeldolgozás sémája (Forrás: Jung, 2011)	9
5. ábra - Növényi reflektancia görbe (Forrás: Jung, 2012.)	10
6. ábra - Elektromágneses spektrum. (Forrás: Eifert János, 2011)	11
7. ábra - Néhány fotoszintetikus pigment abszorpciós spektruma (balra) és fontosabb funkciójuk (jobbra), (Forrás: Taiz, L. & Zeiger, E., 2010)	15
8. ábra - PAR-on kívüli fotoreceptor "aktivitás" (Forrás: Weller, 2017)	18
9. ábra - A térszög értelmezése adott távolság mellett (Forrás: Ábrahám, 2014.)	25
10. ábra - A PAR, a VIS tartomány és a fotopikus válaszgörbe $V(\lambda)$ együttes ábrázolása a növényi klorofill elnyelésének sematizált, színezett képe mellett	26
11. ábra - Növények fényelnyelésének aránya	37
12. ábra - PROSAIL modell révén becsült eltérő reflektancia görbék eltérő LAI indexek szerinti alakulása (a modell során alkalmazott bemeneti paraméterek: ($C_{ab}=30 \mu\text{g cm}^{-2}$, $C_{ar}=0$, $C_w=0.01 \text{ cm}$, $C_m=0.005 \text{ g cm}^{-2}$, $N_{stru}=1.5$, $ALA=\text{spherical}$, $H_{spot}=0.25$, $skyl=0.23$, $\theta_s=30$)	41
13. ábra – Jelenlegi szenzor technológiák	44
14. ábra - Qmini spektrométer képe	54
15. ábra – Az összehasonlításhoz használt Plant Probe-bal kiegészített ASD Fieldspec Handheld 2 spektrométer	59

16. ábra - Kísérleteimben használt szabályozható LED lámpák (balra: Tungsram Research Modul, jobbra: KIND LED K5)	61
17. ábra - Kísérleteimben használt, szabályozható LED lámpák spektruma saját mérések alapján	61
18. ábra - A PAR relatív spektrális függvénye	63
19. ábra - Klorofill A és B abszorpciója	65
20. ábra - Tisza-tavi vizsgálati terület, Magyarország: (a) Sentinel-2 MSIL2A műholdkép valódi színekompozitja az előfeldolgozás után; (b) Micasense Altum 5 sávú ortofotójának valódi színekompozitja az előfeldolgozás után	71
21. ábra - Referencia növényborítás képe a terepi bejárás alapján	71
22. ábra - Vektorpontok (150 db) elhelyezkedése a célterület adatgyűjtési céljából	75
23. ábra - Asztali állvány képe, mely forgatható, a rögzítés 45 fokban tartja a spektrométert, a tartórúd több méretben cserélhető	77
24. ábra - Az AUTOCAD szoftverben elkészített klipsz mérési adapter modell képe többféle nézetből (balról 3 db kép), végleges, cserélhető verzió (jobbra)	77
25. ábra - Raspberry Pi-hez csatlakoztatott Qmini spektrométer, internet eléréssel, egérrel és TFT kijelzővel bővítve	78
26. ábra - KIND K5 és Sylvania GroLux 600W HPS besugárzásának (a.) és fotonfluxusának (b.) összehasonlító mérésének eredményei	79
27. ábra - KIND K5 lámpa alatti terület megvilágítási erejének mérése 50 cm-es távolságból	81
28. ábra – A Nap besugárzása és fotonfluxusa, mérés időpontja: 2019.08.06., Qmini	81
29. ábra - 4 mesterséges világítási rendszer és a Nap (2019.08.09) mért értékei alapján számolt eredmények bemutatása a vezérlőtábla használatának segítségével	82
30. ábra - Vizsgált fényforrások klorofill A-B-re súlyozott fotonfluxusa	83
31. ábra - Nap mérésén modellezett eltérő szenzorérzékenységek	83
32. ábra – Klorofill-tartalom változása, illetve a spektrális klorofill index	85
33. ábra - Nitrogén indexek korrelációs együtthatói a laborban detektált nitrogén szárazanyag-tartalommal	88
34. ábra – Növények reflektancia görbéinek összevetése a kálium tartalomra vonatkozó korrelációs együtthatóval	90
35. ábra – Spektrométeres mérések összevetése a Sequoia multispektrális szenzor több időpontban történő méréseivel, a szórást vizsgálva, csatornák szerinti bontásban: a.) zöld tartomány; b.) vörös tartomány c.) RedEdge tartomány d.) NIR tartomány	91
36. ábra - Sequoia kamera különböző időpontokban jellemző, NIR-csatornában mért reflektancia értékei különböző felszínborítások esetén	92

37. ábra - Sequoia kamera különböző időpontokban jellemző, RedEdge-csatornában mért reflektancia értékei különböző felszínborítások esetén	92
38. ábra - Sequoia kamera mért értékei alapján kalkulált NDVI index értékei különböző felszínborítások esetén	93
39. ábra - Tec5 Handyspec spektrométer NIR-csatornában mért reflektancia értékeinek időbeli eltérései különböző felszínborítás esetén	94
40. ábra - Sequoia kamera NIR-csatornában felvételezett adatainak időbeli lefutása és szórása a reggeli, déli és koraesti mérések alapján (kizárva a délelőtti, illetve délutáni méréseket)	94
41. ábra – a) Valós színes ortofotó a Tisza tavi drónfelmérés alapján; b) referenciaterületek	95
42. ábra - Micasense Altum Tisza tavi felmérésének képrészlete (zoom)	96
43. ábra - Micasense Altum Tisza tavi felmérésének hamisszínes képei csatornák szerinti bontásban: a) kék-csatorna; b) zöld-csatorna; c) vörös-csatorna; d) RedEdge-csatorna; e) NIR-csatorna; f) termális csatorna	97
44. ábra - Micasense Altum Tisza tavi felmérésének különböző hamisszínes többcsatornás képe eltérő csatorna kompozitok mellett: a) kompozit: NIR - Green - Blue; b) kompozit: NIR - Red - Green;	99
45. ábra - Micasense Altum Tisza tavi felmérésének különböző hamisszínes többcsatornás képe eltérő csatorna kompozitok mellett: a) kompozit: NIR - RedEdge - Red; b) kompozit: RedEdge – Red - Green;	100
46. ábra - Sentinel műholdkép képosztályozási algoritmusok szerinti eredményei, jobb felső sarokban a drónképek ugyanazon algoritmus szerinti osztályozott eredményeivel	102
47. ábra – Sentinel-2 műholdkép osztályozási algoritmusainak pontossági %-a ; b) Sentinel-2 műholdkép osztályozási eredményeinek pontossági eredménye a Kappa indexsel megadva	102
48. ábra – a) Sentinel-2 műholdképosztályozási algoritmusainak pontossági %-a a drónkép osztályozási eredményét referenciaként használva; b) Sentinel-2 műholdkép osztályozási algoritmusainak pontossága Kappa indexsel kifejezve, a drónkép osztályozási eredményét referenciaként használva	103
49. ábra - A Sentinel-2 műholdkép és a drónfelvétel osztályozott eredményeinek hibamátrix eredményének újraosztályozott képei, melyen fehér szín jelzi az egyezően osztályozott pixeleket, míg feketével az eltéréseket: a) legnagyobb hasonlóság algoritmus mellett; b) spektrális szög algoritmus esetén 6 osztály mellett; c) legkisebb távolság algoritmus eredményei; d) spektrális szög algoritmusának eredményei 4 osztály esetén)	104
50. ábra - Micasense Altum Tisza tavi felmérésének klaszterezés módszerével kapott osztályozási eredményei; a) legkisebb távolság algoritmus mellett kapott eredmény; b) spektrális szög algoritmus mellett kapott eredmény	106
51. ábra - Micasense Altum Tisza tavi felmérésének a) Random Forest osztályozással lefuttatott eredményei; b) a modell konfidencia eredményei	106

