



1949

**A Tisza-tó feltöltődésének, valamint a helyi vegetáció
dinamikájának vizsgálata és az ehhez szükséges módszertani
alapok megteremtése multispektrális és hiperspektrális
távérzékelte adatok felhasználásával**

Egyetemi doktori (PhD) értekezés

A szerző neve:

Szabó Loránd

Témavezető neve:

Prof. Dr. Szabó Szilárd

DEBRECENI EGYETEM
Természettudományi és Informatikai Doktori Tanács
Földtudományok Doktori Iskola
Debrecen, 2022

Ezen értekezést a Debreceni Egyetem Természettudományi és Informatikai Doktori Tanács Földtudományok Doktori Iskola „A lito- és hidroszféra természetes és antropogén folyamatai” programja keretében készítettem a Debreceni Egyetem természettudományi doktori (PhD) fokozatának elnyerése céljából.

Nyilatkozom arról, hogy a tézisekben leírt eredmények nem képezik más PhD disszertáció részét.

Debrecen, 2022. március 7.

*Szabó Loránd
a jelölt aláírása*

Tanúsítom, hogy Szabó Loránd doktorjelölt 2016-2020 között a fent megnevezett Doktori Iskola „A lito- és hidroszféra természetes és antropogén folyamatai” programjának keretében irányításommal végezte munkáját. Az értekezésben foglalt eredményekhez a jelölt önálló alkotó tevékenységével meghatározóan hozzájárult. Nyilatkozom továbbá arról, hogy a tézisekben leírt eredmények nem képezik más PhD disszertáció részét.

Az értekezés elfogadását javaslom.

Debrecen, 2022. március 7.

*Prof. Dr. Szabó Szilárd
a témavezető aláírása*

**A Tisza-tó feltöltődésének, valamint a helyi vegetáció dinamikájának vizsgálata
és az ehhez szükséges módszertani alapok megteremtése multispektrális és
hiperspektrális távérzékelt adatok felhasználásával**

Értekezés a doktori (Ph.D.) fokozat megszerzése érdekében
a Földtudományok tudományágban

Írta: **Szabó Loránd** okleveles geográfus

Készült a Debreceni Egyetem Földtudományok Doktori Iskolája

(A lito- és hidroszféra természetes és antropogén folyamatai programja) keretében

Témavezető: **Prof. Dr. Szabó Szilárd**, egyetemi tanár

Az értekezés bírálói:

Dr.

Dr.

A bírálóbizottság:

elnök: Dr.

tagok: Dr.

Dr.

Dr.

Dr.

Az értekezés védésének időpontja: 2022.

Tartalomjegyzék

1. Bevezetés.....	9
2. Szakirodalmi áttekintés	11
2.1. A távérzékelt adatok tulajdonságai.....	11
2.2. A távérzékelt adatok felhasználásának áttekintése.....	13
2.3. A vizes élőhelyek felmérésének áttekintése.....	14
3. Anyag és módszer	18
3.1. A mintaterület bemutatása.....	18
3.2. A felhasznált adatbázisok.....	23
3.2.1. Műholdas távérzékeléssel nyert adatok – Landsat felvételek.....	23
3.2.2. Hiperspektrális technológiával nyert légifelvétel.....	24
3.2.3. Kiegészítő adatbázisok.....	24
3.3. A multispektrális és hiperspektrális felvétel osztályba sorolási hatékonyságának elemzése.....	25
3.3.1. Az osztályozás input adatainak meghatározása.....	25
3.3.2. Az osztályozás pontosságának értékelése.....	27
3.3.3. Az eredmények ökológiai szemléletű értékelése.....	28
3.4. Hosszútávú vegetáció-változás monitoring spektrális indexek alkalmazásával	28
3.4.1. Előzetes vizsgálatok a vegetációs periódus maximumának meghatározásához	28
3.4.2. A spektrális indexek feldolgozása, valamint a nyílt víztestek arányának meghatározása	30
3.4.3. Vegetáció-terjedés monitoring és a feltöltődés-veszélyeztetettségi index meghatározása	32
3.4.4. Az eredmények validálása.....	33
4. Eredmények.....	34
4.1. A multispektrális és hiperspektrális felvétel osztályba sorolási hatékonyságának elemzése.....	34
4.1.1. A spektrális felbontás szerepe és az optimális spektrális tartomány kiválasztása.....	34

4.1.2. Az adat-transzformáció hatása az osztályozási pontosságra	36
4.1.3. Általános és felszínborítási osztály szintű pontosság értékelése	39
4.1.4. A felszínborítás térképek értékelése tájökológiai szempontból.....	43
4.1.5. Vegetációs dinamika	45
4.1.6. Eredmények értékelése a multispektrális és hiperspektrális felvétel osztályba sorolási hatékonysága alapján	46
4.2. Hosszútávú vegetáció-változás monitoring spektrális indexek alkalmazásával	50
4.2.1. Az éves vegetációs dinamika meghatározása	50
4.2.2. A vízi vegetáció dinamikája 1984 és 2017 között.....	52
4.2.3. A nyílt víztestek arányának változása	56
4.2.4. A POW és a vízszint kapcsolatának összefüggései	59
4.2.5. A feltöltődés kockázatának térképezése	60
4.2.6. Az eredmények validálása	61
4.2.7. Eredmények értékelése a Tisza-tó hosszútávú vegetáció-változás monitoringja alapján	63
5. Összefoglalás.....	67
Summary	69
Köszönetnyilvánítás	73
Felhasznált irodalom	74

1. Bevezetés

Doktori értekezésemben a Kiskörei víztározó, ismertebb nevén a Tisza-tó távérzékelés-alapú vizsgálatával foglalkozok. Már a földrajz alapképzés során elkészített szakdolgozatomban is Tisza-tavi mintaterületen vizsgáltam több különböző multispektrális műholdfelvételt, majd a geográfus mesterképzésen elkészült diplomamunkámban is Tisza-tavi mintaterületet választottam, ahol a multispektrális mellett a hiperspektrális technológiával készült felvételeket is alkalmaztam a vizsgálatokhoz. Mind a szakdolgozat, mind a diplomamunka, valamint a terepi kiszállások során egyre átfogóbb képet kaptam magáról a tározóról és problémáiról.

A Tisza-tó hazánk második legnagyobb tava, a tározót mesterségesen hozták létre és adták át 1973-ban. A Tisza-tó Magyarország egyik legjelentősebb vízi élőhelye, emellett hazánk egyik leginkább frekvenciált vízparti rekreációs központja. A tározó esetében a legnagyobb problémát a medencék üledékkel történő feltöltődése mellett a területen nagy kiterjedésben jelen lévő vízi vegetáció, dominánsan a sulyom (*Trapa natans*) további terjedése jelenti. A feltöltődés hatására a tó elveszítheti nyílt vízfelületeit, így hosszú távon a jelenlegi élőhelyek is pusztulásra vannak ítélve. A vízi vegetáció terjedése egyrészt a feltöltődés következménye, másrészt okozója is, azaz a két folyamat pozitív visszacsatolás révén erősíti egymást: a sekélytavi zónában gyorsabban terjed a növényzet, az elhalt növényi részek pedig általánosan feltöltődést okoznak; áradások alkalmával a lebegtetett hordalék nagyobb valószínűséggel rakódik le a növényzettel sűrűbben benőtt területeken.

A Tisza-tó kapcsán a magyar szakirodalom többnyire botanikai és ökológiai kérdésekkel foglalkozik, a feltöltődés problematikáját ugyan említik, de ezen területek lokalizációjával, monitoring lehetőségeivel, valamint megoldási kérdésekkel nem foglalkoznak. A külföldi szakirodalomban, mivel lokális problémáról van szó, kevés információ található, azonban a témakörben módszertani írások előfordulnak. A legkézenfekvőbb monitoring lehetőséget a távérzékelte adatok alkalmazása jelenti, doktori értekezésemben a távérzékelés számos módszere közül kettőt kiválasztva, egy multispektrális műholdfelvétel (Landsat 8), valamint egy hiperspektrális légifelvétel (AISA Eagle) elemzésén keresztül vizsgálom a két adatforrás alkalmazásának előnyeit és hátrányait, figyelembe véve az eltérő geometriai és spektrális felbontásukat. Emellett Landsat felvételek alkalmazásával egy spektrális indexeken alapuló hosszútávú változásvizsgálatot hajtok végre a tavon zajló szukcessziós folyamatok vizsgálata érdekében.

Az ily módon szerzett ismeretek segíthetik a területi tervezők, környezetvédelmi hatóságok, vízügyi igazgatóságok és döntéshozók munkáját egy fenntartható környezet megteremtése érdekében. Ehhez kapcsolódóan a következő kérdésekre kerestem a választ:

- 1) mi a legnagyobb tematikus pontosság, amely légi hiperspektrális vagy multispektrális műholdfelvételek alkalmazásával elérhető a vízi vegetáció vizsgálatában;
- 2) milyen spektrális tartományok szükségesek a felszínborítási osztályok azonosításához vízi környezetben, különösképpen a vízi vegetáció, valamint a nyílt vízfelületek esetében;
- 3) a dimenziócsökkentő módszerek javítanak-e az osztályozási pontosságon;
- 4) tájökológiai szempontból hogyan határozza meg az alkalmazhatóságot a különböző geometriai felbontású felvételek használata;
- 5) van-e meghatározható időbeli trend a vízi vegetáció terjedésében;
- 6) mely tömedencékben a leggyorsabb a szukcesszió sebessége?
- 7) Céлом volt továbbá egy olyan módszer kidolgozása, amellyel műholdfelvételek segítségével meghatározhatók a feltöltődés által legnagyobb kockázatnak kitett tömedencék.

2. Szakirodalmi áttekintés

2.1. A távérzékelte adatok tulajdonságai

A távérzékelés az egyik leghatékonyabb eszköz Földünk vizsgálatához, a felszínen bekövetkezett változások nyomon követéséhez (Meyer – Turner 1992; Mas 1999; Regmi et al. 2012; Sterling et al. 2013; Lillesand et al. 2014; Gulácsi – Kovács 2018). A műholdas és légi távérzékelés gyors adatnyerést, naprakész adatokat biztosít kiterjedt területekről, nehezen megközelíthető helyekről is. Az erőforráskutató műholdak hosszú ideje biztosítanak egységes adatokat a Földről, ilyen például a Landsat műholdcsalád is, mely 1972 óta folyamatosan szolgáltat felvételeket (Galat et al. 1990; Yuan et al. 2005; Nagendra et al. 2013; Han et al. 2015). De más földmegfigyelési programokat is érdemes megemlíteni, úgymint a SPOT programot, mely 1986 óta készít felvételeket; a MODIS szenzort, mely 1999 óta küld adatokat; az Európai Űrügynökség Copernicus programjának keretein belül operáló Sentinel műholdcsaládot, melynek optikai távérzékelő műholdja, a Sentinel-2 2015 óta van pályán és azóta folyamatosan biztosít felvételeket (Zhao et al. 2009; Foster et al. 2015; Thenkabail 2015).

Jelen értekezés keretében optikai távérzékeléssel készült felvételekkel foglalkoztam, melyek az elektromágneses spektrum látható fény tartományán felül infravörös tartományban is érzékelnek. Ezeket a távérzékelte felvételeket többféleképpen csoportosíthatjuk. A képalkotó szenzort hordozó platform szerint megkülönböztetünk műholdas és légi távérzékelte adatokat, utóbbi esetben a szenzor repülőgépen, helikopteren vagy pilóta nélküli légijárművön kap helyet. A felvételek legszembevetőbb tulajdonsága a geometriai, más néven térbeli felbontás, ami azt mutatja meg, hogy a felvételünk egy elemi egysége, azaz egy pixele a Föld felszínén mekkora területet fed le. Ez alapján beszélhetünk alacsony felbontású felvételekről, ilyen a MODIS 250, 500 és 1000 méteres térbeli felbontása. Közepes felbontású felvételnek tekinthetjük a Sentinel-2 10 méteres, és a Landsat Thematic Mapper (TM), Enhanced Thematic Mapper Plus (ETM+), valamint Operational Land Imager (OLI) 30 méteres térbeli felbontású felvételeit. Nagy felbontásúnak tekintjük a 10 méter alatti felvételeket, ilyenek például a WorldView-4 1,2 méteres, vagy a PlanetScope 3 méteres térbeli felbontású felvételei (Zhao et al. 2009; Drusch et al. 2012; Foster et al. 2015; Thenkabail 2015; Longbotham et al. 2015).

A térbeli felbontás mellett a másik lényeges tulajdonság a felvételek spektrális felbontása, mely megmutatja, hogy az adott felvétel hány spektrális csatornát tartalmaz, az elektromágneses spektrum mely részeit érzékeli, és ezek a sávok milyen hullámhossz-tartományt fednek le. Spektrális felbontás alapján megkülönböztetünk pankromatikus, multispektrális és hiperspektrális felvételeket. A pankromatikus szenzorok egy szélesebb spektrális sávot fednek le az elektromágneses spektrumból a multispektrális sávokkal szemben, így azonos szenzorméret mellett több fény jut a szenzorra és így jobb a felvételek jel-zaj aránya, valamint nagyobb térbeli felbontást

képesek elérni (Meng et al. 2019). A pankromatikus felvételek relatíve nagyobb térbeli felbontása következtében a topográfiai alkalmazások terjedtek el, emellett az adott szenzor spektrális sávjainak térbeli felbontását is tudják ez alapján javítani, ez az ún. pansharpening módszer. A pansharpening módszert mind multispektrális, mind hiperspektrális felvételek esetében alkalmazhatjuk (Ying et al. 2017). Multispektrális és pankromatikus csatornák fűzőjéről számos tanulmány pozitív eredményeket közöl (Myungjin et al. 2005; Deng et al. 2019; Dibs et al. 2020; Phinzi et al. 2020). A multispektrális és hiperspektrális szenzorok közötti határ nem definiálható egyértelműen. Homolova és munkatársai (2013) szerint a száznál is több keskeny spektrális sáv tekinthető hiperspektrális adatnak, van der Meer és munkatársai (2012) viszont már a 19 spektrális csatornával rendelkező Compact High Resolution Imaging Spectrometer (CHRIS) szenzort is a hiperspektrális szenzorok között említik. Xie és munkatársai (2008) viszont a MODIS 36 csatornás felvételeit multispektrálisnak tartják. Multispektrális felvételeknek a három-tíz-húsz csatornás felvételeket tekintjük, ahol az egyes sávok szélesebb hullámhossz-tartományt fednek le, ezzel szemben a hiperspektrális felvételek sok csatornát, akár több százat is tartalmazhatnak, és ezen csatornák az elektromágneses spektrum egy-egy keskenyebb, jellemzően néhány nanométer széles sávját fedik le, így folyamatos reflektanciagörbét kaphatunk a leképezett objektumokról (Homolova et al. 2013). Fontos kiemelni, hogy míg a multispektrális, valamint hiperspektrális felvételek a látható (vagy részben látható) tartomány mellett jellemzően kiegészülnek infravörös tartományokkal, a kizárólag látható tartományt (RGB) felhasználó alkalmazások száma is bővül, ez jellemzően a légifelvételek, valamint drónfelvételek felhasználhatóságában mutatkozik meg. Így hagyományos RGB kamerák felvételeiből is értékes információt nyerhetünk ki. Phinzi és munkatársai (2021) Normalized Green Red Difference Index (NGRDI) alapján vízmosságokat különítettek el egyéb felszínborítás típusoktól, Schlosser és munkatársai (2020) pedig különböző RGB indexek felhasználásával különítettek el vegetációval borított, illetve nem borított területeket egymástól.

A felvételek harmadik legfontosabb tulajdonsága a temporális, vagy időbeli felbontás, azaz a visszatérési idő. Az időbeli felbontás megmutatja, hogy egy adott szenzor milyen időközönként készít felvételeket a Föld ugyanazon pontjáról. Míg a Landsat műholdak esetében a visszatérési idő 16 nap (2021 szeptemberétől, a Landsat-9 fellövése óta 8 nap), több Landsat műhold együttes működésével és a felvételek területi átfedésével gyakrabban kaphatunk felvételeket ugyanarról a vizsgálni kívánt területről. A Sentinel-2A és Sentinel-2B műholdak együttesen 5 napos visszatérési idővel operálnak. A MODIS szenzor a Terra és az Aqua műholdon is megtalálható, mindegyiknek egy napos a visszatérési ideje, ez azt jelenti, hogy a két műhold együttesen naponta két felvételt is biztosít a Föld minden pontjáról. A PlanetScope konstelláció több mint 200 tagjával szintén több felvételt is biztosít naponta (Zhao et al. 2009; Foster et al. 2015; Thenkabail 2015). A különböző szenzorok visszatérési ideje nem feltétlenül egyenesen arányos a felhasználható felvételek számával, mivel

az időjárási körülmények, a felhőborítás, a páratartalom, a besugárzási szög, mind hatnak egy felvétel alkalmazhatóságára (Hagolle et al. 2010; Claverie et al. 2018; Pahlevan et al. 2019). Az egyik legjelentősebb befolyásoló tényező maga a felhőborítás, a többi zavaró légköri tényezőt radiometriai és atmoszférikus korrekcióval ki lehet küszöbölni. Optikai távérzékelés esetén a felhőzet látszik a felvételeken, valamint a felhőzet árnyéka is rávetül a felszínre tovább módosítva a pixelértékeinket. Amennyiben a mintaterületünket részben vagy egészben felhőzet borítja, úgy ezeket a felvételeket nem használhatjuk fel elemzésre, vagy a felhőzettel borított területeket manuálisan vagy automatizált módon ki kell szűrni (Qui et al. 2020; Wei et al. 2020).

A felvételek elérhetősége sokat javult az elmúlt évtizedben. Számos adatbázist, így a Landsat, valamint az archív SPOT felvételeket ingyenessé tették, az újonnan induló földmegfigyelési programok, például a Copernicus (Sentinel műholdcsalád) vagy a Planet (PlanetScope, RapidEye műholdak) ingyenesen, vagy részben szabadon hozzáférhetővé teszik adatbázisaikat, például oktatási-kutatási célra. Az ingyenesen elérhető adatok jellemzően alacsonyabb térbeli és/vagy spektrális felbontással rendelkeznek, mint a kereskedelmi forgalomban kapható társaik. A légi felvételek pedig szinte kivétel nélkül megrendelésre készülnek, viszont ilyen esetben megválasztható mind a térbeli, mind pedig a spektrális felbontás az alkalmazni kívánt szenzor által, valamint a felvételezés időpontja is rugalmasan jelölhető ki, természetesen az időjárási körülmények figyelembevételével (Aber et al. 2010).

2.2. A távérzékelte adatok felhasználásának áttekintése

A multispektrális és hiperspektrális felvételek alkalmazhatóságának és a belőlük kinyerhető információtartalomnak számos különbsége van. A multispektrális felvételekből jellemzően általános információ nyerhető ki, például a felszínborítás osztályozásánál a főbb felszínborítási osztályokat lehet nagy biztonsággal osztályba sorolni (pl. víz, talaj, erdő, gyepek stb.), addig a hiperspektrális felvételek esetében számos részletes információt nyerhetünk ki az adatfeldolgozás során (Güneralp et al. 2014; Tiner et al. 2015; Gulácsi – Kovács 2018). Hiperspektrális felvételek alapján a felszínborítási osztályok nagy biztonsággal bonthatók alosztályokra, ami vegetáció osztályozása esetén akár faj szintű elkülönítést is lehetővé tesz (Govender et al. 2008; Dalponte et al. 2012; Mucsi et al. 2017). Burai és munkatársai (2010) a Rakamaz-Tiszanagyfalui Nagy-morotva vízi vegetációjának esetében végeztek fajszintű osztályozást, de akár fajon belül is a vegetáció állapotától függően alosztályokat lehet meghatározni, ahogy azt Stratoulis és munkatársai (2017) tették nádasok esetében. A hiperspektrális felvételek esetében azonban a jellemzően nagyobb térbeli és spektrális felbontás miatt megnövekedett adatmennyiséggel is számolni kell, valamint egyes sávok esetében megnövekedett jel-zaj aránnyal is találkozhatunk.

A kétféle adat összevetéséről, alkalmazhatóságuk vizsgálatáról számos tanulmány született (Soudani et al. 2006). Dalponte és munkatársai (2012) fajok osztályozási pontosságát vizsgálták nagy felbontású multispektrális és hiperspektrális felvételek alapján. Lee és munkatársai (2004) levélfelület indexeket vizsgált 17 méter térbeli felbontású AVIRIS hiperspektrális és 30 méter térbeli felbontású Landsat 7 multispektrális felvételek esetében egyaránt. Govender és munkatársai (2008) 17 méter térbeli felbontású CHRIS multispektrális adatokat vetett össze 30 méter térbeli felbontású Hyperion hiperspektrális felvételekkel. A fentebbi tanulmányok kapcsán meg kell említeni, hogy az összehasonlított felvételek készítési ideje nagyobb eltéréseket is mutatott, hét naptól egy évig terjedő időközökkel dolgoztak, amely idő alatt a felszínborítás, különösen a vegetáció és annak állapota megváltozhat. Emellett az összehasonlított felvételek térbeli felbontása is különbözött (Fischer – Kakoulli 2006; Dalponte et al. 2012).

