

Drónfelvételek alkalmazása a növény- és természetvédelemben a környezeti hatások csökkentése érdekében

Szerzők: Dr. Biró Lóránt¹, Dr. Kozma-Bognár Veronika², Dr. Berke József³

DOI: [10.29180/978-615-6342-74-4_1](https://doi.org/10.29180/978-615-6342-74-4_1)

ABSZTRAKT

Napjaink robbanásszerű fejlődése a drónok alkalmazásában és az agráriumban olyan újfajta lehetőségeket kínál, melyek azelőtt elképzelhetetlenek voltak. A drónok alkalmazása a növényfelmérésben, növényvédelemben mindenképpen csökkenti a környezeti hatásokat a korábban alkalmazott módszerekhez képest. Egy kevésbé ismert módszertant mutatunk be a Kis-Balaton természetvédelmi vizsgálatának példáján: a drónok által készített, adott időbeli gyakoriságú (multitemporális) felvételeket nemcsak a változások detektálására lehet használni, hanem akár a feldolgozásuk során az osztályozási eljárások pontosításához is. Kutatásunk alapján kijelenthető, hogy multitemporális felvételeket alkalmazva, növényzeti monitoring vizsgálathoz az RGB szenzorok is alkalmasak, mégpedig a R sáv kiértékelésével megfelelő pontosság érhető el az osztályozás során.

Kulcsszavak: drón, multitemporális, multispektrális, növényvédelem, osztályozás

1. Bevezetés

Spektrális felbontás

A fény elektromágneses sugárzás, amely felbontható különböző hullámhosszúságú tartományokra. A VIS (Visible, vagyis a vörös [R], zöld [G], kék [B]) tartományban elsősorban a növényzetben található szintestek reflektálnak, vagyis ezzel a tartománnyal jól lehet vizsgálni a növényzet állapotát. A NIR (Near Infrared, vagyis a közeli infravörös) tartományt a mezőgazdaságban általában a növényzet fitsségi állapotának vizsgálata során használják fel, hasonlóan, mint a RedEdge sávot, viszont ez utóbbi nem érzékeny a légköri viszonyokra, a talaj reflektanciájára, viszont érzékeny a lombkorona jellemzőire és a klorofill-tartalomra (Clevers et al., 2001; Kozma-Bognár, 2012).

A spektrális vizsgálatok nem elhanyagolható kérdése, hogy a használt szenzor egyszerre hány csatornát, vagyis sávot tud rögzíteni egy időpillanatban. Ebből a szempontból megkülönböztetünk multi- és hiperspektrális felvételezést. A két módszer közötti különbség egyrészt az egyszerre rögzített sávok számában (multispektrális: 4-20 sáv, hiperspektrális: >20 sáv; Európai Unió Tanácsa, 2009), másrészt a sáv tartományok szélességében van különbség. A multispektrális módszernél a sáv szélességek általában nagyok (50-120 nm), míg a

¹ Budapesti Gazdasági Egyetem, Kereskedelmi, Vendéglátóipari és Idegenforgalmi Kar, biro.lorant@uni-bge.hu

² Gábor Dénes Egyetem, Dróntechnológia és Képfeldolgozás Tudományos Műhely, kozma.bognar.veronika@gde.hu,

³ Gábor Dénes Egyetem, Dróntechnológia és Képfeldolgozás Tudományos Műhely, berke.jozsef@gde.hu

hiperspektrális felvételezésnél ennél jóval kisebb, akár 1 nm is lehet (Kozma-Bognár, 2012). Ebből adódóan a felvételek spektrális felbontása is jóval nagyobb a hiperspektrális felvételek esetében, hiszen a spektrum folytonos, míg a multispektrális módszernél a kapott spektrum diszkrét sáv tartományokból áll.