52. ábra - Micasense Altum Tisza tavi felmérésének 'legnagyobb hasonlóság' algoritmusával végzett ellenőrzött osztályozási eredménye: a) 6 osztállyal; b) 4 osztállyal	107
53. ábra - Micasense Altum Tisza tavi felmérésének 'legkisebb távolság' algoritmusával végzett ellenőrzött osztályozási eredménye: a) 6 osztállyal; b) 4 osztállyal	107
54. ábra - Micasense Altum Tisza tavi felmérésének 'spektrális szögtávolság' algoritmusával végzett ellenőrzött osztályozási eredménye: a) 6 osztállyal; b) 4 osztállyal	107
55. ábra - A teljes referenciaterülettel vizsgált helyes, illetve helytelen pixelek területi összegének m ² -ben vizsgált eredményei	108
56. ábra - A 3 eltérő ellenőrzött osztályozási algoritmus eredményeinek területalapú összevetése és adatainak szórása (balra 6 osztállyal, jobbra 4 osztállyal)	108
57. ábra - Eltérő ellenőrzött osztályozási algoritmusok 6 osztállyal futtatott eredményeinek pontosság vizsgálatának eredményei; a) Az osztályozó algoritmusok pontossági %-a osztályok szerint bontásban, illetve a teljes modellre vizsgálva; b) az osztályozó algoritmusok Kappa-index eredményei az osztályok és a teljes modell esetén	109
58. ábra - Eltérő ellenőrzött osztályozási algoritmusok 4 osztállyal futtatott pontosság vizsgálatának eredményei; a) Az osztályozó algoritmusok pontossági %-a az osztályok szerint bontásban, illetve a teljes modellre vizsgálva; b) az osztályozó algoritmusok Kappa-index eredményei az osztályok és a teljes modell esetén	110
59. ábra - A PCA-elemzés eredményeinek képei: (a) PCA 1.szint. (b) PCA 2.szint. (c) PCA 3.szint. (d) PCA 4.szint. (e) PCA 5.szint	111
60. ábra - a) A PCA-elemzés és a referenciaréteg általános pontossága (%); b) A PCA-elemzés és a referenciaréteg Kappa-indexének eredményei	111
61. ábra - a) A PCA és az UAV "eredeti" osztályozásának általános pontossága %; b) A PCA és az UAV "eredeti" osztályozásának Kappa indexei	112
62. ábra - Egyedi döntési szabályrendszer mellett futtatott képosztályozás eredménye, a zöld pixelek jelzik a tündérrózsával borított felszínt	112
63. ábra - a) A tündérrózsára vonatkozó döntési fa pontossági értékelésének (%) eredményei; b) A tündérrózsára vonatkozó döntési szabályok Kappa indexének eredményei	113
64. ábra - QGIS által kalkulált spektrumkép: a) Sentinel-2 műholdkép spektrumképe, b) a Micasense Altum 5 optikai csatornájának spektruma)	114
65. ábra – A spektrális adatok osztályokra jellemző adatgyűjtési eredményeinek szórása	114
66. ábra - Az osztályok spektrális adatainak átlagértéke a drón Micasense Altum, illetve a Sentinel-2 műholdkép alapján	115
67. ábra - 150 db vektoros pont által gyűjtött spektrális átlagok osztályok szerinti bontásban	115
68. ábra - 150 pont spektrális adatgyűjtési eredményének szórása	115

69. ábra - Fényparaméterek leírását segítő modell logikai felépítés	145
70. ábra - A spektrális adatokból kiinduló fénytani paraméterek vezérlőtáblájának képei: a) – b) a modell felépítése, a különböző szenzorok és fizikai átváltások beépítésével; c) az aktuális mérési adatok kalkulált eredménytáblájának képe	147
71. ábra - Spektrális indexek és a beltartalmi paraméterekkel szembeni korrelációjukat megadó számolótábla képei	152
72. ábra – Saláták (<i>Lactuca sativa</i> L.) reflektanciagörbéi (mérés ideje: 2018.08.08.)	152
73. ábra - 2 növényfaj eltérő tápanyagutánpótlás mellett mért spektrális reflektancia értékeinek elsőrendű derivált függvényei	153
74. ábra - Drónképek feldolgozásának és osztályozásának munkamenetének sémája	154