2.3. A vizes élőhelyek felmérésének áttekintése

Az adatok mennyiségének, minőségének és lefedettségének növekedése hozzájárul a környezetünkre ható természetes és mesterséges folyamatok jobb megértéséhez, melyek a Föld felszínének változásaiban mutatkoznak meg (Turner et al. 1994; Lambin et al. 2001). A globális léptékű adatok feldolgozása és elemzése kétségkívül hozzájárul a környezetünkben végbemenő folyamatok megértéséhez, azonban a lokális léptékű vizsgálatok elengedhetetlenek a környezetben lezajló folyamatok komplex megismeréséhez. Az ily módon szerzett ismeretek segíthetik a területi tervezők, környezetvédelmi hatóságok, vízügyi igazgatóságok és döntéshozók munkáját egy fenntartható környezet megteremtésében (Szabó et al. 2020).

A tavaknak és vizes élőhelyeknek jelentős szerep jut az élőhelyek és az ökoszisztéma megőrzésében (Weller 1999; Deák et al. 2015; Russell et al. 2019). Az elmúlt évtizedekben, évszázadokban ezen élőhelyek nagy része mind területileg, mind pedig minőségükben csorbát szenvedtek. Hatást gyakorol rájuk többek között a klímaváltozás, a területhasználatban bekövetkező változások, a mezőgazdasági szennyezés és a turizmus, így ezek a területek érzékenyebbé váltak az eutrofizációra és a tómedencék üledékkel történő feltöltődésére. Mindezen hatások eredményeképpen a vizes élőhelyek ökológiai szempontból Földünk egyik legveszélyeztetettebb területeivé váltak (Rembold et al. 2000; Östlund et al. 2001; Scheffer – van Nes 2007; Matthews – Endress 2010; Tanos et al. 2015). Az egyes területek, tómedencék persze nem egyformán veszélyeztetettek a feltöltődés vagy az eutrofizáció szempontjából. Egy nagy kiterjedésű mély tómedence másképpen reagál a külső hatásokra, mint egy kisebb kiterjedésű sekélyebb tómedence.

A hazai tavak több szempontból is veszélyben vannak. Egyrészt az aszályos napok száma egyre növekvő tendenciát mutat a globális felmelegedéssel összefüggésben (Farkas et al. 2017; Csáki et al. 2018), ezért számos tavunk vízhiánnyal küzd, több

közülük nyár végére teljesen kiszárad (Babka et al. 2018), ami igaz a Tisza menti holtmedrek egy részére is. A nagyobb tavaink kevésbé vannak kitéve szembetűnő fenyegetésnek az aszályos időszakok miatt, viszont más hatások nagyobb mértékben is veszélyeztethetik ezeket az élőhelyeket, mint például a tápanyagbeszivárgás és egyéb szennyező anyagok. A tápanyagtöbblettől függően a tavak szukcessziós folyamatai és a vegetáció térnyerése felgyorsul, ami az eutrofizációt erősíti, ezáltal a tavak feltöltődésére is hatást gyakorol (Rátz – Vizi 2004; Csete et al. 2013). Hasonló jelenség figyelhető meg a Fertő-tó, vagy akár a Kis-Balaton esetében is (Zlinszky et al. 2012).

Korábban egyetlen tanulmány sem foglalkozott a Tisza-tó szukcessziójával, és mindössze néhány tanulmány vizsgálta a folyó és az árterek más részeinek átlagos üledékképződési sebességét. A ^{137}Cs (a cézium radioaktív izotópja) mérések szerint a kutatók az 1986-os csernobili atomkatasztrófa által lerakott jelzőrétegre alapozott kísérleti nukleáris tesztekkel használtak. A holtágakban az üledékképződés sebessége 1-2 cm/év között mozog, de nagy árvizek esetén meghaladhatja az 5 cm/év értéket is (Nguyen et al. 2009; Korponai et al. 2016). A holtágak a hidrodinamikai erők hatására az árterek más részeihez kapcsolódó üledékcspadként funkcionálnak. Az üledékképződés sebessége a folyótól való távolság függvénye is; rövidebb távolságokon ez a sebesség 1 és 2 cm/év között alakul, míg 200 m felett 0,4 cm/évre csökken (Dezső et al. 2009). Figyelemre méltó az is, hogy az itt bemutatott vizsgálatoknak számos ellentmondása van; például mivel a Tisza-tó öblítőcsatornákkal összekötött vízgyűjtőkből áll, a lebegő hordalék durva frakciója azonnal lerakódik, amikor az áramlási sebesség csökken. Az ártereken elhelyezkedő holtágakkal ellentétben a Tisza-tó területén lévő holtágak nem feltétlenül azok a medencék, amelyek a legintenzívebbek az üledéklerakódás szempontjából.

A felhalmozódott üledék számos vízgazdálkodási problémát vet fel, a tómedencék gyorsabb feltöltődése mellett az árterekre is hatást gyakorol (Sándor – Kiss 2008; Grygar et al. 2016; Latuso et al. 2017). A feltöltődést többféleképpen lehet vizsgálni: magfúrást elemezve radiometriai módon vagy nehézfémek által (Nguyen et al. 2009), vagy bioindikátorokat vizsgálva (Hubay et al. 2018; Babcsányi et al. 2020). Ezek a módszerek értékes információt szolgáltatnak a feltöltődésről, de a térbeliség hiányzik belőlük, mivel csupán néhány helyen végeznek mintavételt, és az eredmények ily módon extrapoláltak a teljes mintaterületre vonatkoztatva, az extrapoláció pedig mindig hordoz magában hibalehetőséget. Átfogóbb méréseket a mederfenék felmérésével lehet kivitelezni, melyet szondarudakkal (Sacks et al. 1992), szonár technológiával (Halmai et al. 2020), vagy batimetrikus LiDAR-ral (Light Detection and Ranging) lehet végezni (Lague – Feldmann 2020). Habár ezeknek a technológiáknak megvannak a korlátai. A szondarudas felmérések nagyfokú labormunkát vonnak maguk után és a mintavételek száma, valamint eloszlása meghatározza az eredménytérkép megbízhatóságát. A szonár a szondarudas felméréssel jól kombinálható, főleg mélyebb vízben, de a használata partközelsben,

sekélyebb vízben (<50 cm), illetve sűrű növényzetborítás esetén problémás. Batimetrikus LiDAR-t csak tiszta, növényzetmentes vízben lehet megbízhatóan alkalmazni, máskülönben a szenzor által kibocsátott hullámok a zavaros vízben lebegő szilárd részecske/üledék-frakcióban elnyelődhetnek vagy a növényzetről verődhetnek vissza. Mindhárom bemutatott technológia közös hátránya a magas befektetési költségek ellenére az elkészült adatbázisok alacsony megbízhatósága, valamint, ha folyamatos monitoring tevékenységet tervezünk, akkor a méréseket gyakran el kell végezni. A vizes élőhelyek esetében a megközelíthetőség is gondot okozhat a partmenti erdősávok, ligeterdők, valamint a sűrű vízi- és vízparti növényzet miatt (Güneralp et al. 2014). A vízi vegetáció kiterjedésének és térbeli elhelyezkedésének monitoringját a természetes ökológiai folyamatok mellett a külső hatások, mint az áramlatok, a szél és az emberi beavatkozás is befolyásolja, így egy adott állapot felmérése hagyományos terepi módszerekkel nehezen megvalósítható. A fentebb említett problémákra a lehetséges megoldást az optikai távérzékeléssel készült felvételek felhasználása jelentheti.

A spektrális és a térbeli felbontás egyaránt döntő szerepet játszik a felszínborítás osztályozásában, amikor meg kell határozni a lehető legkisebb térképezési egységet, vagy amikor felszíni objektumok, különösen a vízi vegetáció elkülönítése a cél. Adott felszínborítási osztályok spektrális tulajdonságai lehetnek hasonlóak egy adott hullámhossztartományban (pl. a látható fény tartományában), míg egy másikban eltérhetnek (pl. az infravörös tartományban). Ezek következtében meg kell találni a kompromisszumot a szabadon hozzáférhető, gyengébb térbeli és spektrális felbontású multispektrális felvételek, valamint a nagy térbeli és spektrális felbontással rendelkező légi hiperspektrális felvételek között. Ez azt jelenti, hogy ha egy adott felmérés célja lehetővé teszi az kisebb felbontás alkalmazását, akkor a Landsat-adatok felhasználásával legalább 85%-os általános pontossággal lehet osztályozni a felszínborítást (Foody 2002; Lekfuangfu et al. 2016). A hiperspektrális felméréseket általában célzottan végzik, ezáltal költségesek; azonban korábbi kutatások során kimutatták (Oommen et al. 2008), hogy minél több spektrális csatornát vonnak be az osztályozásba, annál pontosabbak az eredmények. Egy további tanulmányban Govender és munkatársai (2008) a változók kiválasztásának fontosságára hívták fel a figyelmet.

A műholdas távérzékeléssel készült ingyenes adatbázisok (Landsat, Sentinel) sikerrel alkalmazhatók a felszínborítás változásainak nyomon követésében (Singh et al. 2018; Alam et al. 2019). A felvételek eredeti spektrális csatornáinak felhasználása mellett spektrális indexek bevonásával még hatékonyabb monitoring tevékenységet tudunk folytatni (Büttner et al. 1987; Li et al. 2015; Balázs et al. 2018; Varga et al. 2018). A spektrális indexek a műholdas távérzékelés megjelenésével egy időben, az 1970-es évektől népszerűvé és széles körben alkalmazottá váltak. Segítségükkel többek között nyomon lehetett követni a nyílt vízborítású területek változását, a víz és a vegetáció minőségi és mennyiségi változásait hosszú távon is. A Tisza-tóról azonban ilyen


jellegű átfogó hosszútávú vizsgálat nem áll rendelkezésre. Természetesen hasonló vizsgálatokra a nemzetközi szakirodalomban is van példa, akár hazai vonatkozásban is, de a fő cél specifikusabbnak tekinthető ezekben a tanulmányokban, és nem komplex vizsgálatokat takar. Hazai vonatkozásban megemlítendő Koma és munkatársai (2021) tanulmánya, ahol légi LiDAR felvételekkel a vegetáció struktúráját vizsgálták magyarországi vizes élőhelyeken. A további nemzetközi szakirodalmat tekintve ilyen például a vízszint változásának nyomon követése (Omute et al. 2012), az aszályos időszakok tendenciájának vizsgálata (Orhan et al. 2014), vagy Landsat adatok alkalmazása hosszútávú változásvizsgálat során (Jiang et al. 2022). MODIS felvételeket vizsgáló tanulmányok esetében a térbeli felbontás miatt kell kompromisszumokat kötni (Reed et al. 2009; Huang et al. 2012), nagy felbontású felvételek alkalmazásánál pedig jellemzően a vizsgált időszak rövid (Sawaya et al. 2003). A Tisza-tó többek között a Tisza folyó által szállított hordalék miatt veszélyeztetett, másrészt a számos pozitív visszacsatolás révén az üledék lerakódása öngerjesztő folyamattá válik. Minél több az üledék, annál több növény talál magának kedvező feltételeket, az elhalt növények pedig az üledék és tápanyagtöbbletet növelik. Ennek ellenére átfogó tanulmány még nem született a feltöltődéssel leginkább veszélyeztetett területek meghatározására és a vegetációs dinamika vizsgálatára, pedig a vegetáció a feltöltődés indikátora is lehet.


3. Anyag és módszer

3.1. A mintaterület bemutatása

Az 1973-ban mesterségesen létrehozott Kiskörei víztározó, ismert nevén Tisza-tó a Balaton után hazánk második legnagyobb tava (1. ábra). A tározó létrehozásának hátterében árvízvédelmi okok mellett, az ipari és mezőgazdasági vízigény kielégítése állt. A területen az elárasztás előtt mezőgazdasági területek, szántók és gyümölcsösök helyezkedtek el. Az egykori ártéren a lefűződött holtágakat is elöntötte a víz. A 127 km² kiterjedésű tó számos szigettel és szárazulattal (43 km²) tagolt területe négy fő medencére tagolható (északról dél felé haladva: Tiszavalki-medence, Poroszlói-medence, Sarudi-medence és az Abádszalóki-medence). Ezek a medencék a lokális viszonyoknak – medermorfológia, vegetáció, szárazulat – megfelelően almedencékre is tagolhatók. Az évek során a természetes folyamatoknak köszönhetően a terület az egyik legjelentősebb természetközeli élőhelyé, ökológiai szempontból is értékes területté vált. A terület a Hortobágyi Nemzeti Park igazgatása alá esik, és így az UNESCO Világörökségi Listáján is szerepel, teljes területe Natura 2000 védeltséget élvez, és részterületei a hazai Ramsari területek között is megtalálhatók.

Az elárasztás előtti állapotoknak megfelelően a rendelkezésünkre álló vízmélységadatok alapján a Tisza-tó átlagos vízmélysége csupán 1,3 méter, legmélyebb pontja egy korábbi holtág helyén 17 méter. A vízszintet a Kiskörei vízerőműnél mesterségesen szabályozzák, egyrészt a mindenkori árvízvédelmi készütségnek megfelelően, egy esetleges árhullám feltartóztatására, hogy a folyó alsó szakaszán enyhíthessék annak hatását, másrészt a mezőgazdasági vízigénynek megfelelően, valamint az ökoszisztéma fenntartása érdekében. A tározóban éves periódusban váltakozik a nyári üzemi és a téli – két méterrel alacsonyabb – vízszint. A tározó üzemi vízszintre töltését az árvízvédelmi intézkedésekkel összefüggésben februárban kezdik meg és április közepéig tart, ezt követően többé kevésbé stagnáló vízszintet tudnak tartani az üzemeltetők (725 cm a kiskörei vízmércénél). A tározó létesítésekor három ütemben tervezték az üzemi vízszint másfél méteres növelését, 1973-ban, 1980-ban és végül 1995-ben. Az utolsó ütemet végül az előre vetített kockázatok – gátak stabilitása, megemelkedő talajvízszint és a mozaikos élőhelyek területének csökkenése – miatt elvetették. Az általunk vizsgált időszakban, 1984 és 2017 között három üzemi vízszintet különböztethetünk meg (2. ábra). 1984-ben és 1985-ben az átlagos vízszint 675 cm volt, 1986 és 2001 között átlagosan 727 cm, végül 2002 és 2017 között átlagosan 735 cm-t mutatott a kiskörei vízmérce. A vízügyi adatokat a Közép-Tisza-vidéki Vízügyi Igazgatóság (KÖTIVIZIG) biztosította a kutatáshoz. Az adatok a 81,32 méteres tengerszint feletti magasságon elhelyezkedő „Kisköre felső” vízmércéről származnak, mely a tározó legdélibb pontja a Kiskörei vízerőműnél, így ezek az adatok az egész tározó vízszintjét pontosan jellemzik.





2. ábra. Júliusi átlagvízszintek 1984 és 2017 között. Forrás: Közép-Tisza-vidéki Vízügyi Igazgatóság, „Kisköre felső” vízmérce adatai alapján saját szerkesztés.

A terület felszínborítására az ártéri erdők, a sekély vizet kedvelő lágyszárú növények, a víz felszínén nagy összefüggő foltokat alkotó úszó emerz vízi növényzet és a vegetációtól mentes nyílt víztestek a jellemzőek (Szabó L. et al. 2016; Szabó et al. 2019). Az felvételek osztályozása során is ezeket a felszínborítási osztályokat alkalmaztam. Jellemző fajok az ártéri erdők esetében a fehér fűz (*Salix alba*), a szürke nyár (*Populus canescens*), a kanadai nyár (*Populus x Canadensis*), valamint invazív fajok közül az amerikai kőris (*Fraxinus pennsylvanica*), a kőrislevelű juhar (*Acer negundo*) és a gyalogakác (*Amorpha fruticosa*). A lágyszárú vegetáció jellemző képviselői a közönséges nád (*Phragmites australis*) és a keskenylevelű gyékény (*Typha angustifolia*). Az emerz vízi vegetáció legelterjedtebb képviselője a sulyom (*Trapa natans*), de többek között a sárga vízitök (*Nuphar lutea*) és a fehér tündérrózsa (*Nymphaea alba*) is képviseltetik magukat.


A vízi vegetáció kiterjedése és mintázata rendkívül fontos a vízi ökoszisztémák esetében, mivel bármilyen változásuk hatással van a nyílt vízfelszínnek arányára (Török et al. 2018). Terepi felméréseimből kiderült, hogy a sulyom a legelterjedtebb és legnagyobb egyedszámban előforduló vízinövény a Tisza-tó területén. A sulyom a víz felszínén lebeg és a víz alatt az iszapban gyökerezik. A növény bár védettséget élvez, mivel Európa szerte csökken a kiterjedése (Hummel – Kiviat 2004), a Tisza-tó esetében viszont nagy kiterjedése miatt veszélyt jelent a biodiverzitásra, valamint gyorsítja a medencék feltöltődését, továbbá hátrányosan hat mind a természetes

élőhelyek megőrzésére, mind pedig a vízgazdálkodásra. A sulyom kiterjedése elsősorban a vízszinttől függ, mivel a növény a két méternél sekélyebb vízben érzi jól magát, így a két méternél mélyebb vizekben nem fordul elő. Legnagyobb kiterjedését a nyári aszályos időszakban éri el, amikor alacsonyabb a vízszint. Ekkor a sűrűn benőtt foltok árnyékoló hatást fejtenek ki, csökkentve a fény bejutását a vízbe, és jelentősen csökkentik a víz oxigénszintjét, így más növényfajok életterét csökkentik, valamint a vízi faunára is kedvezőtlen hatást gyakorolnak. A makrofita növények a hidrológiai jellemzőkre is hatnak, hozzájárulnak a lebegő makrorészecskék arányához (Folkard 2005). A sekély vizekben hatnak az áramlatok sebességére, ezáltal az üledékszállításra is, mindezek következtében az üledék könnyebben halmozódik fel az aljzaton, ezáltal erősítve a medencék feltöltődését. Ezzel a pozitív visszacsatolással pedig a makrofita vegetáció kiterjedését erősítik (Meire et al. 2014). A hosszantartó, magas vízszinttel járó áradások a vegetációs periódus kezdetén szintén hozzájárulnak a vízinövények kiterjedéséhez, mivel a magas vízszint meggátolja a növények csírázását, így azok nem tudnak kihajtani. Az ilyen áradások a vízinövények mellett más lágyszárú vegetációra is hatással vannak, következésképpen a nyílt vizek kiterjedése lesz a meghatározó az adott évben (Kiss – Sándor 2009; Kelemenné Szilágyi – Végvári 2011). A sulyomnak három tipikus megjelenési formáját különíthetjük el: (i) nagy kiterjedésű, összefüggő foltok (3. ábra (a)); (ii) nagy sűrűségű, kisebb kiterjedésű foltok (3. ábra (b)); és (iii) alacsony sűrűségű, ritkább kiterjedésű foltok (3. ábra (c)). A különböző megjelenési formák a 3. ábra (d) részén láthatók a hiperspektrális felvételen.

Bár a Tisza-tónak négy nagy medencéje van, az Abádszalóki medencét kihagytuk a vizsgálatokból, mivel a vizsgált Landsat felvételeken más felvételezési sávba esett, így a felhasználható felvételek, ezáltal időpontok száma a felhőborítás miatt csökkent volna. A maradék három medencét fizikai tulajdonságaik alapján 10 almedencére osztottuk, annak érdekében, hogy a lokális folyamatokat hatékonyabban tudjuk vizsgálni. Ez a megközelítés részletesebb térbeli elemzést tesz lehetővé, a vegetációterjedés és ezáltal a hatékonyabb kockázatelemzés érdekében (1. ábra, 1. táblázat). A hiperspektrális felvétel feldolgozásához a Tisza-tó északi részén egy 8,15 km²-es területet vizsgáltam, mely a tavon előforduló minden tipikus élőhelyet és felszínborítási osztályt magába foglal (1. ábra; sárga keret).

1. táblázat. A vizsgált medencék típusai és jellemzésük

Medence azonosító	Terület (ha)	Típus	Jellemzés
1	1709	Nagy kiterjedésű medence magas nyílt víz aránnyal	A medencét nagy nyílt víztükör, magas vízszint és kis vegetáció-borítás jellemzi
2	1136	Nagy kiterjedésű medence magas nyílt víz aránnyal	A medencét nagy nyílt víztükör, magas vízszint és a parti régiókban közepes vegetáció-borítás jellemzi
3	590	Közepes kiterjedésű medence magas vegetáció-borítással	A medence közel száz százalékát vegetáció borítja a legtöbb évben, nyílt víztükör egy korábbi, mélyebb meander mentén, a medence közepén fut
4	274	Közepes kiterjedésű medence állandó nyílt víztükörrel	A medence part menti része mélyebb nyílt víztükör, a belső területeken magas vegetáció-borítással
5	658	Nagy kiterjedésű medence magas nyílt víz aránnyal	A medencét nagy nyílt víztükör, magas vízszint és a parti régiókban közepes vegetáció-borítás jellemzi
6	157	Közepes kiterjedésű medence magas vegetáció-borítással	A medencét a legtöbb évben magas vegetáció-borítás jellemzi, nyílt víztükör az északi részen fordul elő
7	82	Kis kiterjedésű medence magas vegetáció-borítással	A medence közel száz százalékát vegetáció borítja a legtöbb vizsgált évben
8	55	Kis kiterjedésű medence állandó nyílt víztükörrel	A medence egy korábbi meander volt, magas vízszint, és nagy nyílt víz arány jellemzi, kis vegetáció-borítással a parti régiók mentén
9	69	Kis kiterjedésű medence állandó nyílt víztükörrel	A medence korábbi meander volt, mély víz és magas nyílt víz arány jellemzi a középső területeket, a parti régiók sűrű vegetáció- borítással bírnak
10	31	Kis kiterjedésű medence állandó nyílt víztükörrel	A medence korábbi meander volt, mély víz és magas nyílt víz arány jellemzi, alacsony vegetáció-borítással a parti területek mentén.