Míg a műholdas távérzékelésben a hiperspektrális szenzorok alkalmazása általános (Bácsatyai & Márkus, 2001; Mucsi, 2013; Lillesand et al., 2015), addig a dróntechnológiában még nem elterjedt. Ez egyrészt a hiperspektrális kamerarendszerek magas költségének és nagy súlyának, másrészt a drónok által szállítható hasznos teher (payload) korlátozott méretének köszönhető. Ennek ellenére egyre több gyártó fejleszt ki UAV-ra (Unmanned Aerial Vehicle, vagyis „drón”) szerelhető egyre kisebb méretű és súlyú hiperspektrális kamerarendszert, köszönhetően a széleskörű alkalmazhatóságnak – és a műholdakkal összehasonlítva – költséghatékonyabb felhasználásnak (Adão et al., 2017; Nex et al., 2022). Ezzel szemben jelenleg számos gyártó jó minőségű multispektrális kamerarendszert gyárt kimondottan UAV-ra (pl. Micasense, Parrot, Sentra, Yusense), melyek általában 6 csatornát tartalmaznak: RGB mellett RedEdge (~717 nm) és NIR (~842 nm) sávot.

Az RGB és/vagy a RedEdge, valamint a NIR tartomány felhasználásával számos indexet hoztak létre, melyeket elsősorban a növényzet vizsgálatára alkalmaznak (Lussem et al., 2018; Solymosi et al., 2019; Feng et al., 2021). A tanulmány keretei nem teszik lehetővé az indexek részletes bemutatását, így csak az NDVI, illetve az NDRE indexről kell pár szót ejteni az alkalmazott módszertan miatt.

Mind a normalizált vörös határ index (NDRE; 1), mind a normalizált vegetációs index (NDVI; 2) a növényzet egészségügyi állapotáról, vagyis fittségéről ad információt. Míg az NDVI index a R (vagyis a vörös) sávot veszi figyelembe, addig a NDRE index az R sáv helyett a RedEdge sávval számol az alábbi képlet alapján:

$$\text{NDRE} = (\text{NIR} - \text{RedEdge}) / (\text{NIR} + \text{RedEdge}) \quad (1)$$
$$\text{NDVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED}) \quad (2)$$

Bizonyos növények (pl. kukorica) esetében a késői életszakaszban a felsőbb levelek jobban elnyelik a vörös fénytartományt, így az alsó levelek nem járulnak hozzá az NDVI index számításához, vagyis az index nem fog valós állapotot mutatni. Ezt küszöböli ki az NDRE index, azzal, hogy a vörös sáv helyett a RedEdge sávval számol, mivel a fénytartományt a növény alsó levelei is azonos mértékben hasznosítanak, így a számolt NDRE index már valós képet fog mutatni (Carlson & Ripley, 1997; Maccioni et al., 2001).

Időbeli felbontás

A képfelvételek időbeli felbontása alatt a képkészítés gyakoriságát értjük. Hasonlatosan a spektrális felbontáshoz, ebben az esetben is megkülönböztethető multi-, illetve hipertemporális felvételezés. Mindkettő esetben közös, hogy az időbeli folyamatok megfigyeléséhez szükséges mintavételezési gyakoriságnál – azaz a vizsgált időbeli folyamat gyakoriságának felénél (Shannon-tétel; Tan & Jiang, 2019) – jóval sűrűbb a felvételkészítés gyakorisága. Az idő a

negyedik dimenzió; abban különbözik az x, y, z (térbeli) dimenzióktól, hogy aszimmetrikus – vagyis csak egy irányba folyik – és nehezen elképzelhető (látjuk az idő múlásának hatásait, de nem érzékeljük közvetlenül; Piwowar et al. 1998). A multi-, illetve hipertemporális módszer közötti különbség a felvételkészítés gyakoriságában van. Nincs egységes álláspont a gyakoriságot illetően, például Kleynhans (2011) 8-30 nap gyakoriságnál vonja meg a határt a multi- és a hipertemporális felvételezés között. Piwowar és munkatársai (1998) ajánlása alapján a következő három követelmény teljesülése esetén lehet feldolgozni a multitemporális adatokat:

1. Legyen egyváltozós jellegű (egyazon paraméter különböző időben készített felvétele).
2. Tartalmazzon időszeleteket, melyek mindegyike ugyanazon területet tartalmazza (kép pixelek és a felbontás is tökéletesen egyezzen).
3. Legyenek radiometriailag konzisztensek (azaz ugyanazokkal az érzékelőkkel készüljenek a felvételek).