M3 melléklet: Táblázatok jegyzéke

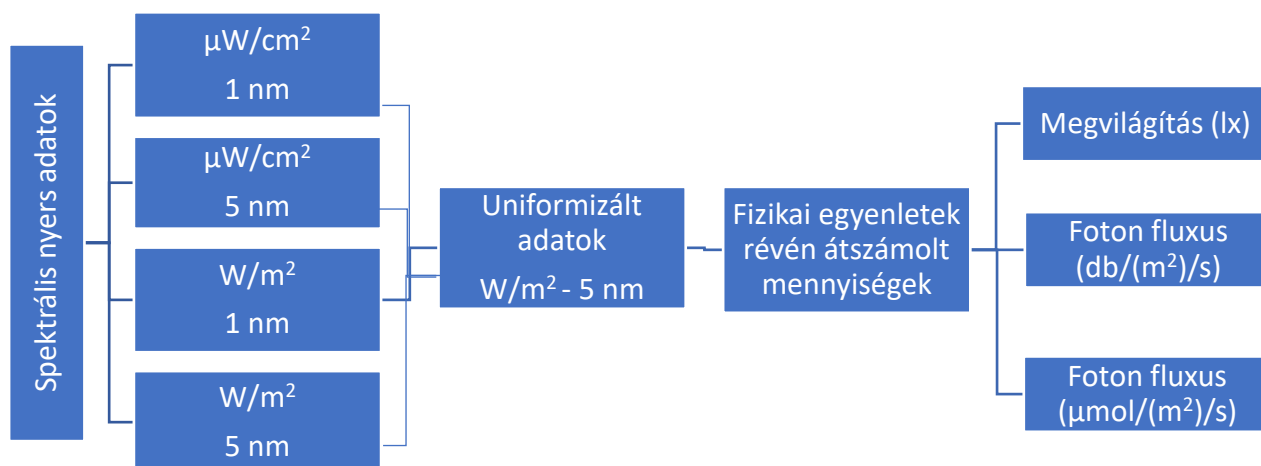
1. táblázat - A rövidhullámú reflektancia spektrum fősztása Kumar, et al. (2001) nyomán	9
2. táblázat - A legfontosabb növényi fotoreceptor csoportok tulajdonságai a magasabb rendű növényeknél (Forrás: Weller, 2017)	17
3. táblázat - Különböző fényforrások összehasonlító mérései alapján használt szorzótényező Forrás: Osram	31
4. táblázat - A kék/vörös (440/690), kék/távoli vörös (440/740), vörös/távoli vörös (690/740) és kék/zöld (440/520) arányok, mint stressz indikátorok mértékének változásai különböző stresszorok hatására a kezeletlen növényhez képest. ++ = jelentősen magasabb, + = magasabb, – – = jelentősen alacsonyabb, – = alacsonyabb, 0 = nincs szignifikáns változás (Forrás: Buschmann et al., (2000) nyomán, kiegészítve Szigeti et al., (2008))	38
5. táblázat - ASD Fieldspec Handheld 2 és a Qmini spektrométerek műszaki adatainak összehasonlítása	59
6. táblázat - ASD Fieldspec 2 és Qmini méréseinek REP-re vonatkozó összehasonlítása	78
7. táblázat - HPS és LED rendszer összesített adatai a rendszer megtérülés szempontjából	79
8. táblázat - HPS és LED rendszer összesített adatai a rendszer megtérülés szempontjából (2022-es adatokkal frissítve)	80
9. táblázat - KIND K5 területi megvilágításának statisztikai összefoglaló táblázata	81
10. táblázat - Klorofill indexek klipsszel mért értékeinek, illetve a SPAD méter adatainak kétmintás t-próbával történő statisztikai összevetése a laboreredményekkel (kivonat a korrelációs és varianciára vonatkozó eredményekre)	84
11. táblázat – A jobb korrelációs eredményeket mutató vízindexek R-értékeinek összefoglaló táblázata	86

12. táblázat - Elsőrendű deriváltból képzett indexek legmagasabb R értékű eredményeinek összefoglalója	86
13. táblázat - Nitrogén és egyéb beltartalmi paraméterek laboreredményeinek alap statisztikai értékeinek összefoglalása	87
14. táblázat - Kálium tartalom becslésére alkalmazott spektrális értékek legjobb eredményei a korreláció szempontjából	89
15. táblázat- PLS-DA modellek kálium tartalom becslési pontossága a reflektancia értékek alapján	90
16. táblázat - Sequoia kamera több időpontban történő felvételeinek csatornánkénti maximális varianciája	92
17. táblázat - Sequoia kamera NIR-csatornában mért reflektancia értékeinek minimumát, maximumát, átlagát és varianciáját jellemző értékek	93
18. táblázat - Képosztályozási algoritmusok futtatási és pontossági eredményeit összefoglaló táblázat	105
19. táblázat - Fontosabb vegetációs indexek (Adatainak forrása: Index Database)	148
20. táblázat - A vizsgálatokba bevont vízindexek matematikai formulája	148
21. táblázat - A nitrogén tartalom szempontjából ajánlott spektrális indexek	149
22. táblázat - Micasense Altum Tisza tavi felmérésének 'legnagyobb hasonlóság' algoritmusával végzett ellenőrzött osztályozási eredményének összefoglaló táblázata 6 osztály esetén	154
23. táblázat - Micasense Altum Tisza tavi felmérésének 'legkisebb távolság' algoritmusával végzett ellenőrzött osztályozási eredményének összefoglaló adatai	155
24. táblázat - Micasense Altum Tisza tavi felmérésének 'spektrális szögtávolság' algoritmusával végzett ellenőrzött osztályozási eredményeinek összefoglaló adatai	155
25. táblázat - Spektrális távolság függvények sulyom és nád osztályra vonatkozó eredményeit összefoglaló táblázat	155

CD melléklet: A mérőfej reprodukálható modellje, a 2 vezérlőtábla, illetve a 'Raster Calculator'-t kiegészítő *JavaScript* kód az alábbi linken elérhető bárki számára:
https://drive.google.com/drive/folders/1DuYy_X1CSGoT0tMv85gKHQ9iH0XRmjIw?usp=share_link/

M4 melléklet: Fénytani vezérlőtábla felépítése

A vezérlőtábla kialakításának logikai felépítését az alábbi ábrán foglalom össze.



69. ábra - Fényparaméterek leírását segítő modell logikai felépítés

A modelltablát követő dinamikus munkalapján létrehoztam egy bármely mérés esetén automatán működő felhasználói felületet. Ennek első lépésekor be tudjuk tölteni saját mért adatainkat. Ezen belül hat opciónk lehetséges a felületen. Tapasztalatom szerint a legtöbb spektroradiométer két nagyságrendben mér: W/m^2 -ben, illetve $\mu W/cm^2$ -ben. Spektrális felbontásukban pedig 1 nm-es, 5 nm-es, avagy ezektől eltérő felbontás lehetséges, gyártótól függően. Így ezen opciók szerint tudjuk betölteni a modellbe saját adatainkat.