3. ábra. A sulyom (*Trapa natans*) természetes előfordulási formái (a), (b), (c), és azok megjelenése a hiperspektrális felvételen (d)

3.2. A felhasznált adatbázisok

3.2.1. Műholdas távérzékeléssel nyert adatok – Landsat felvételek

A doktori disszertációmban vizsgálat alá vontam több különböző Landsat műholdfelvételt. A Landsat 4, 5 Thematic Mapper (TM), a Landsat 7 Enhanced Thematic Mapper Plus (ETM+), valamint a Landsat 8 – Operational Land Imager (OLI) szenzorának felvételeit alkalmaztam a hosszútávú idősoros vegetációváltozás-vizsgálathoz. Mindegyik szenzor 30 méteres térbeli felbontással rendelkezik, és hasonló spektrális tartományt fednek le, így a felhasznált felvételek összehasonlíthatók, idősoros elemzésre alkalmasak. A felvételeket Level-2 szintű reflektancia-értékekkel (surface reflectance) töltöttem le az USGS ESPA letöltő felületét használva (USGS ESPA 2020), az így nyert adatok geometriai és atmoszférikus korrekcióval ellátottak, így készen álltak a további feldolgozásra. A

vizsgálthoz NDVI vegetációs indexeket szintén az USGS ESPA oldalról szereztem be, melyek szintén geometriai és atmoszférikus korrekcióval ellátott Level-2 adatokból álltak elő. Az MNDWI vízindexeket a letöltött Level-2 geometriai és atmoszférikus korrekcióval ellátott spektrális csatornákból számítottam ki, mivel ezek alapértelmezetten nem rendelkeznek a letöltőfelületen.

A hiperspektrális felvétellel összevetni kívánt felvételt a Landsat 8 OLI szenzora készítette 2013 július 8-án, ezen a felvételen további Quick Atmospheric Correction (QUAC) atmoszférikus korrekciót végeztem ENVI/IDL 5.3 szoftverkörnyezetben, annak érdekében, hogy a két felvétel összevetése még megbízhatóbb legyen. A felvétel kilenc csatornája közül hetet használtam fel, a 15 méter térbeli felbontású pankromatikus és a 9. „cirrus” csatornát nem vontam be az osztályozásba.

3.2.2. Hiperspektrális technológiával nyert légifelvétel

A hiperspektrális légifelvételt egy Piper Aztec repülőgépre rögzített AISA Eagle szenzor készítette 2013. július 9-én, a vegetációs periódus csúcán, egy napos eltéréssel az összevetésre szánt Landsat 8 felvétellel. A felvétel 1500 méteres magasságból, 1,5 méteres térbeli felbontással készült. Az AISA Eagle szenzor 400 nm és 1000 nm közötti 128 darab csatornája nagyjából 5 nm-es sávban érzékeli a radianciát. A felvétel radiometriai és geometriai korrekciója az ENVI/IDL 5.3 (Exelis, Inc., Boulder, CO, USA), valamint a CaliGeoPro (Spectral Imaging Ltd., Oulu, Finland) szoftverekkel készült, míg a reflektancia-értékek kinyerése, a radiometriai és atmoszférikus korrekció elvégzése az ENVI Fast Line-of-sight Atmospheric Analysis of Hypercubes (FLAASH) korrekciós módszerrel készült. Így az eltérő besugárzási szög és légköri viszonyok mellett készült felvételek is összehasonlíthatóvá válnak.

3.2.3. Kiegészítő adatbázisok

A KÖTIVIZIG biztosított a kutatáshoz medermorfológiai adatokat digitális batimetriai modell formájában. A modell egy kéthetes terepi mérés eredményeként jött létre 2017-ben, amikor csónakokra rögzített szonárral vizsgálták az egész Tisza-tó medrét. Nagy pontosságú RTK GPS-szel mérték be az egyes mélységadatok koordinátáit, amiből térbeli interpoláció segítségével előállt a végleges raszter alapú medermorfológiai modell, mellyel később a hosszútávú vegetációváltozás-vizsgálat eredményeit validáltam.

A multispektrális és hiperspektrális felvételek felszínborítás-osztályozásának összevetéséhez a tanuló- és ellenőrzőterületeket elsősorban terepi vizsgálatok, valamint a területről rendelkezésre álló ortofotók, 1:10000 méretarányú EOTR topográfiai térképszelvények, műholdfelvételek, valamint a hiperspektrális légifelvétel alapján határoztam meg. A multispektrális felvételek spektrális korlátait

figyelembe véve négy felszínborítási kategóriát különítettem el a területen: erdők, lágyszárú vegetáció, vízi vegetáció, valamint nyílt víztestek. Ezeket a felszínborítási osztályokat a 3.1. fejezetben ismertettem bővebben. A gyűjtött adatok 80%-át tanulóterületnek, 20%-át ellenőrzőterületnek soroltam be, mivel több szerző munkája alapján (Friedl et al. 2000; Lyons et al. 2018; Moreno-Martínez et al. 2018), valamint az előzetes osztályozások alkalmával ez az arány optimálisnak bizonyult.

3.3. A multispektrális és hiperspektrális felvétel osztályba sorolási hatékonyságának elemzése


3.3.1. Az osztályozás input adatainak meghatározása

A multispektrális és hiperspektrális felvételt egyaránt többféle módon osztályoztam a 3.2.3. fejezetben ismertetett tanulóterületek felhasználásával, majd az osztályozott felvételek tematikai pontosságát a meghatározott ellenőrzőterületek alkalmazásával validáltam. Egyrészt input adatok tekintetében többféle spektrális tartománnyal dolgoztam, majd dimenziócsökkentést alkalmazva (Minimum Noise Fraction; MNF) kisebb számú mesterséges változót (főkomponenst) állítottam elő az eredeti csatornákból a maximális magyarázott variancia megtartása mellett, valamint meghatároztam az osztályozást leginkább befolyásoló legfontosabb csatornákat (Variable Importance). Végül az adatokat azonos térbeli felbontás mellett is megvizsgáltam.

A hiperspektrális felvételek esetén egyes csatornák jel-zaj aránya nagy, így ezek bevonása az osztályozásba rontja a végeredményt. A spektrális felbontás szerepét vizsgálva első lépésként a 128 csatornás hiperspektrális felvételtől kiválogattam a zajos sávokat (4. ábra (b)). A zajos sávokat az egyes csatornák szürkeárnyaltos megjelenítése által, valamint az adott csatorna hisztogramjának vizsgálatával határoztam meg, utóbbi esetben a pixelértékek random eloszlását figyelve (Ifarraguerri – Prairie 2004). Ezzel a módszerrel 109 zajmentes csatornát határoztam meg, melyek a 413 nm és 923 nm közötti hullámhossz-tartományban helyezkedtek el. Következő lépésben a Landsat 8 OLI szenzorának spektrális tartományát lefedő csatornákat válogattam ki a hiperspektrális felvételtől, így 47 csatornát kaptam. A kapott 47 csatornát, annak érdekében, hogy a Landsat felvétellel még pontosabban össze tudjuk hasonlítani, 4 csatornává átlagoltam, így a Landsattal megegyező kék (blue; B), zöld (green; G), vörös (red; R), és közeli infravörös (near-infrared; NIR) csatornát kaptam eredményül.

Az osztályozásba bevont csatornákat (128, 109, 47, és 4 db) Support Vector Machine (SVM) osztályozó algoritmussal soroltam osztályba Radial Basis Kernel alkalmazásával. A vizsgálatok során elvégzett összes SVM osztályba sorolást ENVI/IDL 5.3 szoftverkörnyezetben végeztem el (Melgani – Bruzzone 2004; Xu et al. 2009; Burai et al. 2015; Sun et al. 2017). Ez a robusztus módszer alkalmas

különböző forrásból származó és különböző dimenzióval rendelkező input adatok hatékony osztályozására (Bretar et al. 2009).



4. ábra. Az osztályba sorolás input adatainak meghatározása

A 128, valamint 47 csatornát Random Forest (RF) osztályozásnak is alávettem EnMAP-Box 2.2.1 szoftverkörnyezetben (Gislason et al. 2006; van der Linden et al. 2015) 500 döntési fával. Az osztályozáshoz kapcsolódóan meghatároztam a csatornák fontossági sorrendjét (Variable Importance analízis) a 128, valamint 47 csatornán. Az eredményt felhasználva Genuer és munkatársai (2010) módszere alapján határoztam meg az osztályozásban használt végső sorrendet: fontosság szerinti csökkenő sorrendben egyesével növeltem a RF osztályozás során a bemenő csatornák számát, amíg az osztályozási hiba változása 1% alatti nem lett. A 128 csatorna esetében 16, a 47 csatorna közül 14 csatornát találtam jelentős szerepűnek a legjobb általános pontosság eléréséhez. Ez a 16, valamint 14 csatorna lett a végső bementi adat az SVM és RF osztályozókhoz (4. ábra (a)). A Variable Importance eredménycsatornáinak és a Landsat spektrális tartományával megegyező 47 csatornának az unióját képezve 59 csatornát kaptam, melyet szintén SVM használatával osztályoztam (4. ábra (c)).

A Landsat felvétel esetében – mivel a vizsgálatból kivontam a „cirrus” és pankromatikus csatornákat – a hét csatornának a különböző kombinációival

osztályoztam (4. ábra (d)). A BGR+NIR minden kombináció alapját képezte, ezt osztályoztam önállóan is. Emellett egyrészt hozzáadtam a „coastal/ocean” csatornát, másrészt a két rövid hullámú infravörös (short wave infrared; SWIR) csatornát, végezetül mind a hét csatornát bevontam az osztályozásba, melyet ez esetben is SVM alkalmazásával végeztem.

A következő lépésben mind a multispektrális, mind a hiperspektrális felvétel esetében Minimum Noise Fraction transzformációt (MNF) alkalmaztam és az így kapott új főkomponenseket használtam a következő SVM osztályozások input adataként (4. ábra (e)). Az MNF transzformáció két egymást követő főkomponens-analízist foglal magába; az algoritmus először kiszűri a zajos csatornákat, majd az adatokat a zaj szórása alapján újra sorba rendezi (Green et al. 1988). Az új MNF változók (MNF csatornák) mindegyikének átlaga 0, szórása pedig 1. Az első néhány MNF változó pedig magában foglalja az eredeti csatornák pixelértékeinek a varianciáját, azaz az eredeti felvétel információtartalmát az első néhány MNF csatornába rendezve kapjuk meg (Boardman 1993). Ezeket a csatornákat ugyanúgy használhatjuk a felszínborítás osztályozására, mint az eredeti spektrális csatornákat. MNF transzformációt alkalmaztam a 128, 109, 59, 47, valamint négy csatorna esetében, továbbá a hét Landsat csatornán egyaránt. Egyenként 20 SVM osztályozást végeztem el az előbb említett csatornák mindegyikén, ahol 1 és 20 között sorrendben, egyesével növeltem a bemenő MNF csatornák számát, kivétel ez alól a négy csatorna, valamint a Landsat csatornái, melyeken legfeljebb négy, illetve hét MNF csatorna bevonására volt lehetőség. Ez a vizsgálat tette lehetővé, hogy csak a legjobb általános pontosságot elért input adatokat értékeljem az MNF transzformáción átesett csatornák esetében.

Végezetül annak érdekében, hogy összevethessem a tematikai pontosságot és az MNF transzformáció szerepét azonos térbeli, valamint spektrális felbontás mellett, újrámintavételeztem az 1,5 méter térbeli felbontású MNF transzformáción átesett 47, valamint négy csatornát, továbbá a nem transzformált négy csatornát 30 méteres térbeli felbontású felvétellé. Az újrámintavételezéshez átlagoló pixelösszevonást (Pixel Aggregate) alkalmaztam ENVI/IDL 5.3 szoftverkörnyezetben. A módszer az összes eredeti pixel átlagát veszi, amely a kimenő pixel területére esik.

3.3.2. Az osztályozás pontosságának értékelése

Az osztályozások során elkészült felszínborítás térképeken tematikai pontosságvizsgálatot végeztem, hogy összevethessem az egyes input adatok, valamint az alkalmazott módszerek hatékonyságát. A pontosságvizsgálathoz a 3.2.3. fejezetben ismertetett ellenőrzőterületeket használtam fel. Meghatároztam az általános- (Overall Accuracy; OA), az előállítói- (Producer's Accuracy; PA), valamint a felhasználói pontosság (User's Accuracy; UA) mellett a Kappa Koefficiens (Kappa) értékét is (Lunetta – Congalton et al. 1991).


3.3.3. Az eredmények ökológiai szemléletű értékelése

A multispektrális, valamint hiperspektrális adatokból nyert elkészült felszínborítás térképeim közül egyaránt a legnagyobb általános pontosságú térképet ökológiai szempontból is megvizsgáltam. Mindkét térképen meghatároztam a különböző felszínborítási foltok számát, és azok méretét felszínborítási osztályonként. Ezt követően a vízi vegetáció növekedési régióinak meghatározásához QGIS 2.18 (QGIS Development Team 2017) szoftverkörnyezetben „hőtérképet” készítettem a vízi vegetáció felszínborítási osztályának hiperspektrális felvételből nyert felszínborítás térképének folt-sűrűsége alapján. Az eredményeket statisztikai eszközökkel elemeztem. Ezek mellett kiszűrtem a 900 m²-nél kisebb foltokat (egy Landsat pixel mérete), hogy a két felvételből nyert térképek eredményeit nagyobb pontossággal tudjam összehasonlítani. A nem normál eloszlás miatt Mann-Whitney teszttel elemeztük a foltméretek mediánjában bekövetkezett statisztikai különbséget a két felvételből nyert felszínborítás térképek esetében. A teszteket felszínborítási kategóriánként végeztük R 3.3.3 (R Core Team 2017) szoftverkörnyezetben.

3.4. Hosszútávú vegetáció-változás monitoring spektrális indexek alkalmazásával

3.4.1. Előzetes vizsgálatok a vegetációs periódus maximumának meghatározásához

Ahhoz, hogy konzisztens, hosszútávú vegetáció-változás vizsgálatot tudjak folytatni, szükségünk van a vegetációs periódus megismerésére. Ehhez egy olyan évet kellett találnom, amikor megfelelően sok felhőzetmentes felvétel áll rendelkezésre a területről, ez alapján 2015-re esett a választás, ahonnan hat Landsat-8 felvétel állt rendelkezésre május és szeptember között. Azt a felvételt kerestem, amikor a vegetáció a legsűrűbb, legnagyobb kiterjedésű. Ehhez csak a vegetációval borított területeket vizsgáltam az egyes felvételeken, ahol az MNDWI vízindex értékei nullánál kisebbek, vagyis nem vízzel borított területek voltak. A vegetációval borított területek NDVI értékeit vizsgálva kerestem azt a legmagasabb NDVI értéket, ahol a variancia a legkisebb, azaz az NDVI értékek interkvartilis tartománya a legkisebb varianciát mutatja. Ez alapján meghatároztam azt az időablakot, amelyen belül felhasználhatom a felvételeket a hosszútávú elemzéshez. Ezt az időtartományt, valamint a Landsat műholdak visszatérési idejét figyelembe véve megvizsgáltam az összes területileg és időben elérhető felvételt, melyek közül 20 felhőzetmentes felvételt választottam ki az 1984 és 2017 közötti időszakból a további elemzésekhez (5. ábra, 2. táblázat). A felvételek kiválasztása vizuális elemzés mellett, a Landsat-8 esetében a „cirrus” sáv alkalmazásával történt, mellyel a cirrus felhőket lehet detektálni, és így kiszűrni az elemzésből.



5. ábra. A hosszútávú vegetációváltozás-vizsgálata, valamint a feltöltődés veszélyeztetettségi index meghatározásának lépései (NDVI, Normalized Difference Vegetation Index – vegetációs index; MNDWI, Modified Normalized Difference Water Index – vízindex; POW – nyílt víztestek százalékos aránya, Percentage of Open Water)

2. táblázat. A hosszútávú vegetációváltozás-vizsgálathoz felhasznált felvételek és készítési idejük

Vegetációs periódus meghatározása		Hosszútávú vegetációváltozás-vizsgálat	
Szenzor	A felvételezés ideje	Szenzor	A felvételezés ideje
Landsat 8 OLI	2015.05.18	Landsat 5 TM	1984.07.31
Landsat 8 OLI	2015.06.03	Landsat 5 TM	1985.08.03
Landsat 8 OLI	2015.07.05	Landsat 5 TM	1986.07.30
Landsat 8 OLI	2015.07.21	Landsat 5 TM	1987.08.09
Landsat 8 OLI	2015.08.06	Landsat 4 TM	1992.07.29
Landsat 8 OLI	2015.09.23	Landsat 5 TM	1994.08.05
		Landsat 7 ETM+	2000.08.04
		Landsat 7 ETM+	2001.07.31
		Landsat 5 TM	2003.08.05
		Landsat 5 TM	2004.08.07
		Landsat 5 TM	2005.08.10
		Landsat 5 TM	2006.07.28
		Landsat 5 TM	2007.07.31
		Landsat 5 TM	2009.07.29
		Landsat 5 TM	2010.08.01
		Landsat 5 TM	2011.08.11
		Landsat 8 OLI	2014.08.03
		Landsat 8 OLI	2015.08.06
		Landsat 8 OLI	2016.08.08
		Landsat 8 OLI	2017.08.11

3.4.2. A spektrális indexek feldolgozása, valamint a nyílt víztestek arányának meghatározása

A vízi vegetációt figyelmen kívül hagyva a Kiskörei víztározón belül 10 tómedencét (1. ábra; narancssárga körvonal) határoltam el a szárazföldi területektől. A lehatárolás alapját természetes és mesterséges objektumok, nagy felbontású légifelvételek, valamint topográfiai térképek szolgáltatták. Ez a lehatárolás tette lehetővé a feltöltődés és a szukcesszió trendjének és térbeli eloszlásának vizsgálatát.

Az egyes tómedencéken spektrális indexek alkalmazásával vizsgáltam a vízi vegetáció terjedését. A 3.2.1. fejezetben bemutatott, korábban letöltött NDVI (1. egyenlet, Rouse et al. 1973; Tucker 1979) vegetációs indexszel számszerűsíteni tudtam a pixelek zöldességét, vagyis a zöld vegetációt.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad [1]$$

Ebben az egyenletben a RED a vörös csatornát (Landsat 4, 5 és 7 esetében a 3. csatorna, Landsat 8 esetében a 4. csatorna), a NIR a közeli infravörös csatornát jelöli (Landsat 4, 5 és 7 esetében a 4. csatorna, Landsat 8 esetében az 5. csatorna).

A felvételek esetében kiszámoltam az MNDWI (2. egyenlet, Xu 2006) vízindexet, melynek segítségével a nyílt vízfelületek meghatározására nyílt lehetőségem.

$$MNDWI = \frac{SWIR - GREEN}{SWIR + GREEN} \quad [2]$$

Ebben az egyenletben a GREEN a zöld csatornát (Landsat 4, 5 és 7 esetében a 2. csatorna, Landsat 8 esetében a 3. csatorna), a SWIR a közepes infravörös csatornát jelöli (Landsat 4, 5 és 7 esetében az 5. csatorna, Landsat 8 esetében a 6. csatorna).

Bár az NDVI vegetációs indexet alkalmaztam a vízi vegetáció azonosításához és értékeléséhez, az NDVI-t gyakran használják a vízfelületek lehatárolásához is, viszont ehhez az MNDWI vízindex nyújtott biztosabb alapot (Szabó S. et al. 2016; Kiage – Douglas 2020). A statisztikai számításokat két fokozatban hajtottam végre. Az NDVI esetében először az összes tómedencére minden évben meghatároztam az átlag, alsó kvartilis (q1), medián (q2), és felső kvartilis (q3) értékét. Ezt követően az MNDWI segítségével lehatároltam a nyílt vízfelszíneket, Xu (2006) alapján a lehatároláshoz 0 határértéket választottam (ahol az MNDWI értékek nagyobbak vagy egyenlők 0-val, azokat a területeket nyílt vízfelszínként azonosítottam, a negatív értékek a vegetációval borított területeket jelölték). A lehatárolt nyílt vízfelszínek esetében is elvégeztem a korábban említett statisztikai számításokat. A módszertani folyamatára az 5. ábrán látható. Az eredményeket dobozdiagramon ábrázoltam, és az NDVI értékeket három aspektusból értékeltem: elsőnek a teljes tómedencék vonatkozásában, másodszor csak a nyílt vízfelszíneket ($MNDWI \geq 0$), végül csak a vegetációval borított területeket ($MNDWI < 0$).

Mivel a rendelkezésre álló felvételek időben nem voltak egyenlő távolságra, nem alkalmaztam formális időszorelemzést; a grafikus megjelenítés azonban lehetővé tette, hogy következtetéseket vonjak le mind a vegetáció, mind a nyílt vízfelületek változásaira vonatkozóan. E három nézőpontból (teljes tómedence, nyílt vízfelület, és vegetációval borított terület) értékeltem a rendelkezésemre álló batimetriai modellt is.