2. Anyag és módszer

Alkalmazott technológia bemutatása


A felvételek DJI Phantom 4 forgószárnyú quadcopter drónnal készültek, melynek a felvételkészítéshez használt kamera paraméterei az alábbiak:

- Kamera típusa: FC300X
- Szenzor típusa: Sony EXMOR 1/2.3"
- Effektív pixel: 12.4 M
- Képméret: 4000 x 3000 px
- Látószög: 94°
- Fókusz távolság: 20 mm
- Blende: f/2,8
- Záridő: 8-1/8000 s

A Phantom 4 típusú drón csak RGB szenzorral rendelkezik, azonban a Sentera cég gyárt olyan kiegészítőket, melyek segítségével csatlakoztatni lehet különböző Sentera kamerarendszereket DJI drónokhoz. Így az alkalmazott Phantom 4 drónhoz is csatlakoztatni lehet két típusú Sentera kamerarendszert, melyekkel vagy NDVI vegetációs indexet (625 nm-es vörös és 850 nm-es NIR sávot tartalmaz), vagy az NDVI mellett NDRE indexet (720 nm RedEdge és 840 NIR) is képes felvételezni a kamera. Így a felvételkészítés nem egytengelyű lesz, hanem külön tengelyen az RGB és külön tengelyen található az NDVI és/vagy NDRE. A Phantom 4 drónhoz az utóbbi, vagyis a „duális” NDVI, NDRE kamerarendszer lett csatlakoztatva, így a drón a RGB képek mellett azonos időben NDVI és RE (NDRE index helyet csak RedEdge) felvételeket készített a területről.

Felvételezett terület bemutatása

A vizsgált terület a Kis-Balaton tájegység Zimány nevű részének Kis-Szigetén helyezkedik el, amely tulajdonképpen jelenleg már nem egy önálló sziget, és területe ~4200 m² (ábra). Maga a Kis-Balaton a Balaton-felvidéki Nemzeti Park része, amely fokozottan védett, így csak engedély birtokában lehet belépni. A terület – a Balatonnal együtt – önálló ökológiai rendszert alkot, amely világviszonylatban is egyedülálló, és lehetővé teszi akár az éghajlatváltozás okozta vegetációváltozások időbeli vizsgálatát is (Soós et al., 2014). Így az UAV-al történő vegetáció monitorozása is egyre inkább nélkülözhetetlen módszerévé válik az ilyen irányú kutatásoknak is.



1. ábra: A felvételek készítésének helyszíne (Kis-Sziget: piros pontozott terület)

A terület növényzetére a sás, nád és az – adventív észak-amerikai eredetű – magas aranyvessző jellemző, míg a fászszerű növényzetet leginkább a különböző füzek adják. Növényzetet illetően a legnagyobb problémát a magas aranyvessző jelenléte, terjeszkedése jelenti. Erre a gyomfajra jellemző, hogy megjelenésétől számítva – viszonylag gyorsan – csupán négy év alatt fajban szegény, stabil zárt állományokat képes kialakítani, kiszorítva az eredeti, helyspecifikus növényfajokat (Pinke & Pál, 2005).