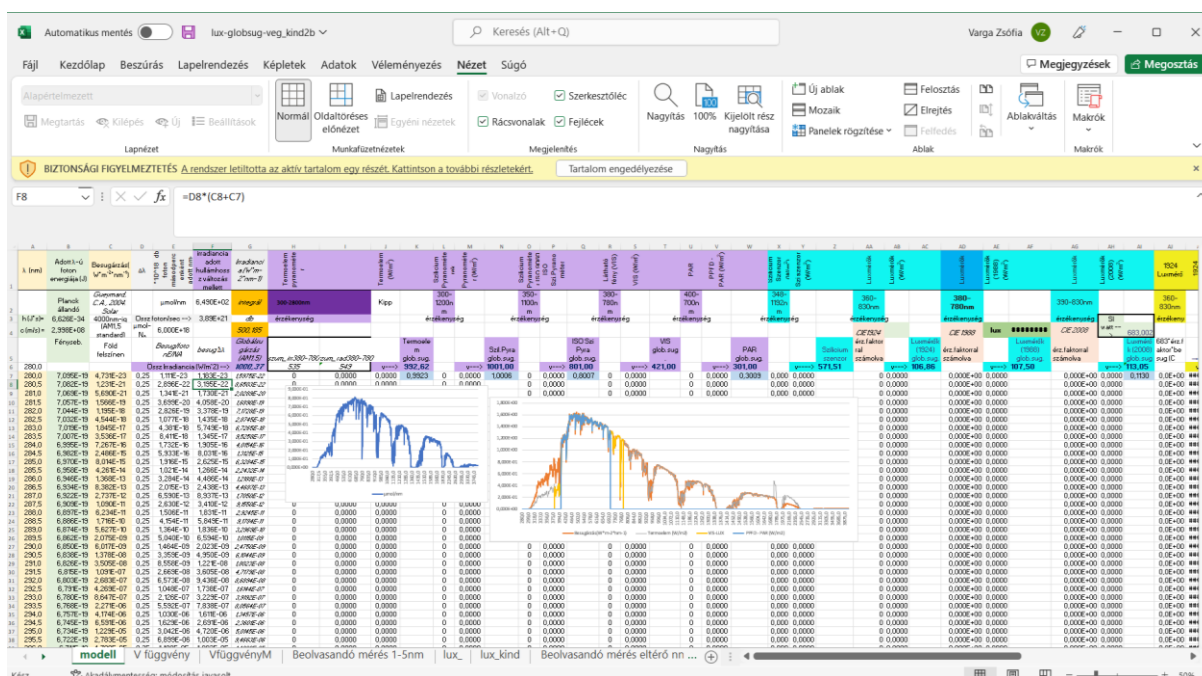
A következő lépésben a modell a háttérben kialakít egy mindig egységes adattáblát, melyhez az 5 nm-es felbontású W/m^2 mértékegységű adatokat választottam, és ezen adattáblát fogja továbbvinni a számolófelület felé. Így a képletek hiba és torzítás nélkül működni tudnak. Amiatt döntöttem ezen felbontás mellett, szemben az 1 nm-es felbontással, mivel a számolókapacitás-igényeit és a méretet is csökkenti. Ezen szempont a mikroszámítógépek szempontjából tűnt fontosnak (például egy vezérlő automatika céljából).

Ahhoz, hogy a számolófelület hiba nélkül tudjon „dönteni”, ehhez egy legördülő menüben bekéri a program a mértékegységet, illetve a felbontást. Ez amiatt volt fontos, hogy egyértelműen tudja kezelni a korábbi nyers adataink többféle opcióját, bár a háttér függvényeket igyekeztem úgy kialakítani, hogy ettől függetlenül is „megtalálja” és megfelelően ki tudja alakítani az egységes adattáblát. Amennyiben eltérő felbontásunk volt, úgy egy külön munkalapon tudjuk ezt behívni. Itt kialakítottam egy interpolációt, illetve olyan keresőfüggvényeket, melyek révén szintén az egységes adattáblába tudja hívni a rendszer az adatokat. Amennyiben 0,3 nm-en belül talál mért értéket a teljes adattáblába, úgy ezen adatokkal tölti fel, amennyiben nem, úgy az interpoláció révén tölti fel az egységes adattáblát. A számolófelületen egyéb dolgunk már nincsen. A modell megadja számunkra a 380-780 nm -es tartományra vonatkozó megvilágítási értéket luxban, a besugárzást, a fotonfluxust fotonszámban, illetve $\mu mol/s$ -ban, illetve a PAR tartományra vonatkozó fotonfluxus értékeit is. A PAR fotonfluxust korrekció

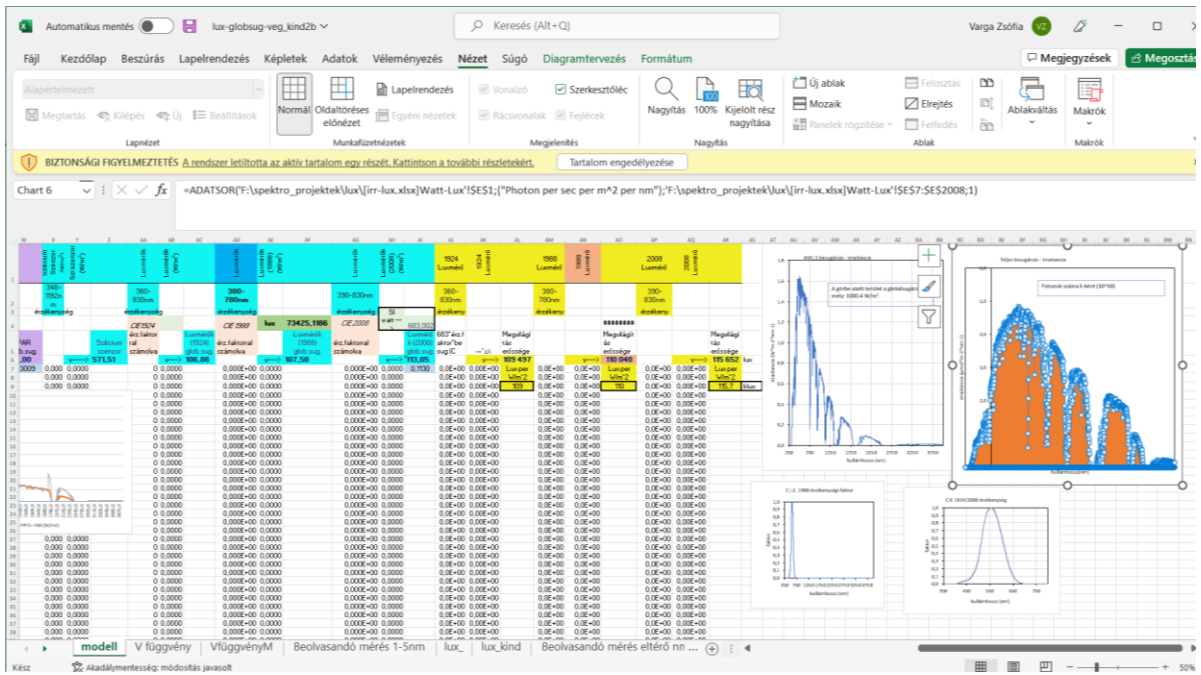
nélkül, és a $V(\lambda)$ függvénnyel korrigálva is megadtam, mivel márkafüggően adott PAR-PPF mérők is így alkalmazzák (és adott referencia értékek is lehet ezen megközelítésben határozták meg). Mivel a PPF értéke itt nehezen kezelhető (függ a távolságtól), ezért a PPF tizes alapú logaritmusát számolja ki a program, mely a statisztikai elemzések révén a legközelebb áll. A végeredmények mellett diagramon ábrázolja a sugárzást (W/m^2 -ben), illetve a fotonfluxust. Mindez egyszerűen kezelhető, és fizikai alapon ad „átjárhatóságot” a fénytani mértékegységek között, nem függ azok eltérő mérőrendszerének detektorától, megközelítésétől.

Egy külön részben pedig, amennyiben megadjuk fényforrásunk teljesítmény adatait, illetve a fogyasztási díjszabást, megadja a fényforrás fotonhatékonyságát $\mu mol/J$, illetve $\mu mol/Ft$ -ban.