A teljes idősor tekintetében megvizsgáltam a vegetációborítás gyakoriságát a mintaterületen. A vizsgálathoz összegeztem a vegetációval borított területeket ($MNDWI < 0$). Az így kapott gyakoriságtérképen meghatároztam az állandó nyílt vízborítású területeket, ahol a 20 vizsgált időpontból legalább 18 esetben vízborítást figyeltem meg, azaz az idősor 90 százalékában; ennek ellentétéként deklaráltam a vegetációval borított területeket. Továbbá az egyes medencék esetében meghatároztam a nyílt vízfelszínnek százalékos arányát (Percentage of Open Water; POW [%]; 3. egyenlet), a nyílt vízfelszín és a teljes tómedence területének százalékában.

$$POW [\%] = \frac{\text{nyílt vízfelszínnek területe a medencén belül [m}^2\text{]}}{\text{a medence teljes területe [m}^2\text{]}} \quad [3]$$

A POW értékeket a vízállással összefüggésben értékeltem. Mivel július végi, augusztus eleji felvételekkel dolgoztam, így az adott év júliusi vízállásadatai alapján (minimum [j_min], maximum [j_max], átlag [j_mean], és szórás [j_sd]) értékeltem a kapcsolatot a két adatsor között. A korrelációt korrelációs diagramon ábrázoltam.

A felvételek feldolgozásához az ENVI IDL 5.3 (ENVI IDL 2019) és az ArcGIS 10.4 (ArcGIS 2019) szoftvereket használtam, a statisztikai számításokhoz az R 3.5.1 (R Core Team 2017) szoftver jmv bővítményét használtuk (Selker et al. 2020). Minden spektrális index és eredménytérkép Landsat felvételekből készült, így ezek egységesen 30 méteres térbeli felbontással rendelkeznek.

3.4.3. Vegetáció-terjedés monitoring és a feltöltődés-veszélyeztetettség index meghatározása

Az egyes tómedencéken belül meghatároztam a vegetáció terjedésének kockázatát, mint a szukcesszió és a feltöltődés indikátorát, vagyis ahol magasabb a vegetáció gyakorisága, ott a feltöltődés is előrehaladottabb állapotban lehet, mivel egyes vízinövények – akár a sulyom –, vagy a nádas és gyékényes a sekélyebb vizeket kedvelik, és nem telepednek meg mélyebb vizekben. Ennek következtében a vízi vegetáció jelenléte sekély vízre, vagy feltöltődésre utalhat, ezáltal a változásokat évről évre nyomon lehet követni. Határértékeket állapítottam meg az átlagos NDVI értékek (a magasabb értékek sűrűbb vegetációt jelölnek) és a minimum POW értékek (idősorban a legkisebb POW érték) esetében, annak érdekében, hogy veszélyeztetettség tényezőket állapíthassak meg az egyes tómedencék esetében (3. táblázat). Ezek alapján két veszélyeztetettségi faktort rendeltem minden egyes tómedencéhez, melyek összesített értékéből megkaptam a saját készítésű feltöltődés-veszélyeztetettség indexet (Level of Sedimentation Risk Index; LoSRI; 4. egyenlet). A két tényező fontos információkat tartalmaz a tavak feltöltődéséről; míg az NDVI képes a vegetáció sűrűségének meghatározására, így az adott területen található biomassza tömegének megállapítására (a nagyobb értékek nagyobb biomasszatömeget jelölnek), addig a POW megmutatja a vegetációmentes területek arányát (feltöltődés mérséklése szempontjából a nagyobb kiterjedésű vízfelszín a kedvezőbb).

3. táblázat. A veszélyeztetettségi faktorok és a LoSRI meghatározása

VDF		OWFF		LoSRI	A feltöltődés kockázata
NDVI átlag értékek	Veszélyeztetettségi faktor	Minimum POW értékek (%)	Veszélyeztetettségi faktor	Összesített veszélyeztetettségi faktor	
-1 to 0.1	1	65–100	1	2–5	Alacsony
0.1–0.2	2	45–65	2		
0.2–0.3	3	30–45	3	6–9	Közepes
0.3–0.4	4	20–30	4		
0.4–0.5	5	10–20	5	10–12	Magas
0.5–1	6	0–10	6		

A LoSRI értékek meghatározása a 4. egyenletben látható:

$$LoSRI = VDF + OWFF \quad [4]$$

Az egyenletben a LoSRI a feltöltődés-veszélyeztetettségi indexet jelöli, a VDF a vegetáció sűrűségi faktort (Vegetation Density Factor), azaz az adott év adott medencéjének átlagos NDVI értékét, az OWFF a nyílt víz frakció faktort jelöli (Open Water Fraction Factor), azaz a nyílt vízfelületek teljes tómedencéhez viszonyított arányát. A LoSRI értékei 2-től 12-ig terjedő skálán mozoghatnak. 2 nem jelez kockázatot, 12 esetében pedig szignifikáns kockázatról beszélhetünk az adott tómedence esetében a feltöltődés szempontjából. Az ilyen besorolású tómedencék – megfelelő kezelés hiányában – a közeljövőben akár teljesen feltöltődhetnek.

3.4.4. Az eredmények validálása

A validációt a rendelkezésünkre álló vízmélységadatok bevonásával végeztük. A validáció során meghatároztam a LoSRI értékek és a vízmélység kapcsolatát, mivel a LoSRI index a feltöltődés veszélyeztetettségére utal, így alacsony érték esetén alacsonyabb vízszintet feltételezhetünk az adott medencében. A vízszint és a LoSRI értékek mellett fontos figyelembe venni a vegetációval borított területek és a tómedencék arányát, azaz ahol a 20 vizsgált időpontból 18 esetben, tehát 90 százalékban vegetáció volt jelen az adott területen, annak a területnek a teljes medencéhez viszonyított arányát, így a validáció tekintetében először ezt határoztam meg (Ratio Of the Vegetated areas and Water basins; ROVW). A ROVW értékek és a POW értékek között fordított arányosság áll fenn.

A ROVW, a vízmélység és a LoSRI értékeket ugyanazon a kettős y-tengellyel rendelkező grafikonon ábrázoltam. A LoSRI és a vízmélység közötti korrelációt Spearman rho értékével is meghatároztam, mivel a LoSRI ordinális változónak tekinthető.

4. Eredmények

4.1. A multispektrális és hiperspektrális felvétel osztályba sorolási hatékonyságának elemzése

4.1.1. A spektrális felbontás szerepe és az optimális spektrális tartomány kiválasztása

A vizsgálat eredményei rávilágítanak arra, hogy a hiperspektrális felvétel esetében SVM-mel osztályozva minimális (0,5%) volt az általános pontosság különbsége, amikor az összes 128 csatornával, illetve a zajos csatornákat kiszűrve, 109 csatornával osztályoztam. A Landsat spektrális tartományát lefedő 47 csatornával osztályozva az általános pontosság 3%-kal lett kisebb a 128 csatornával osztályozott térképhez képest (4. táblázat). A 47 csatornát 4 csatornává átlagolva megkaptam a Landsat BGR+NIR csatornáinak spektrális felbontását, ezzel a 4 átlagolt csatornával osztályozva az általános pontosság 80.5%-ot ért el. A 4 átlagolt csatorna 30 méteres térbeli felbontásúra újrámintavételezve 73,87% általános pontosságot ért el, 6,63%-kal rosszabbat, mint újrámintavételezés előtt, míg az eredeti hét Landsat csatornát SVM-mel osztályozva 81,91%-os általános pontosságot értem el.

RF-fel osztályozva a 128 és 47 csatorna 0,5-1%-kal magasabb általános pontosságot ért el, mint a legjobb SVM osztályozás. 47 csatornával osztályozva (95,5%) 0,5%-kal jobb általános pontosságot értem el, mint a 128 csatornával osztályozva (95%). A Variable Importance analízis esetében 10%-kal jobban teljesített a 16 csatornás osztályozás a 14 csatornás osztályozásnál (5. táblázat). Az alkalmazott osztályozási algoritmusoknak (SVM és RF) nem volt szignifikáns hatása az általános pontosságra, sem a 16, valamint 14 csatorna, sem a 128, valamint 47 csatorna esetében. SVM-mel osztályozva az 59 csatorna, amit a 47, 16, valamint 14 csatorna összevonásával hoztam létre (6. ábra) 1%-kal jobb általános pontosságot ért el (5. táblázat), mint a 128 csatornával osztályozva (4. táblázat).


A multispektrális Landsat felvételt osztályozva 81-82%-os általános pontosságot értem el, több mint 10%-kal rosszabbat, mint a hiperspektrális felvétel esetében. A legpontosabb eredményt az összes csatorna felhasználásával (C+BGR+NIR+SWIR), valamint a „coastal” sáv kihagyásával hat csatornával (BGR+NIR+SWIR) osztályozva értem el (81,91%). A BGR+NIR csatornák a multispektrális szenzorok alapját képezik, habár ezek néhány szenzor esetében, akár csak a Landsat 8 esetében kiegészülhetnek „coastal blue” és/vagy közepes infravörös sávokkal, esetemben a közepes infravörös sávok csak enyhén (0,5%) javították az általános pontosságértékeket, míg a „coastal” sáv nem vezetett jobb osztályozási eredményhez.

4. táblázat. Osztályozási pontosságértékek a 128, 109, valamint 47 csatorna esetében

Szenzor	Eagle		Eagle		Eagle	
Osztályozó	SVM		SVM		SVM	
Bemeneti adat	128 csatorna		109 csatorna		47 csatorna	
Felszínborítás	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)
Erdő	83,61	100,00	82,26	100,00	79,69	100,00
Lágyszárú	100,00	78,00	100,00	76,00	92,31	72,00
Nyílt víz	100,00	100,00	100,00	100,00	100,00	100,00
Vízi veg.	98,08	100,00	98,08	100,00	97,96	94,12
OA (%)	94,50		94,00		91,50	
Kappa	0,93		0,92		0,89	

5. táblázat. Osztályozási pontosságértékek a 16, 14, valamint 59 csatorna esetében


Szenzor	Eagle		Eagle		Eagle	
Osztályozó	RF		RF		SVM	
Bemeneti adat	16 csatorna		14 csatorna		59 csatorna	
Felszínborítás	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)
Erdő	84,48	96,08	64,38	92,16	86,44	100,00
Lágyszárú	95,56	86,00	85,71	72,00	100,00	82,00
Nyílt víz	100,00	100,00	100,00	77,08	100,00	100,00
Vízi veg.	97,96	94,12	100,00	94,12	98,08	100,00
OA (%)	94,00		84,00		95,50	
Kappa	0,92		0,79		0,94	



6. ábra. A különböző input csatornák hullámhossztartománya

4.1.2. Az adat-transzformáció hatása az osztályozási pontosságra

A vizsgálatban részt vevő változók (MNF-csatornák) száma szerepet játszott a pontosság növekedésében, valamint az osztályozásba bevont csatornák eltérő száma eltérő általános pontosságértékekhez vezetett. A 128 hiperspektrális csatorna esetében az első 11 MNF-csatornával osztályozva értem el a legnagyobb általános pontosságot, a 109 csatorna esetében tíz, az 59 csatorna esetében 15, a 47 csatorna esetében hét MNF-csatornával osztályozva értem el a legnagyobb általános pontosságot (7. ábra (a)). A 4 átlagolt sáv esetében négy, a 7 Landsat csatorna esetében pedig szintén négy (7. ábra (b)) MNF-csatornával osztályozva értem el a legnagyobb általános pontosságot. A következőkben ezek vonatkozásában mutatom be az eredményeket.



7. ábra. Különböző számú MNF csatornák felhasználásával elért általános pontosságértékek. A függőleges vonalak mutatják az MNF csatornák számát, amikor elsőnek elérték a maximális pontosságot.


A vizsgálatból kitűnik, hogy az MNF-transzformáció javította az eredményeket, 128, 109, valamint 47 csatornával osztályozva egyaránt 96% általános pontosságot értem el (6. táblázat). A vizsgálat legjobb eredményét (96,5%) az MNF-transzformáción átesett 59 csatornával osztályozva értem el (8. ábra (a); 7. táblázat). Az adat-transzformáció esetében 2-5%-kal javította az általános pontosságértékeket, míg a Kappa koefficiens értékei 0,02 és 0,06 között növekedtek. A 47 újramintavételezett

MNF-transzformált csatornával osztályozva 90,45% általános pontosságot értem el, 0,87 Kappa koefficiens mellett. A 4 átlagolt újrámintavételezett MNF-transzformált csatornával osztályozva 69,85% általános pontosságot értem el, 4,02%-kal jobbat, mint az MNF-transzformáció nélküli 4 átlagolt újrámintavételezett csatorna osztályozásakor.

6. táblázat. Osztályozási pontosságértékek a 128, 109, valamint 47 csatorna esetében Minimum Noise Fraction (MNF) transzformációt alkalmazva

Szenzor	Eagle		Eagle		Eagle	
Osztályozó	MNF+SVM		MNF+SVM		MNF+SVM	
Bemeneti adat	128 csatorna		109 csatorna		47 csatorna	
Felszínborítás	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)
Erdő	87,93	100,00	87,93	100,00	91,07	100,00
Lágyszárú	97,73	86,00	100,00	86,00	93,75	90,00
Nyílt víz	100,00	97,92	97,96	100,00	100,00	97,92
Vízi veg.	100,00	100,00	100,00	98,04	100,00	96,08
OA (%)	96,00		96,00		96,00	
Kappa	0,95		0,95		0,95	

A Landsat esetében is az MNF változókkal értem el a legnagyobb általános pontosságértéket (86,43%, 8. ábra (b); 8. táblázat), 4,52%-kal jobbat, mint adat-transzformáció nélkül. Ezzel szemben az adat-transzformáció nem vezetett pontosabb eredményhez, amikor a 4 átlagolt újrámintavételezett MNF-transzformált hiperspektrális csatornával osztályoztam (69,85%).



8. ábra. A legnagyobb általános pontosságot elért, hiperspektrális adatok (a), valamint Landsat adatok (b) alapján osztályozott felszínborítás térképek

7. táblázat. A legnagyobb általános pontosságot elért, hiperspektrális adatok alapján SVM-mel osztályozott térkép (15/59 MNF csatorna); UA: felhasználói pontosság; PA: előállítói pontosság

Felszínborítás	Erdő	Lágyszárú	Nyílt víz	Vízi veg.	Összes	UA
Erdő (%)	100,00	12,00	0,00	0,00	28,50	89,47
Lágyszárú (%)	0,00	88,00	2,08	0,00	22,50	97,78
Nyílt víz (%)	0,00	0,00	97,92	0,00	23,50	100,00
Vízi veg. (%)	0,00	0,00	0,00	100,00	25,50	100,00
Összes (%)	100,00	100,00	100,00	100,00	100,00	N/A
PA (%)	100,00	88,00	97,92	100,00	N/A	96,50

8. táblázat. A legnagyobb általános pontosságot elért, Landsat adatok alapján SVM-mel osztályozott térkép (4/7 MNF csatorna); UA: felhasználói pontosság; PA: előállítói pontosság


Felszínborítás	Erdő	Lágyszárú	Nyílt víz	Vízi veg.	Összes	UA
Erdő (%)	92,00	8,00	2,08	0,00	25,63	90,20
Lágyszárú (%)	8,00	88,00	20,83	3,92	30,15	73,33
Nyílt víz (%)	0,00	4,00	68,75	0,00	17,59	94,29
Vízi veg. (%)	0,00	0,00	8,33	96,08	26,63	92,45
Összes (%)	100,00	100,00	100,00	100,00	100,00	N/A
PA (%)	92,00	88,00	68,75	96,08	N/A	86,43

4.1.3. Általános és felszínborítási osztály szintű pontosság értékelése

A kutatás során végzett osztályozások pontosságértékeit a 9. ábrán összesítettem a legjobb általános pontosság szerint csökkenő sorrendben, valamint feltüntettem a legrosszabb felhasználói, valamint előállítói pontosságértékeket is, annak érdekében, hogy megmutassam a különböző osztályozási módszerek hatékonyságát. A legjobb négy általános pontosságot elérő osztályozás mindegyike MNF-transzformált hiperspektrális adatokból állt elő. Ezen csatornákból nyert térképek esetében az erdők előállítói pontosság értékei 100%-ot értek el (10-11. ábra), viszont a kategória felhasználói pontosság értékei, a lágyszárú vegetáció előállítói pontosság értékeihez hasonlóan gyengébbek lettek (86-91%). Az eredményekből kitűnik, hogy a nyílt víztestek, valamint a vízi vegetáció esetében mind az előállítói, mind a felhasználói pontosság értékei 96% fölött alakultak (10-11. ábra).

A többi 90% általános pontosság fölött teljesített osztályozások többnyire nem transzformált hiperspektrális adatokból származtak. Az újramintavételezett MNF-transzformált 47 csatorna 90% fölötti általános pontosságot ért el, ez esetben a gyengébb felhasználói pontosságértékek 80% és 92% között alakultak az erdők,


valamint a lágyszárú vegetáció esetében, míg az előállítói pontosság a nyílt víztestek esetében volt gyengébb (72,92%). Az osztályozások szerint a legrosszabb felhasználói pontosságértékek az erdőkhez, míg a legrosszabb előállítói pontosságértékek a lágyszárú vegetációhoz kapcsolódnak (9. ábra), a fentiekben tárgyaltak kivételével.



9. ábra. Az osztályozások során elért legjobb általános pontosságértékek, valamint a leggyengébb felhasználói, valamint előállítói pontosságértékek felszínborítási kategóriáinként (E: Eagle; L: Landsat; szám: csatornák száma; T: MNF-transzformáció; 30: újrámintavételezett; S: SVM; R: RF)

A 80% és 90% közötti általános pontosság értékek magukba foglalják az összes Landsat felvételtől előállított térképet, valamint három hiperspektrális adatot, ezek közül kettő a Variable Importance analízisen átesett 47 csatornából került ki, a másik pedig a 4 átlagolt hiperspektrális csatorna volt (9. ábra). A legmagasabb osztály szintű felhasználói pontosságértékeket az erdők érték el (~93%; 10-11. ábra), míg a legalacsonyabb értékek a lágyszárú vegetációhoz tartoztak (64-66%; 9. ábra). A legmagasabb előállítói pontosságértékeket az erdők, valamint a vízi vegetáció


osztályozása során értem el (84-90%; 10-11. ábra), míg a legalacsonyabb értékek a nyílt víztestekhez köthetők (66-70%; 9. ábra). Általánosságban kijelenthető, hogy a felhasználói pontosságértékek magasabbak voltak az előállítói pontosságértékekhez képest, ezek mellett számos félreosztályozást találtam az erdők és lágyszárú vegetáció, a lágyszárú vegetáció és nyílt víztestek, a nyílt víztestek és vízi vegetáció, valamint a vízi vegetáció és lágyszárú vegetáció között.



10. ábra. Osztályozási pontosságok a felszínborítási osztályok alapján
(szaggatott vonal: 90%-os pontosság)

80% alatti általános pontosságot a 4 átlagolt hiperspektrális csatorna adataiból nyertem (9. ábra). Az MNF-transzformált 4 átlagolt csatorna esetében a

pontosságértékek különösen alacsonyak voltak az erdők felhasználói pontosságértékét (52,58%), valamint a lágyszárú vegetáció előállítói pontosságértékét (18%) tekintve (9. ábra). Ezek mellett kitűnik, hogy a nyílt víztestek felhasználó pontosságértékei, valamint a vízi vegetáció előállítói pontosságértékei 94% fölött teljesítettek (10-11. ábra).



11. ábra. Osztályozási pontosságok a bemeneti csatornák alapján
(szaggatott vonal: 90%-os pontosság)

A vizsgált osztályozások közül a 4 átlagolt újramintavételezett MNF-transzformáción átesett hiperspektrális csatorna teljesített a leggyengébben az általános pontosság tekintetében. A lágyszárú vegetáció felhasználói pontosságértéke 50%-nál, a nyílt

víztestek előállítói pontosságértéke 60%-nál volt alacsonyabb; ez esetben egyik pontosságérték sem érte el a 90%-ot (9. ábra).

Az eredményekből látható, hogy az erdők érték el a legmagasabb előállítói pontosságértékeket (100% a legtöbb esetben), felhasználói pontosság tekintetében a kategórián belül a nagyobb variancia (50-90%) magába foglal két esetet, amikor a 4 átlagolt csatorna esetében különösen alacsony értékeket állapítottam meg (9. ábra). A második legmagasabb előállítói pontosságértékeket (többnyire 90% fölött) a vízi vegetáció esetében értem el, ahogyan ezt a kategória felhasználói pontosságértékeit tekintve is tapasztaltam. Az MNF-transzformált 47, 59, 109, valamint 128 csatornák többnyire rendkívül magas (100%) pontosságértékeket értek el a felszínborítási osztályok szintjén. Míg a nyílt víztestek felhasználói pontosságértékei 85%-nál magasabbak voltak, addig a kategória előállítói pontosságértékei a Landsat felvételek, valamint a 4 átlagolt újramintavételezett csatorna osztályozása esetében alacsonyabb értékeket mutatott (55-75%). A lágyszárú vegetáció osztályozása többnyire magas, 90% fölötti felhasználói pontosságértékeket ért el, egyedül a Landsat felvételek osztályozása esetében teljesített rosszabbul (64-75%). A kategória osztályozása a 4 átlagolt csatorna esetében is rendkívül alacsony előállítói pontosságértékeket ért el (18% és 38%).

A Landsat felvételek esetében mind a felhasználói, mind az előállítói pontosságértékek átlagosnak bizonyultak (9. ábra). A rendkívül alacsony pontosságértékek jellemzően a 4 átlagolt csatornához köthetők. A 128, 109, valamint 59 csatorna osztályozása rendkívül pontos eredményekhez vezetett, mind a felhasználói, mind az előállítói pontosságértékek tekintetében. A 47 csatorna osztályozása változó pontosságértékeket eredményezett, de főleg a lágyszárú vegetáció, valamint az erdők esetében produkált 10-30%-kal gyengébb eredményeket, mint a 128, 109, valamint 59 csatorna osztályozása esetében.