3. Alkalmazott módszertan

A felvételek készítése az előző fejezetben említett DJI Phantom 4 drónnal és annak FC300X típusú RGB kamerájával, valamint az NDVI és RedEdge felvételek egy külön tengelyen található – vagyis Phantom 4 drónra szerelhető kiegészítőként – NDVI, NDRE, RedEdge kamerával (Sentra Double 4K True) készültek. A felvételek a 2020. évben, átlagosan 12 napos gyakorisággal (

táblázat) a nap ugyanabban az órájában készültek, 100 m-es magasságban, és természetesen mindig ugyanarról a területről.

| | | | |
|----------------|-------------|-------------|----------------|
| Tél | január 2. | Nyár | június 13. |
| | január 15. | | június 24. |
| | január 26. | | július 6. |
| | február 14. | | július 19. |
| | február 29. | | július 30. |
| Tavaszi | március 10. | Ősz | augusztus 9. |
| | március 27. | | augusztus 20. |
| | április 8. | | szeptember 2. |
| | április 18. | | szeptember 11. |
| | április 26. | | szeptember 22. |
| | május 8. | | október 1. |
| | május 18. | | október 19. |
| | május 30. | | október 27. |
| | | | november 1. |

1. táblázat: A felvételkedzítések időpontjai

Az elkészített fotók (3 db csatorna, 27 időponttal számolva, összesen 81 képfájl) nyers, vagyis RAW (36 bites) formátumban készültek, melyek át lettek konvertálva szintén veszteségmentes, de a további feldolgozásra inkább alkalmasabb, 16 bites TIF képformátumba. A konvertálás után a felvételek csatornánkénti összeillesztése, vagyis a RGB, NDVI és RedEdge felvételek egy-egy képfájlba történő másolása történt meg. Az RGB felvételeket szétválasztottuk a három sáv (vörös, zöld, kék) alapján, így további három új képfájlt hoztunk létre, így összesen hat olyan új fájl állt rendelkezésre, melyben 27-27 csatorna található, ahol egy csatorna egy felvételt jelent, időrendben követve egymást. Vagyis az azonos sávhoz tartozó felvételeket „egymásra” másoltuk, így 27 csatornás TIF képek jöttek létre, ahol egy csatorna egy felvételt jelentett. A sorrend ebben az esetben 2020. 01. 02-től 2020. 11. 01-ig tartott, de a módszer szempontjából teljesen mindegy, hogy melyik időpont (csatorna) látható, vagyis, melyik felvétel van az adatkocka legfelső pozíciójában.

A sávonként összeillesztett TIF fájlok további feldolgozása ENVI (5.6.2) szoftverrel történt, ahol a feldolgozás fő célja az összeillesztett képfájlok sávonkénti osztályozása volt. Mivel az osztályozás felügyelt módszerekkel történt, ezért első lépésként az ismert területek, vagyis a ROI-k (Range Of Interest) kijelölése történt meg. A kijelölés során négyfajta növényzettípust különítettünk el: magas aranyvessző, sás, nád és cserje.

A ROI-k kijelölése után következett az osztályozás, melyhez két módszert használtunk, a Maximum Likelihood (ML) és a Spectral Angle Mapper (SAM) módszert. Tapasztalatok alapján a Maximum Likelihood eredményezi a legpontosabb osztályozást, míg a Spectral Angle Mapper módszer akkor hatékony, ha viszonylag sok árnyék található a felvételen (Kozma-Bognár & Berke, 2022; Berke, 2021; Kozma-Bognár, 2012). Az előkészített (27-27 időpont képeit) képfájlokat (RGB, NDVI, RE) a fenti két felügyelt módszerrel osztályoztuk.

A létrejött osztályok ellenőrzésére hibamátrixot hoztunk létre, így objektív módon lehet összehasonlítani az egyes sávok osztályozásának eredményeit, sőt a mátrix az osztályok közötti összefüggéseket is feltárja (Kozma-Bognár & Berke, 2022). A hibamátrixok objektív kiértékeléséhez többváltozós statisztikai módszert – klaszteranalízist – alkalmaztunk.

4. Eredmények, értékelés

Az osztályozási módszerek összehasonlítása

Az osztályozások képi eredményeinek összehasonlítása nehezen véghezvihető és szubjektív értelmezéshez vezethet, ezért objektív módon a hibamátrixokon lehet látni a különbségeket. Az átláthatóság kedvéért a **táblázat** és a táblázat alapján készített grafikon (**ábra**) a hibamátrixokban megtalálható legfontosabb mutatókat (production accuracy: előállítói pontosság; overall accuracy: összesített pontosság) tartalmazza sávonként, módszerenként és osztályonként.