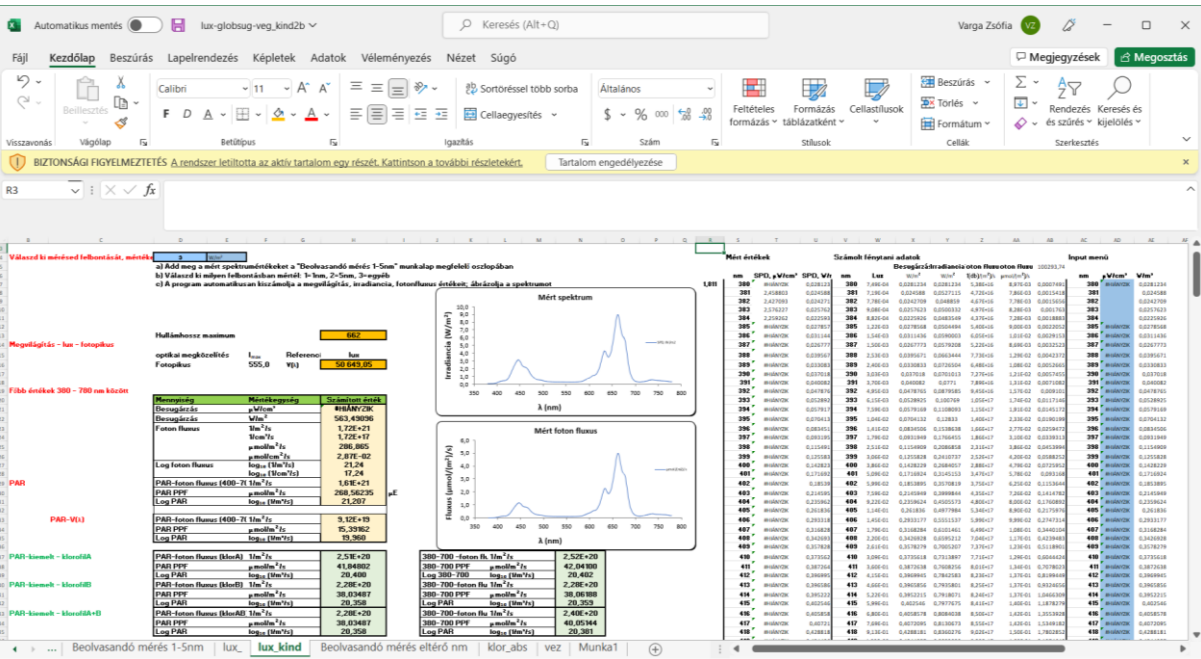
Az első és második kép a modell tábla felépítése eltérő szenzorok érzékenységeinek átszámolására, 3. kép adott fényforrások méréseinek automata kiszámoló táblája, mely megadja az irradiancia, lux, PPF és egy logaritmikusan becsült PPF értéket



(a)



(b)



(c)

70. ábra - A spektrális adatokból kiinduló fénytani paraméterek vezérlőtáblájának képei: a) – b) a modell felépítése, a különböző szenzorok és fizikai átváltások beépítésével; c) az aktuális mérési adatok kalkulált eredménytáblájának képe

M5 melléklet: A vizsgálatokba bevont spektrális indexek matematikai formulái

19. táblázat - Fontosabb vegetációs indexek (Adatainak forrása: Index Database)

Index neve	Matematikai formulája	Kidolgozója	Leírása
VI _{Green} – Green Vegetation Index	$VI_{Green} = \frac{(Green - Red)}{(Green + Red)}$	de Beurs & Henebry (2005)	Dimenzió nélküli szám, mely RGB kamerával is elkészíthető. Minél „zöldebb” a kép annál magasabb lesz az index értéke.
DVI - Difference vegetation index	$DVI = NIR - RED$	Jordan (1969)	Zéró érték esetén csak talajfelszín jelez, negatív értéke vizet, pozitívnál növényzetet
RVI - Ratio vegetation index	$RVI = NIR / RED$	Pearson & Miller (1972)	A domborzati hatások minimalizálására dolgozták ki
NDVI - Normalized vegetation index	$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$	Rouse et al. (1974)	Minimalizálja a domborzati hatásokat és lineáris léptékben ábrázolhatóvá teszi a növényzet mértékét
SAVI - Soil adjust vegetation index	$SAVI = \frac{(NIR - Red)}{(NIR + Red + 0,5)} \times 1,5$	Huete (1988)	Csökkenti a talaj háttér hatásait a mért adatokban, így javítva a növényzet vizsgálatát
TVI - Transformed vegetation index	$TVI = \sqrt{NDVI} + 0,5$	Deering et al. (1975)	A 0,5 érték kiküszöböli a negatív NDVI értéket
NDWI - Normalized difference water index	$NDWI = \frac{(NIR - SWIR)}{(NIR + SWIR)}$	Gao (1996)	Az NDVI nagyon érzékeny az atmoszféra víztartalmára, míg az NDWI-t kevésbé befolyásolja ennek hatása

20. táblázat - A vizsgálatokba bevont vízindexek matematikai formulája

Vízindex	Angol/magyar neve	Formulája
WBI	Water Band Index Víz spektrális sávok indexe	$\frac{\rho_{970}}{\rho_{900}}$
SRWI	Simple Ration Water Index Egyszerű hányados víz index	$\frac{\rho_{860}}{\rho_{1240}}$
WI	Water index	$\frac{\rho_{900}}{\rho_{970}}$

	vízindex	
WI _{corrected}	Korrigált vízindex	WI/NDVI
NDWI	Normalized Difference Water Index Normalizált vízindex	$\frac{\rho_{857} - \rho_{1241}}{\rho_{857} + \rho_{1241}}$
NDII	Normalized Difference Infrared Index Normalizált infravörös index	$\frac{\rho_{819} - \rho_{1649}}{\rho_{819} + \rho_{1649}}$
MSI	Moisture Stress Index Nedvességtartalom stressz indexe	$\frac{\rho_{1599}}{\rho_{819}}$
NDMI	Normalized Difference Moisture Index Normalizált nedvesség index	$\frac{\rho_{820} - \rho_{1600}}{\rho_{820} + \rho_{1600}}$
LVI2	Lake Vegetation Index Tavak vegetációs indexe	$\frac{\rho_{1094} - \rho_{1205}}{\rho_{1094} + \rho_{1205}}$
DSWI_5	Disease Stress Water Index Betegség stressz vízindexe	$\frac{\rho_{800} - \rho_{5500}}{\rho_{1660} + \rho_{680}}$
NMDI	Normalized Multi-band Drought Index Többcsatornás normalizált aszály index	$\frac{\rho_{860} - (\rho_{1640} - \rho_{2130})}{\rho_{860} + (\rho_{1640} - \rho_{2130})}$