4.1.4. A felszínborítás térképek értékelése tájékológiai szempontból

Az osztályozások eredményeiből látható, hogy a legpontosabban osztályozott felszínborítás térképet az 59 MNF-transzformált hiperspektrális csatornából állítottam elő, míg a Landsat esetében szintén az MNF-transzformáción átesett felvétel bizonyult a legpontosabbnak. A hiperspektrális adatokból előállított felszínborítás térkép 35383 összefüggő felszínborítás foltot tartalmazott, míg a multispektrális adatokból előállított térkép mindössze 223 foltot (9. táblázat). A legkisebb foltméretet mindkét térkép esetében a pixelméret határozta meg ($2,25 \text{ m}^2$ és 900 m^2); az összes foltszámot tekintve a legkisebb foltok mindkét esetben az alsó kvartilis tartományban helyezkednek el, nagyjából 25%-uk (10. táblázat). Habár ez az arány nagyon mondható, a mintaterületből a hiperspektrális felvétel esetében mindössze 0,3%-ot, a Landsat esetében 0,8%-ot tesznek ki az egy pixel méretű foltok. A konzisztens statisztikai számítások érdekében a 900 m^2 -nél kisebb foltokat kiszűrtem a

hiperspektrális felvételtől előállított térkép esetében. A foltméretek eloszlása így függetlenné vált a minimális pixelmérettől, és nem torzította a felső kvartilis tartományt. Így 195 darab 900 m²-nél nagyobb vagy egyenlő folt keletkezett a hiperspektrális felvételtől előállított térkép esetében, melyek a teljes mintaterület 93,73%-át foglalták magukban (9. táblázat).


A 900 m²-nél nagyobb foltok adataiból kivehető, hogy a Landsat felvételtől előállított térkép esetében az egyes felszínborítási osztályokra vonatkozó legnagyobb foltok mérete jellemzően nagyobb, mint a hiperspektrális felvételtől előállított térkép esetében (12. ábra). Az adatsoron elvégzett Mann-Whitney tesztből kiderül, hogy egyedül a lágyszárú vegetáció esetében volt szignifikáns ($p=0,007$) a különbség a két térkép foltméretei között.

9. táblázat. A két legpontosabban osztályozott térkép foltszáma és azok kiterjedése

	Eagle 59 csatorna (MNF)	Landsat 8 (MNF)
Foltszám (összes)	35383	223
Minimum foltméret (m ²)	2,25 (1 pixel)	900 (1 pixel)
Foltszám (foltméret < 900 m ²)	35188 → 0,51 km ² (6,27%)	N/A
Foltszám (foltméret ≥ 900 m ²)	195 → 7,64 km ² (93,73%)	N/A

10. táblázat. A két legpontosabban osztályozott térkép foltméretének kvartilis tartományai, valamint a Landsat és Eagle felvételek 900 m²-nél nagyobb foltjai Mann-Whitney tesztjének eredménye (LQ: alsó kvartilis; Med.: medián; UQ: felső kvartilis; félkövér kiemelés: $p < 0,05$)

	Eagle 59 csatorna (MNF) minden folt			Eagle 59 csatorna (MNF) foltméret ≥ 900 m ²			Landsat 8 (MNF)			Szignifi- kancia (p)
	LQ	Med.	UQ	LQ	Med.	UQ	LQ	Med.	UQ	
Erdő	0,0025	0,002	0,007	1,200	1,800	6,000	0,900	3,600	9,200	0,164
Lágysz.	0,0025	0,004	0,009	1,600	3,300	12,800	0,900	2,700	11,900	0,007
Nyílt v.	0,0025	0,007	0,017	1,400	2,300	6,900	0,900	2,500	8,100	0,415
Vízi v.	0,0025	0,007	0,022	1,900	5,800	26,800	0,900	1,800	7,200	0,131




12. ábra. Foltméretek megoszlása felvételek és felszínborítási osztályok alapján

4.1.5. Vegetációs dinamika

Az alkalmazott „hőtérkép” megközelítéssel vizualizálhatók lettek a kis kiterjedésű sűrű eloszlású vízi vegetációnak, jellemzően a sulyomnak a foltjai, ahol a vízi vegetáció terjedése leginkább jelentős az általános vegetációs dinamikát tekintve. A vizualizáció során az egybefüggő területeket és a nyílt vízterületeket kihagytam az elemzésből. Az eredményeket két csoportba lehet sorolni: (i) az egybefüggő vízi vegetációval borított területek 100 és 200 méteres sugarú területei, valamint (ii) a kisebb vízi utak mentén rendszeresen kaszált/ritkított vízi vegetáció területei, ahol később lineáris mintázatban kezd újra terjedni a vízi vegetáció (13. ábra).

Ezek a kis foltok mindössze kis területet foglalnak el a teljes területből (6,27%), viszont csak a nagyfelbontású hiperspektrális felvételtől nyerhetők ki. Habár a vízi vegetáció a Landsat felvételen is azonosítható, a vegetáció terjedése szempontjából kockázatosnak ítélt területek, beleolvadnak a nagyobb összefüggő foltokba, így a

gyengébb felbontású felvételeken az ehhez hasonló vegetációs dinamika nem tanulmányozható.



13. ábra. A vízi vegetáció sűrű foltjait mutató hőterkép

4.1.6. Eredmények értékelése a multispektrális és hiperspektrális felvétel osztályba sorolási hatékonysága alapján

A kutatás során használt AISA Eagle hiperspektrális szenzor felvétele 128 spektrális csatornát tartalmazott, beleértve a magas jel-zaj aránnyal rendelkező sávokat is. Govender és munkatársai (2008) az input adatok kiválasztásának fontosságára hívták fel a figyelmet; saját eredményeim is rámutatnak annak a fontosságára, hogy az optimális input adatok meghatározásával csökkenthető a bemeneti adatok nagysága. A zajos sávok kiszűrése azonban nem javította a tematikai pontosságot; azt is kimutattam, hogy ha a spektrális tartományt a Landsat-sávok tartományára szűkítjük, a tematikus pontosság nagyobb mértékben csökken (94,50% és 91,50% általános pontosság közé). Ezáltal, figyelembe véve a mintaterületen belüli vízi vegetáció osztályozását, a Landsat felvétel spektrális tartományának alkalmazásával még jobb

geometriai felbontás mellett sem tudtam ugyanazt a tematikus pontosságot elérni, mint az összes csatorna felhasználásával. A Landsat felvétel spektrális tartománya a hiperspektrális szenzor 47 csatornáját foglalta magába; ezek közül meg tudtam határozni a tartomány legfontosabb csatornáit, melyek szignifikánsan hozzájárultak a pontosabb eredmények eléréséhez. Így az itt használt 47 sávhoz hozzáadva a Variable Importance analízis során meghatározott legfontosabb sávokat, így 59 csatornát kaptam. Eredményeim azt mutatják, hogy az általam kidolgozott fúziós eljárás eredményeként létrehozott 59 csatorna bizonyult a legalkalmasabbnak a pontosabb eredmények eléréséhez (95,5% általános pontosság). Ebből 47 csatorna a Landsat hullámhossz-tartományával fed át, továbbá kiegészül további sávokkal az 526 nm és 531 nm közötti, 677 nm és 681 nm közötti, valamint 691 nm és 715 nm közötti hullámhossz-tartományokból, továbbá két diszkrét csatornával 758 nm és 811 nm hullámhosszon (6. ábra).

A nagy mennyiségű adathalmazok esetében a dimenziók számának csökkentésére több ordinációs technika (PCA vagy MNF) áll rendelkezésre, amelyek általában nagyobb pontosságú osztályozást eredményeznek (Koutsias et al. 2009; Mills et al. 2013; Dronova et al. 2015). Az MNF-transzformáció alkalmazása jól teljesített a mi adataink esetében, még akkor is, ha a mindössze hét sávot tartalmazó Landsat felvételt osztályoztam, ebben az esetben 4,52%-os javulást tapasztaltam az általános pontosság tekintetében az eredeti sávokhoz képest. Az eredmények azt mutatják, hogy az MNF-csatornák számának növelése jelentősen magasabb általános pontosságértékeket eredményezett, amikor az első néhány MNF-csatornát vontam be az osztályozásba, de további sávok hozzáadása nem vezetett a pontosság javulásához, inkább csökkenést eredményezett a legtöbb esetben (Tsai et al. 2007). A Variable Importance analízis, valamint az MNF-transzformáció kombinációjával osztályozott 59 csatorna esetében további 0,5%-os javulást tapasztaltam az általános pontosságérték tekintetében (96,5%).

A geometriai felbontás tekintetében a disszertáció eredményei azt mutatják, hogy bár a nagyobb pixelméretetek nagyobb területeket fednek le, és következésképpen a felszíni objektumok spektrális keverékét tartalmazzák, nem ez a fő oka annak, hogy kevésbé pontos osztályozáshoz vezetnek. A Landsat-8 OLI szenzora által lefedett spektrális tartományon belüli 47 MNF-transzformált, 30 méteres térbeli felbontásúra újramintavételezett csatorna 4,02%-kal nagyobb pontosságot eredményezett a legpontosabb MNF-transzformált Landsat-sávokhoz képest (azaz a nagyobb számú szűkebb spektrális csatorna több információt tartalmaz). Ez az eredmény összhangban van Moskal és munkatársai (2001) korábbi munkájával, akik AVIRIS és Landsat TM felvételeket dolgoztak fel; a kutatók szintén kimutatták, hogy a spektrális sávok nagyobb száma a pontosabb osztályozáshoz vezet felégetett területek regenerációjának térképezésekor. Underwood és munkatársai (2007) szintén a nagyobb spektrális felbontású felvételek alkalmazását javasolták, mert ezek még a 4,0 m térbeli felbontású multispektrális társaikhoz képest is nagyobb pontosságot

biztosítanak. Az értekezésben bemutatott vizsgálat során szenzortól függetlenül azonos térbeli és spektrális felbontást generáltam, és azt a következtetést vontam le, hogy az eredeti Landsat-sávok 12,00%-kal jobb eredményt adtak az átlagolt hiperspektrális változathoz képest (9. ábra). Továbbá a nem MNF-transzformált 4 átlagolt csatorna újramintavételezése 4,02%-kal jobb általános pontosságot biztosított, mint az újramintavételezett MNF-transzformált sávok osztályozása önmagában. Természetesen egy nagy geometriai felbontású felvételt ritkán szükséges újramintavételezni, ezzel lerontva annak felbontását, mivel így nemcsak a térbeli felbontásból, de a spektrális heterogenitásból adódó hátrányokkal is szembesülni kell. Disszertációmban kizárólag a 30 méteres geometriai felbontású Landsat felvételekkel történő összehasonlíthatóság miatt alkalmaztam ezt a módszert, és nem a nagyobb általános pontosság elérése érdekében.

Mind a felhasználói, mind az előállítói pontosság széles tartományban mozgott a különböző osztályozásokat tekintve. Ki kell emelni, hogy a vízi vegetációt mind az előállítói pontosság, mind a felhasználói pontosság alapján a legjobb pontosságértékekkel osztályoztam. A Landsat adatok esetében az MNF-transzformáció hozzájárult a legpontosabb eredmény eléréséhez: a C+BGRNIR+SWIR sávok osztályozása 81,91% általános pontosságot, valamint mindössze 67,80% felhasználói pontosságot eredményezett a lágyszárú vegetáció esetében, míg az MNF-transzformáció alkalmazása 86,43%-ra javította az általános pontosság, valamint 73,33%-ra a felhasználói pontosságértéket ugyanezen felszínborítási osztály esetében. A másik csoport, amelyet gyenge teljesítmény jellemez, a 4 átlagolt hiperspektrális csatornához köthető, mivel a feldolgozás során a felvétel információtartalma részben elveszett.

A vizsgálat eredményei azt mutatják, hogy a térképeken található legkisebb foltok némelyike valóban meglévő élőhelyeket tartalmaz, viszont a vizuális kiértékelés során megállapítottam, hogy ezek kisebb arányban a képfeldolgozás során keletkezett zajt is magukban foglalják. Ezért nem alkalmaztam semmilyen szűrést a térképeken, hogy egybeolvasszam őket. Mivel ezek az adatok egyébként is torzítanák a statisztikai kiértékelést, kihagytam a 900 m²-nél kisebb területű foltokat. Az átfogó foltméret-elemzések azt mutatták, hogy a foltok száma a különböző szenzoroktól, valamint a térbeli felbontástól függően eltérőek voltak. Ugyanakkor az összehasonlítható (900 m²-nél nagyobb) területük esetében meglehetősen hasonló volt az eredmény (AISA Eagle: 195 folt, Landsat: 223 folt), és csak a lágyszárú vegetáció foltjai különböztek statisztikai értelemben a két térkép között. Ennek megfelelően a 900 m² alatti foltok a teljes területnek csak 6,27%-át foglalták magukban, ahol a Landsat felvétel nem tudott pontos eredményeket szolgáltatni.

Korábbi munkájukban Dalponte és munkatársai (2012), valamint Lee és munkatársai (2004) is kimutatták, hogy a hiperspektrális felvételek nagyobb pontosságot biztosítanak az osztályozások során, a pontosabb spektrális profil miatt. Ezek összhangban vannak az én eredményeimmel, bár ki kell hangsúlyozni, hogy több

szerző (Moskal et al. 2001; Kumar et al. 2012; Mallinis et al. 2014) is úgy találta, hogy a Landsat felvételek is képesek biztosítani a szükséges tematikus pontosságot az ökológiai vagy tájökológiai vizsgálatokban, ha az elemzés léptéke és célja lehetővé teszi a gyengébb felbontást. Ezzel az eredménnyel egyetértek; a Landsat felvétel megfelelő pontosságot biztosít az általános vízi vegetáció térképezéséhez.

Mivel a vizsgált területen jelen lévő vízi növényfajok mérete kisebb, mint a hiperspektrális légifelvétel pixelmérete, a növényfajok egyedeit nem lehet azonosítani a távérzékelt adatokon. A növények és a nyílt víz arányától függően a vegyesen alkotott pixelek esetén a domináns felszínborítási osztály spektrális jellemzője lesz a meghatározó. Mivel a hiperspektrális felvétel nagy (1,5 m) geometriai felbontással rendelkezett, a vízi vegetáció kisebb foltjai is térképezhetők voltak, így az eredménytérkép alkalmas volt a vegetáció dinamikájának tanulmányozására; azaz a foltok sűrűségét és térbeli mintázatát figyelembe véve előrejelzést lehet számítani arra vonatkozóan, hogy a területük a jövőben növekedni fog. Általánosságban elmondható, hogy mivel a vízi növényzet a legjobb osztályszintű pontossággal azonosítható (9. ábra), ezek a térképek alapul szolgálhatnak a Kiskörei víztározó kezelésének tervezéséhez, a vízminőség fenntartásához, valamint a vízi vegetáció esetleges ritkításához.

Összefoglaltam a légi hiperspektrális és a műholdas multispektrális felvételek előnyeit, valamint hátrányait a vizes élőhelyek térképezése kapcsán (11. táblázat). A légi felmérés költségeit pontosan ki lehet számítani a repülőtér és a célterület közötti távolság, valamint a vizsgált terület méretétől függően. A felmérés eredménye egy nagyméretű felvétel, amelynek kiértékeléséhez nagy számítási kapacításra, specifikus szoftverre és üzemeltető, valamint kiértékelő személyzetre van szükség. Ezzel szemben a Landsat felvételek ingyenesen hozzáférhetők, továbbá az osztályozáshoz elegendő lehet egy hagyományos számítógép is, emellett a legtöbb nyílt forráskódú, vagy kereskedelmi szoftver képes az adatok hatékony feldolgozására. A költségeket, valamint az előnyöket ökológiai szemszögből vizsgálva arra az eredményre jutottam, hogy a Landsat felvételek alkalmasak a nagyobb víztestek nyílt vízfelületének és vízi vegetációborításának térképezésére, azonban nem alkalmazhatók a fajszintű információk feltárására, beleértve az egyed azonosítást vagy a vegetációs dinamikát. A hiperspektrális adatok alkalmasak a fajszintű osztályozásra, sőt megfelelő térbeli felbontás mellett a fajok dinamikáját is ki lehet mutatni. A Sentinel-2 műholdak felvételeinek 10-20 méteres geometriai felbontása bár lényegesen jobb a Landsat felvételeknél, a vegetációs dinamika térképezésére csak korlátozottan lehetnek alkalmasak, évtizedeket átölelő vizsgálatokhoz pedig még nem áll rendelkezésre elegendő felvétel.


11. táblázat. A hiperspektrális és multispektrális felvételek összevetése ökológiai felhasználás szempontjából

Tulajdonságok	AISA Eagle	Landsat 8 OLI
Geometriai felbontás (m)	1,5	30
Csatornák száma	128	9
Sávszélesség (nm)	5	15-84 (átlag = 47)
Ár	Magas	Ingyenes
Kiterjedés (km ²)	Kis/közepes (10-1000)	Regionális/országos (10-100000)
Felszínborítás osztályozása	Igen	Igen
Fajszintű térképezés	Igen	Nem
Vegetációs dinamika vizsgálata	Igen	Nem

4.2. Hosszútávú vegetáció-változás monitoring spektrális indexek alkalmazásával

4.2.1. Az éves vegetációs dinamika meghatározása

A vizsgálat során a vegetációs maximumot kerestem, ahol az NDVI értékek a legnagyobbak és a lehető legkisebb varianciával bírnak. Az itt bemutatott adatok az NDVI értékek változásait szemléltetik 2015 májusa és szeptembere közötti időintervallumban (14. ábra). Az adatok alapján minden tómedence esetében hasonló a vegetációs periódus karakterisztikája, július 5-ét követően a vegetáció minden tómedencében elérte a legnagyobb kiterjedését és sűrűségét, melyet a magas NDVI értékek igazolnak, ezek közül is legtöbb esetben az augusztus 4-ei időpontban volt a vegetációs maximum. A szeptember 4-ei felvételen a vegetáció már kezd elhalni. Ezek alapján a további vizsgálatok esetében a felvételek kiválasztásához legjobb a július 28. és augusztus 11. közötti időszak.




14. ábra. 2015-ös pozitív NDVI értékek a 10 medence esetében

4.2.2. A vízi vegetáció dinamikája 1984 és 2017 között


A 1984 és 2017 közötti NDVI-értékek szórása (minimum, medián, maximum) alapján három medencetípust különböztettem meg (15. ábra). Ezek közül az elsőbe az 1., 2. és 5. medence került, mivel itt az NDVI-értékek csökkenő tendenciát mutattak 1984 és 2015 között, majd 2015-től ismét növekedtek. A vizsgált időszak alatt is voltak ingadozások, de ez a növekedés az 5. számú medence esetében volt jelentős, ahol az NDVI mediánja 0,5 fölé emelkedett, ami kiterjedt vegetációborításra utal. A második medencetípust a 3., 4., 6., 7. és 9. számú medencék alkották; ezen medencék NDVI-értékei a vizsgált időszak alatt általában növekvő tendenciát mutattak, amelyek telítési görbék alakját öltötték. Az adatok azt mutatták, hogy 1984 és 1987 között az NDVI-értékek csökkentek, majd 1987 és 2000 között egy meredek görbét követve növekedni kezdett, mielőtt az értékek stagnálást vagy enyhe csökkenést mutattak volna. A 8. és 10. medence a harmadik típust képviselte, ahol az NDVI-értékek nem mutattak határozott tendenciát, és a mediánok széles tartományban ingadoztak, még az egymást követő években is. Az összes medencét tekintve a 2010-es év volt kiemelkedő, mivel itt az NDVI-értékek a többi évhez képest alacsonyok maradtak.

Ezután megismételtem az elemzéseket a nyílt vízfelületeken ($MNDWI \geq 0$), valamint a vízi növényzettel borított területeken ($MNDWI < 0$). Ezen elemzés eredményei lehetővé tették számomra, hogy a nyíltvízi NDVI-értékekben két tendenciát különböztessenek meg (16. ábra), amelyek között lényeges különbségek vannak. Az első típusba az 1., 2., 4. és 5. számú medencéket soroltam, ahol csökkenő tendenciát fedeztem fel az NDVI-értékekben, valamint növekvő értékeket az utolsó három évben, 2015 és 2017 között. A legtöbb évben azonban az NDVI-értékek nulla alatt maradtak, azaz vegetációmentes nyílt vizet jeleztek. A második típus (3., 6., 7., 8., 9. és 10. számú medencék) a legtöbb évben magasabb NDVI-értékeket és pozitív mediánokat mutatott. A 3., 6., 7. és 8. számú medencék mind növekvő tendenciát mutattak az NDVI-értékekben 1984 és 2000 között. A 9. és 10. számú medencékre stagnáló, de ingadozó tendencia volt jellemző.


A növényzettel borított területek esetében az NDVI-értékek statisztikai elemzése alapján nagyon hasonló tendenciákat fedeztem fel a medencék között (17. ábra), ezért nem tudtam elkülöníteni a különböző medencetípusokat. Az NDVI-értékek növekvő tendenciát mutattak, két minimumponttal 1984-ben és 2010-ben. A 2014-es évet követően az NDVI-értékek nagyon enyhe csökkenő tendenciát mutattak.