Mind az osztályozott képekből, mind a hibamátrixokból – és a **2. táblázatból** is – jól látható, hogy általában a Maximum Likelihood (ML) módszer jobban teljesített, mind a Spectral Angle Mapper (SAM) módszer. Ez leginkább a sávok összesített pontosság értékeinek vizsgálatával szembeötlő. Ha a sávokon belül az egyes csoportok értékeit hasonlítjuk össze, akkor leginkább csak az R, G, B sávok esetében szignifikáns az a megállapítás, hogy az ML módszer jobb eredményt ad a SAM módszernél. Ez a megállapítás nem teljesen igaz az RGB, RE (RedEdge) és NDVI sávok osztályozásának eredményeire, ez jól látható az összesített pontosság értékeinek összehasonlításából is. Bár az RE sáv aranyvessző osztálya esetében feltűnő a két osztályozó módszer előállítói pontosságainak különbsége, míg a ML módszernél 73,2%, addig a SAM módszernél csak 1,6%.

Az osztályok előállítói pontosságainak összehasonlításából látható, hogy általában az aranyvessző osztályok adták a legnagyobb pontosságot (~65%), melyet a cserje (~54,4%), sás (~48,4%), majd a nád (42,5%) követett. Ha a rosszabbul teljesített sávokat (RGB, RE, NDVI) nem vesszük figyelembe, hanem csak az R, G, B sávokat akkor értelemszerűen a fenti értékek növekednek és az osztályok pontossági sorrendje is megváltozik: cserje (~85%), aranyvessző (~79%), nád (~66%) és sás (54%).

Összességében, ha mindkét pontosságot figyelembe vesszük, akkor egyértelműen a G (zöld) sáv ML módszerrel történő osztályozása adta a legpontosabb eredményt, míg a legrosszabb paramétereket a RE sáv SAM módszerrel alkalmazott osztályozása adta. Az osztályokat tekintve, a vizsgálatok szempontjából fontos aranyvesszőt is a G (zöld) sáv ML módszerrel történő osztályozással lehet a legjobban megfigyelni.

| Sáv/Módszer/Osztály | | Előállítói pontosság | | | | Összesített pontosság |
|---------------------|-----|----------------------|------|-------------|--------|-----------------------|
| | | Nád | Sás | Aranyvessző | Cserje | |
| RGB | ML | 16,1 | 39,8 | 76,9 | 55,6 | 48,6 |
| | SAM | 19,9 | 52,3 | 57,2 | 17,0 | 40,6 |
| R (vörös) | ML | 72,3 | 76,9 | 91,6 | 90,4 | 82,7 |
| | SAM | 53,9 | 25,7 | 70,4 | 76,8 | 53,8 |
| G (zöld) | ML | 80,3 | 81,0 | 94,3 | 94,5 | 87,2 |
| | SAM | 61,8 | 33,3 | 76,1 | 79,6 | 60,1 |
| B (kék) | ML | 71,2 | 70,4 | 90,3 | 88,1 | 79,6 |
| | SAM | 55,5 | 34,6 | 53,2 | 82,4 | 53,0 |
| RE (RedEdge) | ML | 34,3 | 12,5 | 73,2 | 7,4 | 33,9 |
| | SAM | 33,5 | 41,0 | 1,6 | 32,0 | 26,2 |
| NDVI | ML | 5,1 | 58,7 | 49,1 | 20,9 | 37,9 |
| | SAM | 6,8 | 55,0 | 53,3 | 8,3 | 36,1 |

2. táblázat Az osztályok előállítói pontossága sávonként és módszerenként (ML: Maximum Likelihood, SAM: Spectral Angle Mapper)