21. táblázat - A nitrogén tartalom szempontjából ajánlott spektrális indexek

Spektrális index	Index angol neve	Formula	Hivatkozás
NDVI ₇₅₀₋₇₀₅	Normalized Difference Vegetation Index	$NDVI = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}}$	Gitelson and Merzlyak (1998)
NDVI ₈₀₀₋₆₈₀		$NDVI = \frac{\rho_{800} - \rho_{680}}{\rho_{800} + \rho_{680}}$	Peñuelas et al. (1997b); Rouse et al. (1973)
CRI ₅₅₀	Carotenoid Reflectance Index	$CRI = \frac{1}{\rho_{510}} - \frac{1}{\rho_{550}}$	Gitelson et al. (2002)
SIPI	Structure Intensive Pigment Index	$SIPI = \frac{\rho_{800} - \rho_{445}}{\rho_{800} + \rho_{445}}$	Peñuelas et al. (1995)
REIP	RedEdge Inflection Point	$R / (NIR + R + G)$ vagy $700 + 40 * [(\rho_{667} - \rho_{782}) / 2 - \rho_{702}] / (\rho_{738} + \rho_{702})$	Sripada et al. (2005)

RedEdge Ratio Index		(ρ_{760}/ρ_{730})	Erdle et al. (2011)
N_870-1450		$N_{870_1450} = \frac{\rho_{870} - \rho_{1450}}{\rho_{870} + \rho_{1450}}$	Pimstein et al. (2011)
N_1645-1715		$N_{1645_1715} = \frac{\rho_{1645} - \rho_{1715}}{\rho_{1645} + \rho_{1715}}$	Pimstein et al. (2011)
MSAVI2	Modified SAVI	$0,5 * [2 * (NIR + 1) - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - R)}]$	Qi et al. (1994)
OSAVI	Optimized soil-adjusted vegetation index	$(NIR - R) / (NIR + R + 0,16)$	Rondeaux et al. (1996)
SAVI	Soil-adjusted vegetation index	$1,5 * [(NIR - R) / (NIR + R + 0,5)]$	Huete (1988)
Yara N sensor ALS		$\rho_{730}, \rho_{760}, \rho_{900}, \rho_{970}$	Link and Reusch (2006)
CropSpec		ρ_{730}, ρ_{805}	Reusch et al. (2010)
GreenSeeker		ρ_{650}, ρ_{770}	Solie et al. (1996)

M6 melléklet: Spektrális indexek és a beltartalmi paraméterekkel szembeni korrelációjukat megadó számolótábla felépítése

Az első két munkalap ad helyet a nyers spektrális, illetve beltartalmi értékek beolvasására. A spektrális adatokból egy háttértáblára automatán létrehoz keresési, illetve interpolációs eljárással egy standardizált, 1 nm-es felbontású spektrális állományt. Ezután elvégzi az elsőrendű deriválást egy következő munkalagra, majd az itt látható első három kép munkalapján megadja a fontosabb spektrális indexeket (a nevesített indexek mellett egyéb normalizált, és SR ráció szerinti párokat is megadva). Ezen indexeket az elsőrendű derivált adataiból is kiszámolja egy következő munkalapon. A spektrális indexek mellett külön megadja az egyes RGB régiók maximális és minimális értékét, illetve megkeresi a 680-800 nm közötti tartomány maximum és minimum értékeit, megadja ezen két pont közötti egyenes meredekségét és inflexiós pontját.


A beltartalmi paraméterek megadására a klorofill-, nitrogén-, és kálium tartalom, a relatív víztartalom, a LAI érték, illetve további beltartalmi paraméterek adhatóak meg két oszlopban, %-ban illetve pontos koncentrációban. Majd két korrelációs táblán (egyik a standard mérések, míg másik az elsőrendű derivált eredményeit) összeveti az összes index és spektrális tartományt jellemző statisztikai értékeket a beltartalmi mérések eredményeivel, automatikusan színezve az 50% feletti korrelációs eredményeket zöldre, a 40-50% közöttieket kékre, míg a 60% felettieket sötétzöldre, ezzel gyorsabban láthatóvá teszi a jobb eredménnyel bíró összefüggéseket.

index	Crededge	NDVI	MTCI	MTC2	MCARI	MCARI2	NDMI	NDWI_a	NDWI_b	NDWIz	CRI	WI	N_WI	MSI	DSWI	DSWI2	DSWI5	LV11	11_kerekít	LV2			
beltart																							
C_száraza.%	0,1192825	0,33672	0,208127	0,37242	0,102576	0,140105	0,165828	-0,14891	-0,19336	-0,11236	-0,19793	-0,18379	0,328343	0,209361	0,209718	0,187297	0,221349	0,384375	0,2344	-0,06337	-0,06159	-0,220	
N_száraza.%	0,5129842	0,515293	0,56381	0,52396	0,49724	0,503075	0,530523	-0,48956	-0,14613	-0,15154	-0,13941	-0,55616	0,571574	0,308617	0,308361	0,148362	0,547481	0,515982	0,561015	-0,00246	-9,3E-05	-0,153	
C_N	0,2418196	0,235145	0,261746	0,280548	0,235735	0,216361	0,234902	-0,23613	0,128483	0,116985	0,13251	-0,23424	0,277058	0,003122	0,003141	-0,12763	0,147942	0,202082	0,204169	-0,15073	-0,15163	0,1054	
N_g/m ²	0,6015081	0,297873	0,574082	0,287925	0,606329	0,589713	0,587438	-0,58157	0,127831	-0,06051	0,134712	-0,53371	0,337643	0,122922	0,122933	-0,12837	0,453064	0,197165	0,461227	0,159552	0,155852	0,1236	
N%																							
nitrat_nmol	0,2307637	0,200924	0,242262	0,233311	0,224082	0,202906	0,223372	-0,21413	0,085693	0,029657	0,088704	-0,22315	0,219018	-0,01157	-0,0119	-0,08535	0,169893	0,181121	0,196223	0,014075	0,013727	0,1056	
K%																							
P																							
Klorofil (a+b)																							
LAI_g/m ²	0,1285522	-0,23008	0,052196	-0,25436	0,152957	0,123619	0,090354	-0,15827	0,348299	0,116969	0,348824	-0,00937	-0,24764	-0,22731	-0,22715	-0,34903	-0,09623	-0,35604	-0,08919	0,201249	0,195624	0,3555	
RWE%																							
H ₂ O_g/m ²	0,194268	-0,1464	0,154309	-0,19798	0,217128	0,18879	0,159911	-0,27315	0,656383	0,463767	0,660295	-0,09385	-0,18463	-0,50823	-0,50842	-0,65021	-0,11775	-0,37942	-0,08122	-0,07357	-0,0817	0,659	
szárazta_mg	0,1363573	0,0737	0,129559	0,087085	0,133202	0,118357	0,130632	-0,12589	-0,03297	-0,07079	-0,03097	-0,11907	0,10817	0,058086	0,058244	0,026128	0,116356	0,103152	-0,11971	0,061148	0,064071	-0,030	
feherje_g/mg	0,453704	0,483599	0,52545	0,477251	0,441072	0,460198	0,480648	-0,47612	-0,08043	-0,06871	-0,07538	-0,50192	0,506955	0,206001	0,205932	0,082666	0,467146	0,436058	0,497043	-0,04834	-0,04772	-0,092	
keményítő_nm	-0,045836	0,0222	-0,07097	0,067385	-0,05772	-0,07355	-0,04872	0,170453	-0,1421	-0,14075	-0,1428	0,033208	0,043428	0,029209	0,029103	0,141116	0,053872	0,130091	0,006386	0,100403	0,099115	-0,114	
glukoz_nmol/l	-0,213353	-0,04017	-0,12972	-0,01903	-0,2136	-0,18549	-0,18474	0,079519	0,022378	-0,01719	0,013694	0,130038	-0,05716	-0,10528	-0,10514	-0,02429	-0,16381	-0,0378	-0,11452	0,09434	0,095666	0,0123	