15. ábra. A 10 medence NDVI értékei 1984 és 2017 között



16. ábra. A 10 medence NDVI értékei a nyílt vízfelületek esetén ($MNDWI \geq 0$) 1984 és 2017 között




17. ábra. A 10 medence NDVI értékei a vegetációval borított területek esetén (MNDWI < 0) 1984 és 2017 között


4.2.3. A nyílt víztestek arányának változása

A nyílt víztestek százalékos aránya alapján öt különböző típusba sorolhatók a medencék (18. ábra). Az első típusba (i) az 1. számú medence sorolható, ahol összességében enyhe csökkenés volt tapasztalható, és a nyílt vízfelületek kiterjedése 2010-ben érte el a maximális értékét. Ez a kiemelkedő év minden medencében megfigyelhető volt. A második típust (ii) a 2. és az 5. számú medencék alkották. 1984 és 2005 között csökkenő tendencia volt megfigyelhető, majd a nyílt víztestek aránya 2010-ig növekedett, mielőtt csökkenő tendencia kezdődött volna. Ezen típusba tartozó medencék esetében a nyílt víztestek aránya minden esetben 50% felett mozgott. A harmadik típusba (iii) 3., 6. és 7. számú medencék tartoztak. A trend ebben az esetben is hasonló volt, mint a (ii) típusnál, bár a nyílt víztestek minimális százalékos értékei 2000 és 2005 között megközelítették a nullát. A negyedik típusba (iv) a 9. számú, míg az ötödik típusba (v) a 8. és 10. számú medencék sorolhatók, a trend mindkét típus esetében hasonló volt a (iii) típusban megfigyeltékhez, viszont itt az arányok kisebb szórást mutattak, valamint a minimumértékek nem közelítették a nullát.


Ezt követően összesítettem a vegetációval borított területeket a teljes idősor viszonylatában (19. ábra). Figyelembe véve a vegetációborítás gyakoriságának medián értékeit (20. ábra), két csoportot különítettem el: 3 alatti értékhez az 1., 2., 5., 8. és 10. számú medencék tartoztak, ahol a vízi vegetáció térnyerésének kockázata alacsonyabb, míg a második csoportba a 10 feletti medián értékkel rendelkező medencék (3., 4., 6., 7. és 9.) tartoztak. Ebben a csoportban a vegetáció térnyerésének nagyobb a kockázata.



18. ábra. A nyílt vízfelületek százalékos arányának (POW) változása a 10 medencén belül 1984 és 2017 között



19. ábra. A vegetációborítás gyakoriságát ábrázoló térkép




20. ábra. A vegetációborítás gyakorisága medencénként

4.2.4. A POW és a vízszint kapcsolatának összefüggései

A vízszint 1984-ben és 1985-ben 665 cm, illetve 685 cm volt, míg az ezt követő években 727 cm körülire emelték. Ezért 1984-et és 1985-öt témavezetőm javaslatára kizártuk a statisztikai elemzésből, hogy elkerüljük a téves következtetéseket. A júliusi vízszint és a POW értékek közötti korrelációs együtthatók értékei 0 és -0,53 közé estek, habár ezek a kapcsolatok az alacsony mintaszám következtében nem voltak szignifikánsak (21. ábra). Így ezeket az eredményeket nem tekinthetjük pontosnak és reprezentatívnak. A POW és vízszinthez kapcsolódó alacsony variancia továbbra is jelentéktelen, míg a vizsgált medencék vízszintértékei közötti viszonylag nagy korreláció (~0,50 és 0,94 között) azt jelzi, hogy a vízszint a teljes tározón belül nagyon hasonló. Az egyetlen kivételt a 8. és 10. számú medencék jelentették. Mindkét

medence lefűződött holtág, amelyek helyzetüket tekintve meglehetősen elszigeteltek, és amelyek vízháztartása valamelyest független a szabályozott vízszinttől.



21. ábra. A vízszint és a POW korrelációja (a fehér értékek nem szignifikánsak)

4.2.5. A feltöltődés kockázatának térképezése

Ebben az elemzésben a LoSRI-index alapján különböző mértékben veszélyeztetett medencéket osztályoztam (12. táblázat). Az eredmények azt mutatják, hogy a kevésbé veszélyeztetett csoportba az 1., 2. és 5. számú medencék tartoznak, amelyek elég nagyok és mélyek ahhoz, hogy megakadályozzák a vízi vegetáció, köztük a sulyom megtelepedését. Ezekben a medencékben az átlagos NDVI-értékek alacsonyak voltak (0,15-nél kisebbek), és különösen az 1. és 2. számú medencékben magas volt a nyílt víztestek aránya (65%-nál nagyobb). Azt is kimutattam, hogy a 4., 8. és 10. számú medencék átlagos NDVI-értékei közepesek (0,3-0,4), míg a 8. és 10. számú medencék

35% feletti POW-értékekkel rendelkeztek. Ezekre a medencékre nem volt nagy hatással a szukcesszió. A mintaterületen a 3., 6. és 7. számú medencék voltak a legveszélyeztetettebbek. Ezekben a medencékben az NDVI-értékek rendkívül magasak voltak (mindegyik nagyobb, mint 0,45), és a 2000-es évek elején egyes években a nyílt vízfelületek százalékos értékei majdnem nullára csökkentek. Ezeket a vízgyűjtőket érintette leginkább a szukcesszió. A 9. számú medence szintén magas átlagos NDVI-értékkel (0,51) rendelkezett a vizsgált évek során. Ez a medence egy korábban lefűződött meander volt, akárcsak a 8. és 10. számú medence, így ezek mélyebbek voltak, és ennek következtében a vízi növényzet nem tudott akkora mértékben elterjedni. A vizsgált utolsó években azonban a 9. számú medence nyílt vízfelületének aránya átlagosan 20%-ról 13%-ra csökkent, ezért érdemes ezt a medencét is veszélyeztetettnek minősíteni.


12. táblázat. A veszélyeztetettségi faktorok értékei

Medence	Veszélyeztetettségi faktor		
	VDF	OWFF	LoSRI
1	1	1	2
2	1	1	2
5	2	2	4
8	4	2	6
10	4	3	7
4	4	4	8
9	6	5	11
3	5	6	11
6	5	6	11
7	5	6	11

4.2.6. Az eredmények validálása

A LoSRI-t a jövőbeli változások előrejelzésére fejlesztettem ki, beleértve a vízi vegetáció terjedését is. Az összes mintát figyelembe véve a Spearman-féle korreláció 0,6 ($p < 0,05$) volt a LoSRI és az átlagos vízmélységértékek között. Az átlagos vízmélység a legnagyobb medencékben (1. és 2. számú) kevesebb volt, mint 1,4 m, míg a nyílt víztestek ezekben a medencékben 1,4 m és 1,6 m átlagos mélységűek voltak (22. ábra). Ezekben a medencékben a ROVW-értékek is kicsik voltak (13,49% és 37,58%), és a legalacsonyabb LoSRI-értékek (2) is ezek közül kerültek ki. A nyílt víztesteket tekintve az egykori lefűződött meanderek (3., 8. és 9. számú medencék) rendelkeztek a legnagyobb átlagos vízmélységgel (>1,85 m), ennek ellenére az alacsony POW és a magas ROVW-értékek (>51,97%) miatt ezeket a medencéket nagy mértékben veszélyezteti a szukcesszió, különösen a 3. és 9. számú medencéket,

ahol a ROVW-értékek 86,33%-nál nagyobbak. A LoSRI-értékek ebben az esetben szintén magasak (11) voltak. A 6., 7. és 10. számú medencék átlagosan 0,55 és 0,72 m közötti sekély vízmélységgel rendelkeztek. A 6. és 7. számú medencék ROVW-értékei 94% felett alakultak. Ezekben a medencékben a LoSRI-értékek is nagyon magasak (11) voltak; a 7. számú medencét teljes mértékben vegetáció borította, míg a 6. számú medencében minimális nyílt vízfelület és alacsony (0,44 m) vízmélység volt meghatározó. Bár a 10. számú medence egy korábbi meander volt, átlagos mélysége mindössze 0,6 m. Ez a medence 56,76%-os ROVW-értékkel és 7-es LoSRI-értékkel rendelkezett.



22. ábra. Vízmélység (bal y-tengely) és LoSRI (jobb y-tengely) értékek medencénként (x-tengely felső számok), valamint a teljes idősor 90%-ában vegetációval borított területek teljes medencéhez viszonyított százalékos aránya (x-tengely alsó értékek)

4.2.7. Eredmények értékelése a Tisza-tó hosszútávú vegetáció-változás monitoringja alapján

A vízmélység meghatározása kihívást jelentő feladat, azonban a vízmélység sok esetben összhangban van a növényzet terjedésével, mivel a sekélyebb víz számos növényfaj számára kedvezőbb, így a vízi vegetáció jelenléte a vízmélység bioindikátora is lehet. Ezért az NDVI hatékony eszköze lehet a vegetációterjedés monitorozásának, valamint a feltöltődés nyomon követésének. A Tisza folyó nagy mennyiségű lebegő hordalékot szállít (Bogárdi 1971), amely a változó áramlási viszonyok miatt a Tisza-tó medencéin belül lerakódik. A duzzasztómű hatására a medencékben minimális a víz áramlása, így az üledék lerakódik, ami kedvező a vízi növényzet (főként a sulyom), valamint a sekély vizekre jellemző fajok (pl. nádas) megtelepedéséhez és terjedéséhez. Ennek következtében a tó elveszíti a nyílt vízfelületeket (Laczi et al. 2018; Szabó et al. 2019). Jelen vizsgálat során a megállapított trendek nem jeleztek súlyos veszélyeztetettséget. A vízi vegetáció, valamint a part menti lágyszárú vegetáció nem mutattak intenzív terjedésre utaló jeleket, azonban azt tapasztaltam, hogy a POW-értékek az áradások miatt akár 50%-kal is ingadozhatnak (18. ábra). A vízi vegetáció kaszálása, illetve a nagy árvizek alkalmával beálló magasabb vízszint (pl. 2010-ben) a vegetációs periódus elején akadályozták a vízi növényzet terjedését. A növények nem tudtak kihajtani, és ez negatív anomáliát okozott az NDVI-értékekben (15-16. ábra). A feltöltődés hosszú távon továbbra is a tározó létét veszélyeztető probléma, ahol a lefűződött holtágak is veszélynek vannak kitéve (Lóczy 2012).

Meghatároztam az NDVI-értékeket a 10 medencében, és az MNDWI-index alapján medencénként elkülönítettem a nyílt víztesteket és a vegetációval borított területeket. A megfigyelt NDVI-értékek dinamikája alapján a vizsgált területen belül három típusba soroltam a tómedencéket, összhangban a kiterjedéssel és a mélységgel. A nagy medencéket nyílt vízfelületek, mély víz és minimális vegetációborítás jellemezte. A kisebb medencék lefűződött holtágakat és korábbi csatornákat tartalmaztak, itt fordultak elő a legnagyobb vízmélységek is. Ezek a kisebb medencék változatos, de többnyire pozitív NDVI értékekkel rendelkeztek, nagyobb variancia mellett. A sulyom 2 méternél sekélyebb vízszintet igényel, így a sekélyebb (<1,3 m) medencékben nagy területeket foglalt el. A vegetációval borított területeket kizárva az NDVI-értékek alapján, két medencetípust különítettem el mennyiségi különbségek alapján. Az 1., 2., 4. és 5. számú medencék többnyire nulla alatti NDVI-értékekkel rendelkeztek, ami azt jelenti, hogy nagyobb volt a nyílt víztestek aránya, mint a többi medence (3., 6. és 10. számú) esetében. A vegetációval borított területekre vonatkozó NDVI vizsgálatok (17. ábra) alapján mindössze egy típust sikerült meghatározni, ami azt jelzi, hogy a növényzettel borított területek dinamikája homogénnek tekinthető.

A POW-értékek alapján elkülönített öt medencetípus az NDVI-hoz képest nagyobb eltéréseket eredményezett. A vizsgálatból az is kiderült, hogy az MNDWI hatékony eszköznek bizonyul a POW-értékek meghatározásához, valamint az NDVI-vel együtt

lehetővé teszik, hogy a medencéken belüli vegetációval borított területek minőségi állapotáról is információt tudjunk adni. A vizsgált évek során a medencék vegetációborításának állapota a szukcesszió trendjére utal.

Bár korábbi tanulmányok már megállapították az NDVI és a vízszint közötti összefüggést (Omute et al. 2012), ebben a vizsgálatban nem tudtam megerősíteni ezt a kapcsolatot. Közismert, hogy az üzemi vízszint a tényleges gazdálkodási céloknak megfelelően változik; ezt a szintet 1984 és 1986 között 60 cm-rel emelték. Az 1984-es és 1985-ös adatokon elvégzett korreláció vizsgálata szignifikáns negatív kapcsolatot mutatott ki, az r értékek $-0,7$ és $-0,9$ között voltak. Ez azt jelzi, hogy a magasabb vízszintek jó kapcsolatban álltak a kisebb POW-értékekkel. Ennek magyarázata két okból is összetett: egyrészt a tározó működésének kezdetén a vízi növényzet jelenléte nem volt jellemző, másrészt pedig a magasabb vízszintek akadályozták a sulyom terjedését, amely a leginkább jelentős faj a vízi vegetáció terjedését illetően. A POW-értékeknek magasabb vízszintek esetén magasabbnak kell lenniük, ha minden más körülmény változatlan marad. A POW és a vízszint közötti korreláció 1984 és 1985 kivételével szignifikáns maradt, $r > 0,5$; ez az egyik következménye a vízszintértékek alacsony varianciájának (szórás: 5,4 cm). 2002-ben egy további töréspontot figyelhetünk meg, amikor a vízszint további 10 cm-t emelkedett.

Hummel és Kiviat (2004) tanulmánya kimutatta, hogy 2 m-es vízmélységben a sulyom a legelterjedtebb növény. A jövőbeli kutatásoknak a lágyszárú és vízi vegetációt is figyelembe kell venniük, de eredményeim azt mutatták, hogy a vegetációval borított területeken az átlagos vízmélység $0,88 \pm 0,47$ m. Ez azt jelenti, hogy a növényzet könnyen elterjedhet a medencék hasonló mélységű részein. A nyílt vízfelületek esetében az átlagos vízmélység $1,52 \pm 0,33$ m-en belül maradt. A vízi vegetáció – esetemben a domináns sulyom – jelenléte a vízmélységtől függ, amelyet két kulcsfontosságú paraméter befolyásol: a szabályozott vízszint és a feltöltődés. Sikerült tehát kimutatnom, hogy a vízi vegetáció hatékony indikátora a vízmélységnek.

Az NDVI- és POW-értékek alapján egy-egy hatfokozatú veszélyeztetettségi faktort állítottam elő, amelyeket minden medencéhez hozzárendeltem. Az így kapott értékek összegzéseként állítottam elő a LoSRI feltöltődés-veszélyeztetettségi indexet. A vizsgált medencéken belül a LoSRI és az átlagos vízmélység közötti korreláció 0,6 volt ($p < 0,01$). Ez az eredmény azt jelenti, hogy a LoSRI közvetett információt nyújthat a vízmélységről, csupán a műholdfelvételek alapján, mivel az NDVI a medencék állapotát és a biomassza mennyiségét, a POW pedig a nyílt vízfelületek százalékos részarányát értékeli. Ezek a tényezők részben a vízmélység következményei. A ROVW-értékeket azért is figyelembe kell venni, mert egy sekély vízzel rendelkező medence is tartalmazhat nagy nyílt vízfelületet a kezelés, egy korábbi meander jelenléte vagy az adott medence medermorfológiai jellemzői miatt. A LoSRI és a ROVW együttesen előre jelzi egy adott medence szedimentációs

állapotát. Meg kell jegyezni, hogy a LoSRI és a vízmélység közötti korreláció ($r = 0,6$) mérsékelt volt. Ez a mérsékelt szintű korreláció annak tudható be, hogy a vízmélység csak a tómeder aktuális állapotát tükrözte (egyetlen 2017-es felmérés), míg a LoSRI-t egy 33 évet felölelő idősorozat 20 műholdfelvételéből számítottam ki. Ezenkívül a tó folyamatos vízszintszabályozás alatt áll, továbbá egyes területeken a vízi vegetációt gépekkel kaszálják.

A LoSRI hatékony mutató lehet a legtöbb tómedence esetében. A holtágak és a korábbi folyómedrek esetében azonban, ahol a medence területe kisebb és a vízmélység jelentősen nagyobb lehet, a LoSRI túlbecsüli a kockázatot, mivel a mélyebb belső részek nem veszélyeztetettek, csak a part menti területek. Ez lehet a helyzet a 8., 9. és 10. számú medencék esetében, ahol a vízmélység nagyobb, valamint a víz gyors mélyülésevel csak a litorális zónában jelenhet meg a vegetáció, az ilyen területeken a szukcessziós folyamat viszonylag hosszú ideig tart. Ezért ezekben az esetekben a LoSRI-index mellett vegetációs gyakorisági térképet is használni kell. Az MNDWI vízindex alapján elkülönített nyílt vízfelületek, valamint vegetációval borított területek alapján a 20 műholdfelvétel összesített bináris rétegének ábrázolása a vegetációborítás gyakoriságáról adott képet, mely alapján lehetőséget kaptam a térbeli értékelésre. Ez a megközelítés segít azonosítani azokat az állandó nyílt víztesteket, amelyeket jelenleg nem veszélyeztet a szukcesszió, és ehhez mindössze az adott területről készült műholdfelvételekre van szükség, további bemenő adatok nélkül. Ez a módszer ezért hatékony, és bármikor gyorsan alkalmazható egy adott területre, ahol szukcesszió gyanúja merül fel.

Kiage és Douglas (2020) szintén alkalmazta az MNDWI, valamint NDVI indexeket, és úgy találták, hogy az MNDWI megbízhatóbb eredményeket ad az NDVI-hoz képest; a saját módszertanomban az MNDWI-t a vízfelületek azonosítására, az NDVI-t pedig a vegetáció értékelésére használtam. Kutatásomat további szerzők eredményeinek hasonlóságaival vagy különbségeivel összehasonlítani azonban nehéz, mivel a tavakkal és vizes élőhelyekkel foglalkozó tanulmányok általában vízgyűjtő szinten vagy nagyobb területeken készülnek, és a céljuk a felszínborítás változásának és következményeinek feltárása (Were et al. 2013; Degife et al. 2019; Kangabam et al. 2019).

A szedimentáció jelentős hatást gyakorol a tavak szukcessziójára a lebegő üledék lerakódása révén, ami a vízi vegetáció számára élőhelyet biztosít, amelyek maguk is felgyorsítják a feltöltődést. Ezért kulcsfontosságú, hogy elegendő információval rendelkezünk a vízmélységről. A legtöbb esetben a hatóságok és a tavak fenntartói egyszerűen nem rendelkeznek elég részletes információval a tavak és medencéik medermorfológiai viszonyairól, és ezt még szonár eszközökkel is nehéz meghatározni, mivel a mélység az üledékképződés miatt folyamatosan változik. A műholdak információt szolgáltatnak a vegetáció térbeli kiterjedéséről és dinamikájáról. A felvételek alkalmazását kiegészíthetjük terepi felmérésekkel, az így összegyűjtött információ lehetővé teszi a teljeskörű kockázati térképezést. Az általam

kidolgozott módszer sekély tavak esetében is működhet, viszont a helyi viszonyok ismeretét, ezen belül a növényfajok ismeretét igényli, emellett hosszútávon elérhető műholdfelvételeket igényel. Ezek a követelmények, valamint az új megközelítés azt eredményezi, hogy a sekély víztestek helyzetét, valamint az üledékképződés mértékét kizárólag műholdfelvételek segítségével meg lehet becsülni. Bár a kutatás validálása csak mérsékelt korrelációkat eredményezett, jobb eredményeket lehetne elérni olyan víztestek esetében, ahol a vízszint természetes, és a vegetációt nem kezelik. Esetemben fontos volt a vegetáció terjedésének fókuszpontjait megtalálni. Az állandó nyílt vízfelületek, valamint a vegetáció borítottságának változásai együttesen jó kockázati indikátoroknak minősülnek. Kutatásom eredménye egy lehetséges megközelítést javasol a vízügyi igazgatóságok számára, annak érdekében, hogy a veszélyeztetett területekre összpontosíthassanak.