3. ábra Az osztályok előállítói pontossága sávonként és módszerenként (ML: Maximum Likelihood, SAM: Spectral Angle Mapper)

Az eredmények értelmezése

Az eredmények értelmezését segíti, ha el tudjuk dönteni egy adott sávval és módszerrel osztályozott csoportról, hogy elfogadható-e az eredmény vagy nem. Az előző fejezetben bemutattuk a pontosságok alapján az adott módszerrel és sávval osztályozott eredményeket, így minden csoportról megmondható, hogy megfelelő-e az eredmény, vagy nem. Ezt az értékelést – vagyis, hogy egy csoport „jó-e” vagy nem – is meg lehet vizsgálni objektív módon, mégpedig többváltozós statisztikai módszerrel, a klaszterezéssel. Ebben az esetben minden csoportról

tudjuk az előállítói és a felhasználói pontosságot, a téves osztályba sorolás és az osztályból való kihagyás valószínűségét. Ezek adják a módszer bemenő adatait, melyek alapján be szeretnénk sorolni a csoportot megbízható és nem megbízható kategóriába, vagyis 2 klaszterbe szeretnénk azokat sorolni (k-means klaszterezés).


A klaszterezés eredményeképpen két csoport jött létre, melyek átlagos paraméterértékeit a Hiba! A hivatkozási forrás nem található. tartalmazza. Látható, hogy az 1. csoport tartalmazza a zokat a sáv/módszer/ROI kombinációkat, melyek rossz eredményekre vezetnek, hiszen a pontosságuk alacsony (<37%), viszont a téves osztályba sorolás és az osztályból való kihagyás valószínűsége nagy (>63%). Ezzel szemben a 2. csoport azokat a sáv/módszer/ROI kombinációkat tartalmazza, melyek jó eredmény adtak, hiszen a pontosságuk magas (>75%) és a téves osztályba sorolás és az osztályból való kihagyás valószínűsége alacsony (<25%).

| Csoport / Paraméter | Előállítói pontosság | Felhasználói pontosság | Téves osztályba sorolás | Osztályból való kihagyás |
|---------------------|----------------------|------------------------|-------------------------|--------------------------|
| 1. csoport | 35,6 | 37,4 | 62,6 | 64,4 |
| 2. csoport | 81,4 | 75,4 | 24,6 | 18,7 |

3. táblázat A klaszterezés eredményeképpen kapott két csoport átlagos paraméterértékei

Fontos kérdés, hogy az azonosított csoportokba mely sáv/módszer kombinációk tartoznak, hiszen így meg lehet adni, hogy később mely fenti kombinációkat érdemes használni, ha multitemporális felvételeket szeretnénk használni osztályozáshoz. Ebben segít a **4. ábra**, amely alapján a fenti kérdés egyértelműen megválaszolható, tehát ha megfelelő pontosságot szeretnénk elérni, akkor az R, G, B sávok egyikét kell használni és Maximum Likelihood módszerrel osztályozni. E három sáv pontosságának oka valószínűleg a növényzet zöld és vörös színanyagainak a vegetációs időszakon belüli változása, melynek hatása tulajdonképpen a pixelek RGB értékeinek varianciájában tükröződik. Ezt a feltételezést még jobban alátámasztja a **ábra**, ami alapján látható, hogy a G (zöld) sáv felvételeinek osztályozása adja a legpontosabb eredményt.

Az „alulteljesített” sávok (RGB, RE, NDVI) esetében valószínű hibatényező lehet, hogy az RE, NDVI felvételek nem azonos tengelyen helyezkedtek el, mint a többi RGB, R, G, B sáv. Ez eredményezte azt is, hogy a felvételek között előfordultak elcsúszások, vagyis nem teljesen ugyanaz volt minden kép esetében a terület (a felbontás természetesen nem változott). Ezek az elcsúszások okozhattak osztályozásbeli pontatlanságokat is. A RGB felvételek pontatlansága viszont mindenképpen meglepő, és további vizsgálatokat igényel ennek a kérdésnek a megoldása.