71. ábra -Spektrális indexek és a beltartalmi paraméterekkel szembeni korrelációjukat megadó számológépi táblázat képe


M7 melléklet: Spektrális reflektancia mérési minták

Saláta (*Lactuca sativa* L.) reflektancia méréseinek eredményeit mutatja be az alábbi ábra.



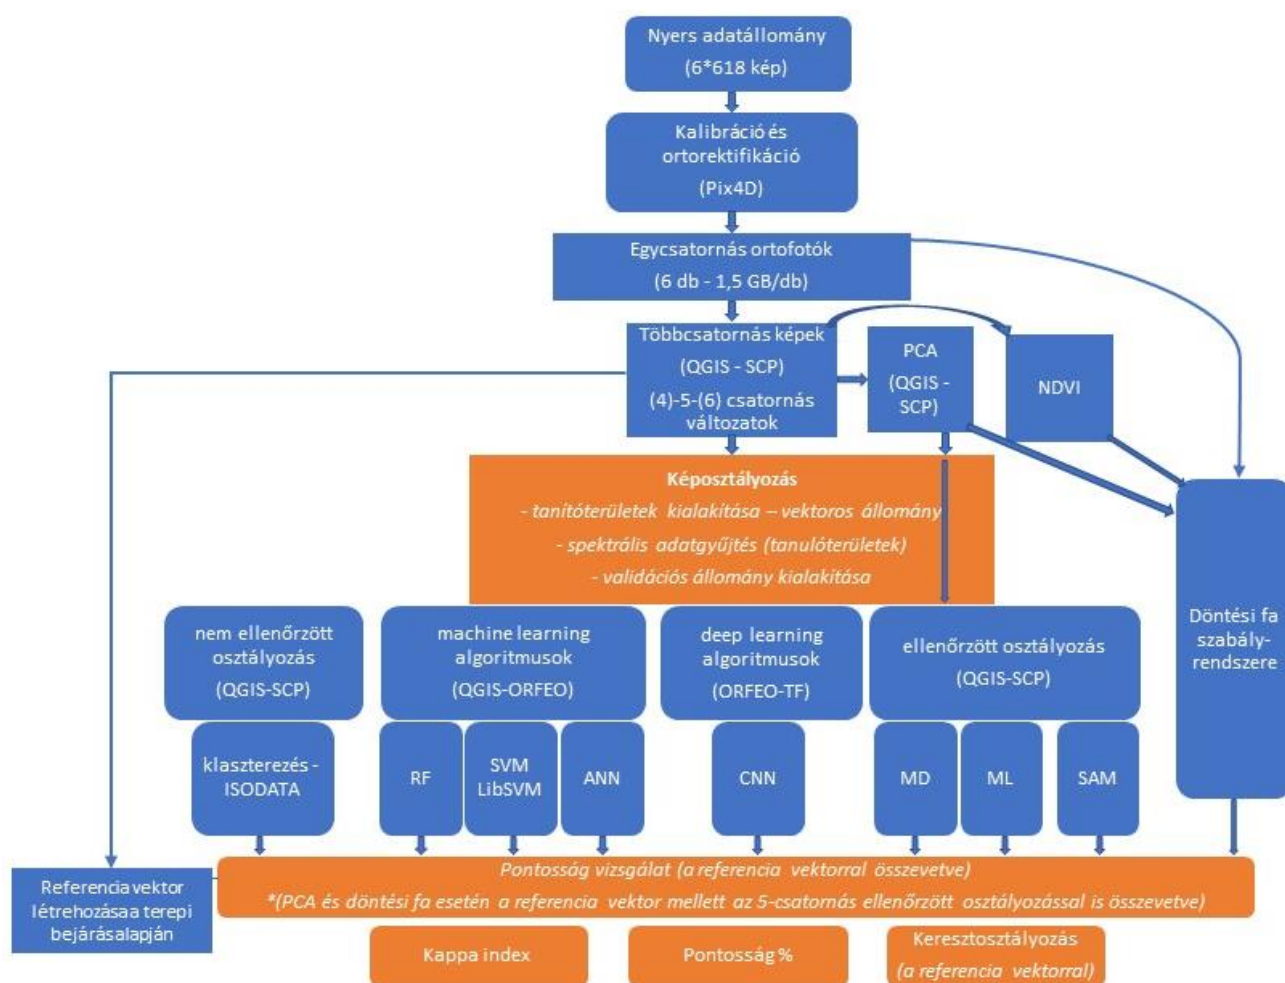
72. ábra – Saláták (*Lactuca sativa* L.) reflektanciagörbéi (mérés ideje: 2018.08.08.)

A nitrogén kezelések spektrális mért eredményeinek elsőrendű derivált függvényét az alábbi ábrán láthatjuk.