5. Összefoglalás

Doktori értekezésemben egyrészt hiperspektrális (AISA Eagle) és multispektrális (Landsat-8 OLI) felvételek összehasonlító elemzésének eredményeiről számoltam be, és értékeltem az osztályozási pontosság növelésének lehetőségeit. Kimutattam, hogy több spektrális csatorna általában jobb eredményt ad, de mind a túlillesztés, mind a nagyszámú csatornához kapcsolódó korrelációs problémák ronthatják a pontosságot. Ezt támasztják alá a 47, 109, valamint 128 hiperspektrális csatornával osztályozott térképeim általános pontosságértékei, ahol rendre növekvő 91,5%, 94%, valamint 94,5% pontosságot értem el. A Random Forest osztályozáshoz kapcsolódóan a Variable Importance analízis során meghatároztam azt a 14, valamint 16 csatornát, amelyek szignifikánsan hozzájárulnak a nagyobb pontosságértékek eléréséhez, ezeket a csatornákat a későbbiekben is felhasználtam, bár a Random Forest osztályozóval ezek esetében változó általános pontosságértékeket értünk el (84% és 94%). Eredményeim azt mutatják, hogy az újonnan kidolgozott fúziós eljárás eredményeként létrehozott 59 csatorna (ebből 47 a Landsat hullámhossz-tartományával fed át, továbbá kiegészül a Variable Importance analízis során meghatározott további sávokkal az 526 nm és 531 nm közötti, 677 nm és 681 nm közötti, valamint 691 nm és 715 nm közötti hullámhossz-tartományokból, továbbá két diszkrét csatornával 758 nm és 811 nm hullámhosszon) bizonyult a legalkalmasabbnak a legjobb eredmények eléréséhez (95,5% általános pontosság). Esetemben az MNF-transzformációval végzett ordináció bizonyult a leghatékonyabb eszköznek a bemeneti csatornák számának csökkentésére és a magyarázott variancia maximális szinten tartására, mivel a 47, 109, valamint 128 csatorna esetében egyaránt 96% általános pontosságot értem el. A Variable Importance analízis, valamint az MNF-transzformáció kombinációja további 0,5%-os javulást eredményezett az általános pontosságérték tekintetében (96,5%). Az osztályozásba bevont MNF-csatornák számának növelése az első néhány változó bevonása során szignifikánsan növelte az általános pontosságot, de a maximális pontosságérték elérése után még több változó bevonása nem eredményezett további javulást. A Landsat felvétel esetében az MNF-transzformáció szintén hozzájárult a tematikus pontosság 86,43%-ra történő javításához (81,91%-ról). Érdemes kiemelni, hogy a vízi vegetációt mind az előállítói pontosság, mind a felhasználói pontosság alapján a legjobb pontosságértékekkel osztályoztam. Ezek az eredmények amellet, hogy fontosak a kutatók számára, támogatják és elősegítik a szakemberek munkáját a Tisza-tó fenntartásának hosszú távú tervezéséhez. A tájökológiai szempontokat a felszínborítási foltok révén figyelembe véve azt állapítottam meg, hogy a 900 m²-nél nagyobb területű foltok statisztikailag nem különböztek (kivéve a lágyszárú vegetációt) a multispektrális műholdfelvételekből és a hiperspektrális légifelvételtől származtatott két legpontosabb térképen. A 900 m²-nél kisebb foltok a terület 6,27 százalékát tették ki, azaz a Landsat felvételek erre a területre nem tudnak a térbeli felbontásból adódóan pontos eredményeket biztosítani. Ennek megfelelően az ökológiai vizsgálatokban, ahol a cél alacsonyabb felbontást is lehetővé tesz, a

Landsat-felvételek jól alkalmazhatók, és a legrelevánsabb információk (mint a felszínborítási osztályok) megfelelő pontossággal kinyerhetők belőlük.

Doktori értekezésem másik fő területét a hosszútávú (1984-2017), Landsat felvételek spektrális indexein alapuló vegetációváltozás-vizsgálat tette ki a Tisza-tó térségében, azzal a céllal, hogy meghatározzam, van-e bármilyen trend a vegetáció terjedésében a Tisza-tavat alkotó részmedencék (10 vizsgált tómedence) esetében. Ehhez kapcsolódóan módszertant dolgoztam ki azon medencék azonosítására, ahol a szedimentációval összefüggésbe hozható vegetáció terjedése kockázatot jelent. A Tisza-tó területén belül 10 részmedencét különítettem el terepi felmérés, a rendelkezésemre álló légifelvételek és topográfiai térképek segítségével. A felvételek kiválasztása előtt meghatároztam az éves vegetációs dinamikát egy 2015-ös idősor alapján. A vizsgált hat felvétel alapján a további elemzésekhez július 28. és augusztus 11. közötti felvételeket választottam, ahol az NDVI értékek a legmagasabb értéket mutatták a legkisebb variancia mellett. A területről 1984 és 2017 között 20 felhőzetmentes felvétel állt rendelkezésre. Meghatároztam az NDVI-értékeket a 10 medencében, és az MNDWI-index alapján medencénként elkülönítettem a nyílt víztesteket és a vegetációval borított területeket, így ezeket a területeket külön külön is értékeltem az NDVI viszonylatában. Továbbá meghatároztam a nyílt víztestek százalékos arányát is medencénként. Az eredmények lehetővé tették, hogy az NDVI- és POW-értékek alapján egy-egy hatfokozatú veszélyeztetettségi faktort alkossak, amelyeket minden medencéhez hozzárendeltem. A LoSRI index értékeket ezt követően ezekből az adatokból összegeztem. A vízszint- és vízmélységértékek összhangban voltak az eredményekkel. A kevésbé veszélyeztetett medencék a nagyobb kiterjedésű medencék voltak, alacsony NDVI, valamint magas POW-értékekkel, míg a leginkább veszélyeztetettek a kisebb, vagy vegetációval borított területek voltak, magas NDVI, valamint alacsony POW-értékekkel. Ezek a medencék különleges kezelést igényelnek. A validálás megmutatta, hogy a LoSRI általános használatának vannak korlátai, de a mérsékelt összefüggés azt jelezte, hogy gondos értelmezéssel megbecsülhető a szedimentáció kockázata. Az MNDWI vízindex alapján elkülönített nyílt vízfelületek, valamint vegetációval borított területek alapján a 20 műholdkép összesített bináris rétegének ábrázolása a vegetációborítás gyakoriságáról adott képet, mely alapján lehetőségem nyílt a térbeli értékelésre. A vegetációval borított területek esetében a határértéket 90 százalékban állapítottam meg, azaz ahol a 20 időpontból legalább 18 esetben vegetációborítás volt az adott területen. Az eredmények validálásánál ezt a mérőszámot is figyelembe vettem. Mivel a Tisza-tó rendszeres emberi beavatkozásnak van kitéve (mesterséges vízszintszabályozás, mederkotrás, vízinövények kaszálása), a medencék időbeli és térbeli tendenciái nem voltak egyértelműek. Ez a módszer nagy tavak esetében is alkalmazható a feltöltődés azonosításának elősegítésére, de korlátozottan alkalmazható olyan sekély tavak esetében, amelyekben a sekély vizeket kedvelő vegetáció jelen van. Mindent összevetve, kizárólag távérzékelt adatok alapján, ha a fent említett körülmények fennállnak, a feltöltődés kockázata feltárható.

Summary

In my doctoral thesis I investigated the Kisköre Reservoir according to the sedimentation processes and the dynamics of local vegetation and established the methodological basis for the observations using multispectral and hyperspectral remote sensing datasets. The Kisköre Reservoir, i.e. the Lake Tisza is the second largest lake in Hungary. It is an artificial lake, which was established in 1973 and since then it became one of the most important wetland in Hungary based on its ecological diversity and touristic importance. The most important problem of the lake is the sedimentation of the sub-basins and the spread of the aquatic vegetation, the water caltrop (*Trapa natans*) which is the most common aquatic vegetation species over the reservoir. Due to the sedimentation the lake is facing the threat of losing open water surfaces. The sedimentation is also contributes to the vegetation spread, as the aquatic vegetation prefers shallow water, thus the appearance of the aquatic vegetation could be a bioindicator of the sedimentation. One of the most efficient method for monitoring the Lake Tisza and the vegetation dynamics is using remote sensing datasets.

In the first part of my doctoral thesis, I performed a comparative analysis of a hyperspectral (AISA Eagle) and multispectral (Landsat-8) imagery. I observed the classification accuracies and developed a method to improve the classification performance. The land cover of the Lake Tisza contains riparian forests, herbaceous vegetation, aquatic vegetation and open water surfaces. During the classifications I applied these four land cover categories as well. Train and test data were defined according to field measurements and using supporting datasets. The hyperspectral image contained 128 spectral bands, and I performed the classifications using different input band sets.

I filtered out the bands with low signal/noise ratio, so I got 109 bands. I selected the bands overlapping with the Landsat-8 blue, green, red and near-infrared (BGRNIR) bands, this resulted 47 bands. I also created a four band averaged dataset from these 47 bands to get a multispectral like dataset. From the Landsat image I applied different band combinations using the BGRNIR bands as a basis of the input bands. I performed classifications with the BGRNIR, coastal blue band and BGRNIR, BGRNIR and short wave infrared bands, and finally coastal blue band and BGRNIR and short wave infrared bands. Based on the results I found that more spectral bands improved the accuracies. Applying Support Vector Machine classifier the 47 bands reached 91.5% Overall Accuracy, 109 bands had 94% Overall Accuracy, while 128 bands gained 94.5% Overall Accuracy. I also applied Random Forest classifier and a related technique, Variable Importance Analysis, which resulted in the 16 and 14 most important bands from the 128 and 47 bands. The 16 bands gained 94% Overall Accuracy, and the 14 bands had only 84% Overall Accuracy applying Random Forest classifier. My newly developed band fusion method applying the Variable Importance Analysis results and the additional Landsat spectral range resulted the best accuracy

(59 bands; 95.5% Overall Accuracy). From the 59 bands 47 overlapped with the Landsat wavelength range, with additional bands from the wavelength ranges 526 nm to 531 nm, 677 nm to 681 nm, and 691 nm to 715 nm, and two discrete bands at 758 nm and 811 nm.

The MNF-transformation, as an ordination method, helped to reduce the number of input bands while kept the explained variance at the maximum level, thus 96% Overall Accuracy was achieved in case of the 47, 109, and 128 hyperspectral bands. Applying the MNF-transformation on the 59 bands resulted the best Overall Accuracy (96.5%) in my thesis. In case of the Landsat image, the MNF-transformation also improved the classification results (from 81.91% to 86.43% Overall Accuracy). Increasing the number of MNF bands included in the classification significantly increased the Overall Accuracy for the first few variables included, but including more variables after reaching the maximum accuracy value did not result in further improvements. I reached the maximum Overall Accuracies by classifying 7 MNF bands of the 47 bands, 15 MNF bands of the 59 bands, 10 MNF bands of the 109 bands, and 11 bands of the 128 bands. In case of the Landsat imagery applying 4 MNF bands resulted the best Overall Accuracy. Among the User's and Producer's Accuracies the aquatic vegetation was classified with the best results.

Observing the landscape ecological perspectives of the two most accurate land cover maps of both sensors, I found that only the herbaceous vegetation differed statistically among the land cover patches larger than 900 m² (1 Landsat pixel size). Patches of less than 900 m² accounted for 6.27% of the area, meaning that Landsat imagery for this area cannot provide accurate results due to the spatial resolution. The landscape ecological observations highlighted that the Landsat images are suitable for mapping the most relevant ecological information (i.e. land cover classes) with acceptable accuracies if the aim of the study allows the coarser geometric resolution. I observed the vegetation dynamics over the area, especially the dynamics of the aquatic vegetation. I determined the small size dense patches where further spread is assumed. The results can be grouped into two categories: (i) areas of continuous aquatic vegetation within a radius of 100 to 200 m, and (ii) areas of regularly cutted aquatic vegetation along smaller waterways, where later aquatic vegetation starts to re-establish in a linear pattern. These results are important for the researchers and management for maintain or improve the actual state of the Lake Tisza.

The second part of my doctoral thesis contains the long-term vegetation change observation of the Lake Tisza applying spectral indices of Landsat imagery between 1984 and 2017. The main goal was to reveal the trend of vegetation change and the succession of the lake within the 10 delineated sub-basins that I declared as study areas based on field measurements, aerial photographs, and topographic maps. I developed a methodology to identify the threat of sedimentation-based succession and vegetation spread over the sub-basins. Before selecting the images for the long-term analysis, I determined the annual vegetation dynamics based on a time series analysis

from 2015. Based on these six Landsat images from May to September I determined the time range between 28 July and 11 August, where the NDVI values showed the highest value with the lowest variance, thus I selected imagery for further analysis from this time range. There were 20 cloud-free records available for the area between 1984 and 2017.

I applied NDVI vegetation indices to evaluate the vegetation and succession conditions of the whole sub-basins, the vegetated areas, and non-vegetated parts of the sub-basins as well. I separated the vegetated and non-vegetated parts of the sub-basins based on the MNDWI water indices. From these results I determined the Percentage of Open Water (POW) values for each sub-basin. Based on the NDVI values of the whole basins I determined three types of the basins. The first type showed mostly decreasing NDVI values (basins #1., 2. and 5.), the second showed mostly increasing trend (basins #3., 4., 6., 7. and 9.), and the third type did not show any trend. According to the NDVI values of the open water surfaces two types could be determined. The first type (basins #1., 2., 4. and 5.) had mostly decreasing trend, and had NDVI values below zero in most of the years, indicating clear water. The second type (basins #3., 6., 7., 8., 9. and 10.) had higher NDVI values and mostly positive median values. According to the NDVI values of the vegetated areas different types cannot be categorized, because the vegetated areas are homogenous in the basins. According to the POW values five different basin types could be determined. The first type contained the basin #1. with a slight decreasing trend. The second type contained the basins #2. and 5. with POW values above 50%. The third type contained the basins #3., 6. and 7. and their POW values were approaching zero between 2000 and 2005. The fourth type contained the basin #9., and the fifth type contained the basins #8., and 10. The fourth and fifth types had similar trend as the third type, but the values had not much variance and the values did not approach zero. Based on the vegetated areas I determined the vegetation frequency over the area, by summarizing the vegetation cover layers. I also evaluated the vegetation frequency by their median values, and I determined two categories according to it. The first category contained the basins #1., 2., 5., 8., and 10. with median values below 3, and the second category contained the basins #3., 4., 6., 7., and 9. with median values higher than 10.

Based on the NDVI and POW values two six-stage threat factor were assigned to each sub-basin. By summarizing these two threat factors I created the Level of Sedimentation Risk Index (LoSRI) for each sub-basin. Larger basins with low NDVI values and high POW values were the less threatened basins of sedimentation, and smaller basins with high NDVI values and low POW values were the most threatened ones. I validated the results by water level and water depth data. The water level and water depth values were consistent with my results, although the correlation was moderate, thus there are limitations of the LoSRI index in general use, but the risk of sedimentation can be estimated. The vegetation frequency map allowed the spatial evaluation of the succession processes. The succession trends in the sub-basins were

not evident, as the Lake Tisza is artificially managed by regulation of the water level, sediment excavation and plant cutting as well. Thus the new method can be successfully applied to large extent and deeper lakes, but in case of smaller and shallow lakes where the vegetation is also present this method to reveal sedimentation has limitations. The advantage of this method is that we can estimate the level of sedimentation and the rate of succession of a lake or sub-basins of a lake system based on just remote sensing datasets, thus this is a cost-effective and rapid technique.

Köszönetnyilvánítás

Köszönetemet szeretném kifejezni elsősorban Szabó Szilárd témavezetőmnek, aki az egyetemi tanulmányaim alatt, és különösen a doktori kutatásom kapcsán elmondhatatlanul sokat segített és mindig támogatott.

Köszönet illeti Burai Pétert, aki adatokkal, és nem utolsó sorban szakértelmével hozzájárult a doktori értekezés létrejöttéhez.

Köszönet illeti Deák Balázst, aki szakértelmével és észrevételeivel az ökológiai szemléletű vizsgálatokban segített.

Köszönet jár Kummer Lászlónak és a Közép-Tisza-vidéki Vízügyi Igazgatóságnak a biztosított adatokért.

Köszönet jár az értekezés bírálóinak Gombosné Nagy Ildikónak és Szabó Gergelynek, akik értékes szakmai észrevételeikkel és javaslataikkal hozzájárultak a dolgozat színvonalának emeléséhez.

Köszönetemet szeretném kifejezni munkatársaimnak, valamint volt PhD csoporttársaimnak, akik szakmailag segítettek a dolgozat elkészítését és támogattak még akkor is, amikor a kelleténél több szóviccel viszonyoztam ezt.

Köszönet illeti barátaimat, zenésztársaimat, akik érdeklődéssel, biztatással, és nem utolsó sorban türelemmel álltak hozzám a dolgozat elkészítésének ideje alatt is.

Hálával és köszönettel tartozom szüleimnek, és családomnak, akik idáig is mellettem álltak és támogattak, nem csak tanulmányaim kapcsán, de az élet számos területén.

Szavakkal nehéz kifejezni azt a hálát és szeretetet, ami a feleségemet, Renát illeti, aki mindvégig szeretettel támogatott és biztatott, még a nehezebb időkben is.

Felhasznált irodalom

1. Aber, J. S., Marzolff, I., & Ries, J. (2010). *Small-format aerial photography: Principles, techniques and geoscience applications* Elsevier.
2. Alam, A., Bhat, M. S., & Maheen, M. (2019). Using Landsat satellite data for assessing the land use and land cover change in Kashmir valley. *Geojournal*, , 1-15.
3. ArcGIS 10.4. ESRI GDI, Redlands, CA, USA. 2019.
4. Babcsányi, I., Tamás, M., Szatmári, J., Hambek-Oláh, B., & Farsang, A. (2020). Assessing the impacts of the main river and anthropogenic use on the degree of metal contamination of oxbow lake sediments (Tisza river valley, Hungary). *Journal of Soils and Sediments*, 20(3), 1662-1675.
5. Babka, B., Futó, I., & Szabó, S. (2018). Seasonal evaporation cycle in oxbow lakes formed along the Tisza River in Hungary for flood control. *Hydrological Processes*, 32(13), 2009-2019.
6. Balázs, B., Bíró, T., Dyke, G., Singh, S. K., & Szabó, S. (2018). Extracting water-related features using reflectance data and principal component analysis of Landsat images. *Hydrological Sciences Journal*, 63(2), 269-284.
7. Boardman, J. W. (1993). Automating spectral unmixing of AVIRIS data using convex geometry concepts. Paper presented at the *JPL, Summaries of the 4th Annual JPL Airborne Geoscience Workshop*, Pasadena, CA., 1 11-14.
8. Bogárdi, J. (Ed.). (1971). *Vízfolyások hordalékszállításáa*. Budapest: Akadémiai Kiadó.
9. Bretar, F., Chauve, A., Bailly, J. S., Mallet, C., & Jacome, A. (2009). Terrain surfaces and 3-D landcover classification from small footprint full-waveform LiDAR data: Application to badlands. *Hydrology and Earth System Sciences*, 13, 1531-1544.
10. Burai, P., Deák, B., Valkó, O., & Tomor, T. (2015). Classification of herbaceous vegetation using airborne hyperspectral imagery. *Remote Sensing*, 7(2), 2046-2066.
11. Burai, P., Lövei, G., Lénárt, C., Nagy, I., & Enyedi, E. (2010). Mapping aquatic vegetation of the Rakamaz-Tiszanagyfalui Nagy-morotva using hyperspectral imagery. *Landscape & Environment*, 4(1), 1-10.
12. Büttner, G., Korandi, M., Gyömörei, A., Köte, Z., & Szabó, G. (1987). Satellite remote sensing of inland waters: Lake Balaton and reservoir Kisköre. *Acta Astronautica*, 15(6-7), 305-311.
13. CaliGeoPro (Spectral Imaging Ltd.)

14. Claverie, M., Ju, J., Masek, J. G., Dungan, J. L., Vermote, E. F., Roger, J., Skakun, S. V., & Justice, C. (2018). The harmonized Landsat and Sentinel-2 surface reflectance data set. *Remote Sensing of Environment*, 219, 145-161.
15. Csáki, P., Szinetár, M. M., Herceg, A., Kalicz, P., & Gribovszki, Z. (2018). Climate change impacts on the water balance-case studies in Hungarian watersheds. *Időjárás= Quarterly Journal of the Hungarian Meteorological Service*, 122(1), 81-99.
16. Csete, M., Pálvolgyi, T., & Szendrő, G. (2013). Assessment of climate change vulnerability of tourism in Hungary. *Regional Environmental Change*, 13(5), 1043-1057.
17. Dalponte, M., Bruzzone, L., & Gianelle, D. (2012). Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. *Remote Sensing of Environment*, 123, 258-270.
18. Deák, B., Valkó, O., Török, P., Kelemen, A., Tóth, K., Miglécz, T., & Tóthmérész, B. (2015). Reed cut, habitat diversity and productivity in wetlands. *Ecological Complexity*, 22, 121-125.
19. Degife, A., Worku, H., Gizaw, S., & Legesse, A. (2019). Land use land cover dynamics, its drivers and environmental implications in Lake Hawassa watershed of Ethiopia. *Remote Sensing Applications: Society and Environment*, 14, 178-190.
20. Deng, L., Feng, M., & Tai, X. (2019). The fusion of panchromatic and multispectral remote sensing images via tensor-based sparse modeling and hyper-laplacian prior. *Information Fusion*, 52, 76-89. doi:https://doi.org/10.1016/j.inffus.2018.11.014
21. Dezső, Z., Szabó, S., & Bihari, Á. (2009). Tiszai hullámtér feltöltődésének időbeli alakulása 137Cs-izotóp gamma spektrometriai vizsgálata alapján. Mócsy, I., Szacsvay, K., Urák, I., Zsigmond, AR (Ur.). *Proc. V. Kárpát-Medencei Környezettudományi Konferencia. Kolozsvár*, 443-438.
22. Dibs, H., Hasab, H. A., Al-Rifaie, J. K., & Al-Ansari, N. (2020). An optimal approach for land-use/land-cover mapping by integration and fusion of multispectral Landsat OLI images: Case study in Baghdad, Iraq. *Water, Air, & Soil Pollution*, 231(9), 1-15.
23. Dronova, I., Gong, P., Wang, L., & Zhong, L. (2015). Mapping dynamic cover types in a large seasonally flooded wetland using extended principal component analysis and object-based classification. *Remote Sensing of Environment*, 158, 193-206.
24. Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., & Martimort, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25-36.