4. ábra A klaszterezés eredményeképpen kapott csoportok összetétele sáv/módszer kombinációk alapján

5. Következtetések, javaslatok

Az eddig levont következtetések alapján kijelenthető, hogy multitemporális felvételeket alkalmazva, növényzeti monitoring vizsgálathoz az RGB szenzorok is alkalmasak, mégpedig a R sáv kiértékelésével megfelelő pontosság érhető el, főleg akkor, ha Maximum Likelihood módszerrel végezzük az osztályozást. Fontos kiemelni, hogy tökéletesnek vehető eredményt, csak a pankromatikus – vagyis a szenzorból közvetlenül kiolvasott – felvételek feldolgozásával kaphatunk. Az RGB felvételek pixelértékei az eredeti felvételhez képest adatvesztést tartalmaznak, melynek mértékét csak becsülni tudjuk, azonban ezt figyelembe kell venni az értelmezés során.

A módszertan alkalmazásakor érdemes arra figyelni, hogy az adatkocka legfelső rétege mely időpont felvételét tartalmazza, hiszen ezt a felvételt fogjuk osztályozni a feldolgozás során. Természetesen ez lehetőséget ad arra is, hogy ha az adatkocka bármelyik időpontban készített felvételét helyezzük a legfelső helyre, vagyis a legelső csatornára, akkor ezt a felvételt osztályozzuk az összes többi időpontban készített felvétel felhasználásával. Tulajdonképpen ebben rejlik a módszer hatékonysága, vagyis az összes időpontban készített felvétel felhasználásával történik az osztályozás, így a lehető legpontosabb osztályozást kapjuk (megfelelő módszer kiválasztása mellett).

Az adatok előfeldolgozásánál figyelni kell arra is, hogy minden időpontban azonos magasságból és azonos területről készüljenek a felvételek. Többtengelyű felvételezés esetén ez a követelmény nem teljesül maradéktalanul, így az osztályozás során (leginkább a SAM módszer esetében) pontatlanságok léphetnek fel, ezért kívánatosabb az egytengelyű felvételek készítése (pl. multitemporális szenzorok alkalmazása).

A munka folytatásaként a módszertani értékelést követően érdemes lehet az R sáv Maximum Likelihood módszerével úgy végig osztályozni a felvételeket, hogy az adatkocka legfelső csatornája mindig egy új időpontú felvétel legyen. Így lényegében egy olyan idősor jönne létre, melynek segítségével látni lehet az aranyvessző területi változásait a vizsgált vegetációs időszakban. Ez további természetvédelmi, beavatkozási feladatokat alapozhat meg, amely lehetővé tenné a Balaton-Felvidéki Nemzeti Park területén belüli agresszívan terjeszkedő adventív növényzet (ez esetben a magas aranyvessző) elleni védekezést.

Felhasznált Irodalom

Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R., & Sousa, J. (2017): Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. *Remote Sensing*, 9(11), 1110. <https://doi.org/10.3390/rs9111110>

Bácsatyai L., Márkus I. (2001): *Fotogrammetria és távérzékelés*. Kézirat, Sopron.

Berke J. (2021): *Képosztályozás elmélete*; MI alapú képosztályozás c. tantárgy előadás anyaga. Széchenyi István Egyetem. Mosonmagyaróvár

Carlson, T. N., & Ripley, D. A. (1997): On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sensing of Environment*, 62(3), 241–252. [https://doi.org/10.1016/s0034-4257\(97\)00104-1](https://doi.org/10.1016/s0034-4257(97)00104-1)

Clevers, J. G. P. W., de Jong, S. M., Epema, G. F., van der Meer, F., Bakker, W. H., Skidmore, A. K., & Addink, E. A. (2001): MERIS and the red-edge position. *International Journal of Applied Earth Observation and Geoinformation*, 3(4), 313–320. [https://doi.org/10.1016/s0303-2434\(01\)85038-8](https://doi.org/10.1016/s0303-2434(01)85038-8)