73. ábra - 2 növényfaj eltérő tápanyagutánpótlás mellett mért spektrális reflektancia értékeinek elsőrendű derivált függvényei

M8 melléklet: A drónon alkalmazott multispektrális kamerájának feldolgoási munkamenete



74. ábra - Drónképek feldolgozásának és osztályozásának munkamenetének sémája

M9 melléklet: Ellenőrzött osztályozási algoritmusok 6 osztályos területi eredményeinek összefoglaló táblázata

22. táblázat - Micasense Altum Tisza tavi felmérésének 'legnagyobb hasonlóság' algoritmusával végzett ellenőrzött osztályozási eredményének összefoglaló táblázata 6 osztály esetén

legnagyobb hasonlóság	Osztály	Pixelek száma	%	Terület [m ²]
	1 - sulyom	194 931 057	39,2741	100 269,1049
	2 - nád	67 700 868	13,6401	34 824,1350
	3 - gyékény	110 653 171	22,2940	56 918,0437
	4 - víz	35 534 320	7,1593	18 278,2288
	5 - tündér	76 544 943	15,4220	39 373,3715
	6 - sás	10 970 969	2,2104	5 643,2734

23. táblázat - Micasense Altum Tisza tavi felmérésének 'legkisebb távolság' algoritmusával végzett ellenőrzött osztályozási eredményének összefoglaló adatai

legkisebb távolság	Osztály	Pixelek száma	%	Terület [m ²]
	1 - sulyom	145 774 236	23,81	74 983,701
	2 - nád	27 326 403	4,464	14 056,22
	3 - gyékény	125 763 360	20,544	64 690,46
	4 - víz	74 541 038	12,177	38 342,598
	5 - tündér	112 407 349	18,36	57 820,362
	6 - sás	10 522 942	1,719	5 412,816

24. táblázat - Micasense Altum Tisza tavi felmérésének 'spektrális szögtávolság' algoritmusával végzett ellenőrzött osztályozási eredményeinek összefoglaló adatai

spektrális szög függvénye	Osztály	Pixelek száma	%	Terület [m ²]
	1 - sulyom	263 806 129	53,1508	135 697,2298
	2 - nád	61 450 092	12,3808	31 608,8458
	3 - gyékény	76 508 110	15,4146	39 354,4252
	4 - víz	36 427 440	7,3393	18 737,6340
	5 - tündér	43 516 825	8,7676	22 384,2889
	6 - sás	14 626 732	2,9469	7 523,7335

M10 melléklet: Micasense Altum Tisza tavi felmérésének 6 osztályának spektrális adatainak spektrális távolság függvényeinek eredményei

A spektrális távolság függvények eredményeiből a sulyom, illetve nádra vonatkozó eredményeket foglaltam össze az alábbi táblázatban.

25. táblázat - Spektrális távolság függvények sulyom és nád osztályra vonatkozó eredményeit összefoglaló táblázat

Spektrális távolság függvények	Összehasonlított osztályok				
	MC_ID = 1 MC_n = sulyom	MC_ID = 1 MC_n = sulyom	MC_ID = 1 MC_n = sulyom	MC_ID = 1 MC_n = sulyom	MC_ID = 1 MC_n = sulyom
	MC_ID = 2 MC_n = nad	MC_ID = 3 MC_n = gyekeny	MC_ID = 4 MC_n = viz	MC_ID = 5 MC_n = tunder	MC_ID = 6 MC_n = sas
Jeffries-Matusita függvény	1,984	1,998	1,999	1,757	1,997
Spektrális szög	14,019	8,239	42,060	6,043	11,659
Euklideszi távolság	0,326	0,387	0,726	0,163	0,318
Bray-Curtis hasonlóság [%]	75,887	66,077	7,13	90,88	76,575
		MC_ID = 2 MC_n = nad C	MC_ID = 2 MC_n = nad	MC_ID = 2 MC_n = nad	MC_ID = 2 MC_n = nad
		MC_ID = 3 MC_n = gyekeny	MC_ID = 4 MC_n = viz	MC_ID = 5 MC_n = tunder	MC_ID = 6 MC_n = sas
Jeffries-Matusita függvény		1,662	1,998	1,737	1,155
Spektrális szög		19,0386	51,066	10,922	7,29
Euklideszi távolság		0,1593	0,436	0,177	0,057
Bray-Curtis hasonlóság [%]		85,233	11,403	84,675	92,582

M11 melléklet: Kódrészletek melléklete

Micasence kamera spektrális adatainak *QGIS SCP* pluginba történő integrációjához szükséges kódrészletek:

- `BandsetTab.py` kódrészlete (90.sortól)

```
# set satellite wavelengths

def setSatelliteWavelength(self, satelliteName = None, bandList = None, bandSetNumber
    = None):
    if satelliteName is None:
        satelliteName = cfg.ui.wavelength_sat_combo.currentText()
    if bandSetNumber is None:
        bandSetNumber = cfg.ui.Band_set_tabWidget.currentIndex()
    tW = eval('cfg.ui.tableWidget__' + cfg.bndSetTabList[bandSetNumber])
    c = tW.rowCount()
    wl = []
    tW.blockSignals(True)
    id = cfg.ui.unit_combo.findText(cfg.noUnit)
    if satelliteName == cfg.NoSatellite:
        for x in range(0, c):
            wl.append(x + 1)
            id = cfg.ui.unit_combo.findText(cfg.noUnit)

# Micasence

elif satelliteName == cfg.satMicasense:
    wl = [0.475, 0.56, 0.668, 0.717, 0.842]
    id = cfg.ui.unit_combo.findText(cfg.wlMicro)
    bl = ['01', '02', '03', '04', '05']
```

- `config.py` kódrészlete

```
''' band set '''

# list of satellites for wavelength

NoSatellite = 'Band order'

satMicasense = Micasense [bands 1, 2, 3, 4, 5]

satGeoEye1 = 'GeoEye-1 [bands 1, 2, 3, 4]'
```

8 KÖSZÖNETNYILVÁNÍTÁS

Szeretnék köszönetet mondani témavezetőmnek, Dr, Jung Andrásnak a türelméért, a szakmai meglátásaiért, és szakmai segítségeiért, mellyel előremozdított, támogatott, és mögöttem állt, amikor elakadtam,

Köszönöm Dr, Láng Zoltánnak, hogy elindított ezen az úton,

Köszönöm a MATE, Budai Campusán dolgozó kollégáim, különösen a Zöldség Tanszék és az Érzékszervi Labor munkatársainak segítségét és a biztosított eszközöket (mérőműszerek (például SPAD mérő) és a laborméréseket, a KIND K5 szabályozható LED lámpát), illetve a kertészeti növényigényekkel kapcsolatos tanácsaikat,

Köszönöm az ELTE IK, Geoinformatikai Intézet munkatársainak, különösen Vörös Fanninak, Pál Mártonnak és Dr, Kovács Bélának, hogy az Intézet által végzett UAV lerepülések adatainak feldolgozásába bekapcsolódhattam

Köszönöm a Tisza tavi Sporthorgászati Egyesület munkatársainak, hogy engedélyezték a terület felmérését, az adatok felhasználását, illetve a referencia növényborítás létrehozását szakmai tapasztalataikkal segítették

Köszönöm a NAIK MGI munkatársainak és szervezett rendezvényeinek mind a LED rendszerekkel, mind a drónok használatával kapcsolatos tapasztalatait,

Köszönöm a Tungsram Agritech munkatársainak, hogy munkám során biztosították számomra a Research Modul LED rendszert,

Köszönöm Dr, Kovács Attilának a növényi beltartalmi analitikai mérésekben nyújtott segítségét és a laborhasználat lehetőségét,

És köszönöm két gyermekem türelmét, mellyel segítették ezen munka létrejöttét,