Európai Unió Tanácsa (2009): A TANÁCS 428/2009/EK RENDELETE a kettős felhasználású termékek kivitelére, transzferjére, brókertevékenységére és tranzitjára vonatkozó közösségi ellenőrzési rendszer kialakításáról. Az Európai Unió Hivatalos Lapja. L 134/1. https://eur-lex.europa.eu/legal-content/HU/TXT/HTML/?uri=CELEX:32009R0428&from=en#ntr1-L_2009134HU.01000101-E0001

Feng, H., Tao, H., Zhao, C., Li, Z., & Yang, G. (2021): Comparison of UAV RGB Imagery and Hyperspectral Remote-sensing Data for Monitoring Winter-wheat Growth. <https://doi.org/10.21203/rs.3.rs-170131/v1>

Kleynhans, W. (2011): *Detecting land-cover change using MODIS time-series data*. PhD Thesis. University of Pretoria. Pretoria.

Kozma-Bognár V. (2012): *Hiperspektrális felvételek feldolgozásának és mezőgazdasági alkalmazásának vizsgálata*. PhD Értekezés. Pannon Egyetem Állat- és Agrárkörnyezet-tudományi Doktori Iskola. Keszthely

Kozma-Bognár V., Berke J. (2022): *Képosztályozás hibaszámítása*; Hiperspektrális felvételezés és adatelemzés c. tantárgy előadás anyaga. Széchenyi István Egyetem. Mosonmagyaróvár

Lillesand, T., Kiefer, R.W., Chipman, J. (2015): *Remote Sensing and Image Interpretation*. Wiley, USA.

Lussem, U., Bolten, A., Gnyp, M. L., Jasper, J., & Bareth, G. (2018): EVALUATION OF RGB-BASED VEGETATION INDICES FROM UAV IMAGERY TO ESTIMATE FORAGE YIELD IN GRASSLAND. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-3, 1215–1219. <https://doi.org/10.5194/isprs-archives-xlii-3-1215-2018>

Maccioni, A., Agati, G., & Mazzinghi, P. (2001): New vegetation indices for remote measurement of chlorophylls based on leaf directional reflectance spectra. *Journal of Photochemistry and Photobiology B: Biology*, 61(1–2), 52–61. [https://doi.org/10.1016/s1011-1344\(01\)00145-2](https://doi.org/10.1016/s1011-1344(01)00145-2)

Mucsi L. (2013): *Műholdas távérzékelés: Elmélet és gyakorlat*. Szegedi Tudományegyetem Természeti Földrajzi és Geoinformatikai Tanszék, Szeged.

Nex, F., Armenakis, C., Cramer, M., Cucci, D. A., Gerke, M., Honkavaara, E., Kukko, A., Persello, C., & Skaloud, J. (2022): UAV in the advent of the twenties: Where we stand and what is next. *ISPRS Journal of Photogrammetry and Remote Sensing*, 184, 215–242. <https://doi.org/10.1016/j.isprsjprs.2021.12.006>

Piwowar, J. M., Peddle, D. R., & LeDrew, E. F. (1998): Temporal Mixture Analysis of Arctic Sea Ice Imagery: A New Approach for Monitoring Environmental Change. *Remote Sensing of Environment*, 63(3), 195–207. [https://doi.org/10.1016/s0034-4257\(97\)00105-3](https://doi.org/10.1016/s0034-4257(97)00105-3)

Pinke Gy., Pál R. (2005): *Gyomnövényeink eredete, termőhelye és védelme*. Alexandra, Pécs.

Solymosi, K., Kövér, G., & Romvári, R. (2019): The Progression of Vegetation Indices: a Short Overview. *Acta Agraria Kaposváriensis*, 23(1). <https://doi.org/10.31914/aak.2264>

Tan, L., & Jiang, J. (2019): Signal Sampling and Quantization. *Digital Signal Processing*, 13–58. <https://doi.org/10.1016/b978-0-12-815071-9.00002-6>