25. ENVI/IDL 5.3 (Exelis, Inc., Boulder, CO, USA)
26. Farkas, J. Z., Hoyk, E., & Rakonczai, J. (2017). Geographical analysis of climate vulnerability at a regional scale: The case of the Southern Great Plain in Hungary. *Hungarian Geographical Bulletin*, 66(2), 129-147.
27. Fischer, C., & Kakoulli, I. (2006). Multispectral and hyperspectral imaging technologies in conservation: Current research and potential applications. *Studies in Conservation*, 51(sup1), 3-16.
28. Folkard, A. M. (2005). Hydrodynamics of model *Posidonia oceanica* patches in shallow water. *Limnology and Oceanography*, 50(5), 1592-1600.
29. Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185-201.
30. Foster, C., Hallam, H., & Mason, J. (2015). Orbit determination and differential-drag control of planet labs Cubesat constellations. *ArXiv Preprint arXiv:1509.03270*,
31. Friedl, M. A., Woodcock, C., Gopal, S., Muchoney, D., Strahler, A. H., & Barker-Schaaf, C. (2000). A note on procedures used for accuracy assessment in land cover maps derived from AVHRR data. *Int.J.Remote Sens.*, 21(5), 1073-1077. doi:10.1080/014311600210434
32. Galat, D. L., Verdin, J. P., & Sims, L. L. (1990). Large-scale patterns of *Nodularia spumigena* blooms in Pyramid Lake, Nevada, determined from Landsat imagery: 1972–1986. *Hydrobiologia*, 197(1), 147-164.
33. Genuer, R., Poggi, J., & Tuleau-Malot, C. (2010). Variable selection using random forests. *Pattern Recognition Letters*, 31(14), 2225-2236.
34. Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294-300.
35. Govender, M., Chetty, K., Naiken, V., & Bulcock, H. (2008). A comparison of satellite hyperspectral and multispectral remote sensing imagery for improved classification and mapping of vegetation. *Water SA*, 34(2), 147-154.
36. Green, A. A., Berman, M., Switzer, P., & Craig, M. D. (1988). A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions on Geoscience and Remote Sensing*, 26(1), 65-74.
37. Grygar, T. M., Elznicová, J., Kiss, T., & Smith, H. (2016). Using sedimentary archives to reconstruct pollution history and sediment provenance: The Ohře River, Czech Republic. *Catena*, 144, 109-129.
38. Gulácsi, A., & Kovács, F. (2018). Drought monitoring of forest vegetation using MODIS-based normalized difference drought index in Hungary. *Hungarian Geographical Bulletin*, 67(1), 29-42.

39. Güneralp, I., Filippi, A. M., & Randall, J. (2014). Estimation of floodplain aboveground biomass using multispectral remote sensing and nonparametric modeling. *International Journal of Applied Earth Observation and Geoinformation*, 33, 119-126.
40. Hagolle, O., Huc, M., Pascual, D. V., & Dedieu, G. (2010). A multi-temporal method for cloud detection, applied to FORMOSAT-2, VEN μ S, LANDSAT and SENTINEL-2 images. *Remote Sensing of Environment*, 114(8), 1747-1755.
41. Halmai, Á., Gradwohl-Valkay, A., Czigány, S., Ficsor, J., Liptay, Z. Á., Kiss, K., Lóczy, D., & Pirkhoffer, E. (2020). Applicability of a recreational-grade interferometric sonar for the bathymetric survey and monitoring of the Drava River. *ISPRS International Journal of Geo-Information*, 9(3), 149.
42. Han, X., Chen, X., & Feng, L. (2015). Four decades of winter wetland changes in Poyang Lake based on Landsat observations between 1973 and 2013. *Remote Sensing of Environment*, 156, 426-437.
43. Homolova, L., Malenovský, Z., Clevers, J. G., García-Santos, G., & Schaepman, M. E. (2013). Review of optical-based remote sensing for plant trait mapping. *Ecological Complexity*, 15, 1-16.
44. Huang, S., Li, J., & Xu, M. (2012). Water surface variations monitoring and flood hazard analysis in Dongting Lake area using long-term Terra/MODIS data time series. *Natural Hazards*, 62(1), 93-100.
45. Hubay, K., Molnár, M., Orbán, I., Braun, M., Bíró, T., & Magyari, E. (2018). Age–depth relationship and accumulation rates in four sediment sequences from the Retezat Mts, South Carpathians (Romania). *Quaternary International*, 477, 7-18.
46. Hummel, M., & Kiviat, E. (2004). Review of world literature on water chestnut with implications for management in North America. *Journal of Aquatic Plant Management*, 42, 17-27.
47. Ifarraguerri, A., & Prairie, M. W. (2004). Visual method for spectral band selection. *IEEE Geoscience and Remote Sensing Letters*, 1(2), 101-106.
48. Jiang, X., Wang, J., Liu, X., & Dai, J. (2022). Landsat observations of two decades of wetland changes in the estuary of Poyang Lake during 2000–2019. *Water*, 14(1), 8.
49. Kangabam, R. D., Selvaraj, M., & Govindaraju, M. (2019). Assessment of land use land cover changes in Loktak Lake in Indo-Burma Biodiversity Hotspot using geospatial techniques. *The Egyptian Journal of Remote Sensing and Space Science*, 22(2), 137-143.
50. Kelemenné Szilágyi, E., & Végvári, P. (2011). A Kiskörei tározó (Tisza-tó) makrovegetációja - ahol nagy a sulyom mező, ott tömeges a rucaöröm. [The Macro-Vegetation of the Kisköre-Reservoir (Lake Tisza)] *ECONOMICA - A Szolnoki Főiskola Tudományos Közleményei*, IV(12), 83.

51. Kiage, L. M., & Douglas, P. (2020). Linkages between land cover change, lake shrinkage, and sublacustrine influence determined from remote sensing of select Rift Valley Lakes in Kenya. *Science of the Total Environment*, 709, 136022.
52. Kiss, T., & Sándor, A. (2009). Land use changes and their effect on floodplain aggradation along the Middle-Tisza River, Hungary. *Acta Geographica Debrecina Landscape & Environment*, 3(1), 1-10.
53. Koma, Z., Zlinszky, A., Bekő, L., Burai, P., Seijmonsbergen, A. C., & Kissling, W. D. (2021). Quantifying 3D vegetation structure in wetlands using differently measured airborne laser scanning data. *Ecological Indicators*, 127, 107752. doi:<https://doi.org/10.1016/j.ecolind.2021.107752>
54. Korponai, J., Gyulai, I., Braun, M., Kövér, C., Papp, I., & Forró, L. (2016). Reconstruction of flood events in an oxbow lake (Marótzugi Holt-Tisza, NE Hungary) by using subfossil cladoceran remains and sediments. *Advances in Oceanography and Limnology*, 7(2), 125-135.
55. Koutsias, N., Mallinis, G., & Karteris, M. (2009). A forward/backward principal component analysis of Landsat-7 ETM data to enhance the spectral signal of burnt surfaces. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(1), 37-46.
56. Kumar, A., Lee, W. S., Ehsani, R. J., Albrigo, L. G., Yang, C., & Mangan, R. L. (2012). Citrus greening disease detection using aerial hyperspectral and multispectral imaging techniques. *Journal of Applied Remote Sensing*, 6(1), 063542-1-063542-22.
57. Laczi, Z., Teszárné Dr Nagy, M., Fejes, L., & Katona, P. G. (2018). *Negyvenéves a Tisza-tó. A Közép-Tisza-vidéki Vízügyi Igazgatóság jubileumi kiadványa* (szerk. Laczi Z.). Szolnok. ISBN 978-615-00-1647-4
58. Lague, D., & Feldmann, B. (2020). Topo-bathymetric airborne LiDAR for fluvial-geomorphology analysis. *Developments in earth surface processes*, 23. Elsevier. 25-54.
59. Lambin, E. F., Turner, B. L., Geist, H. J., Agbola, S. B., Angelsen, A., Bruce, J. W., Coomes, O. T., Dirzo, R., Fischer, G., & Folke, C. (2001). The causes of land-use and land-cover change: Moving beyond the myths. *Global Environmental Change*, 11(4), 261-269.
60. Latuso, K. D., Keim, R. F., King, S. L., Weindorf, D. C., & DeLaune, R. D. (2017). Sediment deposition and sources into a Mississippi River floodplain lake; Catahoula Lake, Louisiana. *Catena*, 156, 290-297.
61. Lee, K., Cohen, W. B., Kennedy, R. E., Maersperger, T. K., & Gower, S. T. (2004). Hyperspectral versus multispectral data for estimating leaf area index in four different biomes. *Remote Sensing of Environment*, 91(3), 508-520.

62. Lekfuangfu, A., Kasetkasem, T., Rakwatin, P., Tanarat, S., Kumazawa, I., & Chanwimaluang, T. (2016). Land cover mapping classification based on multi Restricted Boltzmann machines and support vector machines. Paper presented at the *Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON), 2016 13th International Conference on*, 1-5.
63. Li, Q., Lu, L., Wang, C., Li, Y., Sui, Y., & Guo, H. (2015). MODIS-derived spatiotemporal changes of major lake surface areas in arid Xinjiang, China, 2000–2014. *Water*, 7(10), 5731-5751.
64. Lillesand, T., Kiefer, R. W., & Chipman, J. (2014). *Remote sensing and image interpretation* John Wiley & Sons.
65. Lóczy, D. (2012). Floodplain evaluation. In D. Lóczy, M. Stankoviansky & A. Kotarba (Eds.), *Recent landform evolution: The Carpatho-Balkan-Dinaric region* (pp. 215-217) Springer Science & Business Media. doi:10.1007/978-94-007-2448-8
66. Longbotham, N. W., Pacifici, F., Malitz, S., Baugh, W., & Camps-Valls, G. (2015). Measuring the spatial and spectral performance of WorldView-3. Paper presented at the *Hyperspectral Imaging and Sounding of the Environment*, HW3B. 2.
67. Lunetta, R. S., Congalton, R. G., Fenstermaker, L. K., Jensen, J. R., Mcgwire, K. C., & Tinney, L. R. (1991). Remote sensing and geographic information system data integration: Error sources and research issues. *Photogrammetric Engineering & Remote Sensing*, 57(5), 677-687.
68. Lyons, M. B., Keith, D. A., Phinn, S. R., Mason, T. J., & Elith, J. (2018). A comparison of resampling methods for remote sensing classification and accuracy assessment. *Remote Sensing of Environment*, 208, 145-153. doi:https://doi.org/10.1016/j.rse.2018.02.026
69. Mallinis, G., Galidaki, G., & Gitas, I. (2014). A comparative analysis of EO-1 Hyperion, QuickBird and Landsat TM imagery for fuel type mapping of a typical mediterranean landscape. *Remote Sensing*, 6(2), 1684-1704.
70. Mas, J. (1999). Monitoring land-cover changes: A comparison of change detection techniques. *International Journal of Remote Sensing*, 20(1), 139-152.
71. Matthews, J. W., & Endress, A. G. (2010). Rate of succession in restored wetlands and the role of site context. *Applied Vegetation Science*, 13(3), 346-355.
72. Meire, D. W., Kondziolka, J. M., & Nepf, H. M. (2014). Interaction between neighboring vegetation patches: Impact on flow and deposition. *Water Resources Research*, 50(5), 3809-3825.
73. Melgani, F., & Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8), 1778-1790.

74. Meng, X., Shen, H., Li, H., Zhang, L., & Fu, R. (2019). Review of the pansharpening methods for remote sensing images based on the idea of meta-analysis: Practical discussion and challenges. *Information Fusion*, 46, 102-113. doi:<https://doi.org/10.1016/j.inffus.2018.05.006>
75. Meyer, W. B., & Turner, B. L. (1992). Human population growth and global land-use/cover change. *Annual Review of Ecology and Systematics*, 23(1), 39-61.
76. Mills, R. T., Kumar, J., Hoffman, F. M., Hargrove, W. W., Spruce, J. P., & Norman, S. P. (2013). Identification and visualization of dominant patterns and anomalies in remotely sensed vegetation phenology using a parallel tool for principal components analysis. *Procedia Computer Science*, 18, 2396-2405.
77. Moreno-Martínez, Á., Camps-Valls, G., Kattge, J., Robinson, N., Reichstein, M., van Bodegom, P., Kramer, K., Cornelissen, J. H. C., Reich, P., Bahn, M., Niinemets, Ü., Peñuelas, J., Craine, J. M., Cerabolini, B. E. L., Minden, V., Laughlin, D. C., Sack, L., Allred, B., Baraloto, C., Byun, C., Soudzilovskaia, N. A., & Running, S. W. (2018). A methodology to derive global maps of leaf traits using remote sensing and climate data. *Remote Sensing of Environment*, 218, 69-88. doi:<https://doi.org/10.1016/j.rse.2018.09.006>
78. Moskal, L. M., Price, J., Jakubauskas, M. E., & Martinko, E. A. (2001). Comparison of hyperspectral AVIRIS and Landsat TM imagery for estimating burn site pine seedling regeneration densities in the Central Plateau of Yellowstone National Park. Paper presented at the *Proceedings of the Third International Conference on Geospatial Information in Agriculture and Forestry*, Denver, Colorado, 5-7.
79. Mucsi, L., Liska Cs. M., Henits L., Tobak Z., Csendes B., Nagy L. (2017). The evaluation and application of an urban land cover map with image data fusion and laboratory measurements. *Hungarian Geographical Bulletin*, 66(2), 145-156.
80. Myungjin Choi, Rae Young Kim, Myeong-Ryong Nam, & Hong Oh Kim. (2005). *Fusion of multispectral and panchromatic satellite images using the curvelet transform* doi:10.1109/LGRS.2005.845313
81. Nagendra, H., Lucas, R., Honrado, J. P., Jongman, R. H., Tarantino, C., Adamo, M., & Mairota, P. (2013). Remote sensing for conservation monitoring: Assessing protected areas, habitat extent, habitat condition, species diversity, and threats. *Ecological Indicators*, 33, 45-59.
82. Nguyen, H., Braun, M., Szaloki, I., Baeyens, W., Van Grieken, R., & Leermakers, M. (2009). Tracing the metal pollution history of the Tisza River through the analysis of a sediment depth profile. *Water, Air, and Soil Pollution*, 200(1-4), 119-132.

83. Omute, P., Corner, R., & Awange, J. L. (2012). The use of NDVI and its derivatives for monitoring Lake Victoria's water level and drought conditions. *Water Resources Management*, 26(6), 1591-1613.
84. Oommen, T., Misra, D., Twarakavi, N. K., Prakash, A., Sahoo, B., & Bandopadhyay, S. (2008). An objective analysis of Support Vector Machine based classification for remote sensing. *Mathematical Geosciences*, 40(4), 409-424.
85. Orhan, O., Ekercin, S., & Dadaser-Celik, F. (2014). Use of Landsat land surface temperature and vegetation indices for monitoring drought in the Salt Lake Basin Area, Turkey. *TheScientificWorldJournal*, 2014, 142939. doi:10.1155/2014/142939
86. Östlund, C., Flink, P., Strömbeck, N., Pierson, D., & Lindell, T. (2001). Mapping of the water quality of Lake Erken, Sweden, from imaging spectrometry and Landsat Thematic Mapper. *Science of the Total Environment*, 268(1-3), 139-154.
87. Pahlevan, N., Chittimalli, S. K., Balasubramanian, S. V., & Vellucci, V. (2019). Sentinel-2/Landsat-8 product consistency and implications for monitoring aquatic systems. *Remote Sensing of Environment*, 220, 19-29.
88. Phinzi, K., Abriha, D., Bertalan, L., Holb, I., & Szabó, S. (2020). Machine learning for gully feature extraction based on a pan-sharpened multispectral image: Multiclass vs. binary approach. *ISPRS International Journal of Geo-Information*, 9(4), 252.
89. Phinzi, K., Holb, I., & Szabó, S. (2021). Mapping permanent gullies in an agricultural area using satellite images: Efficacy of machine learning algorithms. *Agronomy*, 11(2), 333.
90. QGIS Development Team (2017). *QGIS Geographic Information System. Open Source Geospatial Foundation Project*.
91. Qiu, S., Zhu, Z., & Woodcock, C. E. (2020). Cirrus clouds that adversely affect Landsat 8 images: What are they and how to detect them? *Remote Sensing of Environment*, 246, 111884.
92. R Core Team. (2017). *R: A language and environment for statistical computing* [computer software]. Vienna, Austria: R Foundation for Statistical Computing.
93. Rátz, T., & Vizi, I. (2004). The impacts of global climate change on water resources and tourism: The responses of Lake Balaton and Lake Tisza. *Advances in Tourism Climatology*, 82.
94. Reed, B., Budde, M., Spencer, P., & Miller, A. E. (2009). *Integration of MODIS-derived metrics to assess interannual variability in snowpack, lake ice, and NDVI in southwest Alaska* doi:https://doi.org/10.1016/j.rse.2008.07.020

95. Regmi, P., Grosse, G., Jones, M. C., Jones, B. M., & Anthony, K. W. (2012). Characterizing post-drainage succession in thermokarst lake basins on the Seward Peninsula, Alaska with TerraSAR-X backscatter and Landsat-based NDVI data. *Remote Sensing*, 4(12), 3741-3765.
96. Rembold, F., Carnicelli, S., Nori, M., & Ferrari, G. A. (2000). Use of aerial photographs, Landsat TM imagery and multidisciplinary field survey for land-cover change analysis in the lakes region (Ethiopia). *International Journal of Applied Earth Observation and Geoinformation*, 2(3-4), 181-189.
97. Rouse Jr, J. W., Haas, R. H., Schell, J., & Deering, D. (1973). Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. *NASA/GSFC Type III Final Report, Greenbelt, Md*, 371.
98. Russell, M., Fulford, R., Murphy, K., Lane, C., Harvey, J., Dantin, D., Alvarez, F., Nestlerode, J., Teague, A., & Harwell, M. (2019). Relative importance of landscape versus local wetland characteristics for estimating wetland denitrification potential. *Wetlands*, 39(1), 127-137.
99. Sacks, L., Lee, T. M., & Tihansky, A. (1992). *Hydrogeologic setting and preliminary data analysis for the hydrologic-budget assessment of lake Barco, an acidic seepage lake in Putnam county, Florida* US Department of the Interior, US Geological Survey.
100. Sándor, A., & Kiss, T. (2008). Floodplain aggradation caused by the high magnitude flood of 2006 in the lower Tisza region, Hungary. *Journal of Environmental Geography*, 1(1-2), 31-39.
101. Sawaya, K. E., Olmanson, L. G., Heinert, N. J., Brezonik, P. L., & Bauer, M. E. (2003). *Extending satellite remote sensing to local scales: Land and water resource monitoring using high-resolution imagery* doi:<https://doi.org/10.1016/j.rse.2003.04.006>
102. Scheffer, M., & van Nes, E. H. (2007). Shallow lakes theory revisited: Various alternative regimes driven by climate, nutrients, depth and lake size. *Shallow lakes in a changing world*. Springer. 455-466.
103. Schlosser, A. D., Szabó, G., Bertalan, L., Varga, Z., Enyedi, P., & Szabó, S. (2020). Building extraction using orthophotos and dense point cloud derived from visual band aerial imagery based on machine learning and segmentation. *Remote Sensing*, 12(15), 2397.
104. Selker, R.; Love, J.; Dropmann, D. jmv: The ‘jamovi’ Analyses. R package version 1.2.5. (2020) <https://CRAN.R-project.org/package=jmv>. (accessed on 17 February 2020)
105. Singh, S. K., Laari, P. B., Mustak, S., Srivastava, P. K., & Szabó, S. (2018). Modelling of land use land cover change using earth observation data-sets of Tons River Basin, Madhya Pradesh, India. *Geocarto International*, 33(11), 1202-1222.

106. Soudani, K., François, C., Le Maire, G., Le Dantec, V., & Dufrêne, E. (2006). Comparative analysis of IKONOS, SPOT, and ETM data for leaf area index estimation in temperate coniferous and deciduous forest stands. *Remote Sensing of Environment*, 102(1), 161-175.
107. Sterling, S. M., Ducharne, A., & Polcher, J. (2013). The impact of global land-cover change on the terrestrial water cycle. *Nature Climate Change*, 3(4), 385.
108. Stratoulis, D., Keramitsoglou, I., Burai, P., Csaba, L., Zlinszky, A., Tóth, V., & Balzter, H. (2017). A framework for lakeshore vegetation assessment using field spectroscopy and airborne hyperspectral imagery. *Earth Observation for Land and Emergency Monitoring*, 159
109. Sun, W., Liu, C., Xu, Y., Tian, L., & Li, W. (2017). A band-weighted Support Vector Machine method for hyperspectral imagery classification. *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1710-1714.
110. Szabó, L., Burai, P., Deák, B., Dyke, G. J., & Szabó, S. (2019). Assessing the efficiency of multispectral satellite and airborne hyperspectral images for land cover mapping in an aquatic environment with emphasis on the water caltrop (*Trapa natans*). *International Journal of Remote Sensing*, 40(13), 4876-4897. doi:10.1080/01431161.2019.1579383
111. Szabó, L., Deák, B., Bíró, T., Dyke, G. J., & Szabó, S. (2020). NDVI as a proxy for estimating sedimentation and vegetation spread in artificial Lakes—Monitoring of spatial and temporal changes by using satellite images overarching three decades. *Remote Sensing*, 12(9), 1468.
112. Szabó, L., Deák, M., & Szabó, S. (2016). Comparative analysis of Landsat TM, ETM+, OLI and EO-1 ALI satellite images at the Tisza-tó area, Hungary. *Acta Geographica Debrecina Landscape & Environment*, 10(2), 53. doi:10.21120/LE/10/2/1
113. Szabó, S., Gácsi, Z., & Balázs, B. (2016). Specific features of NDVI, NDWI and MNDWI as reflected in land cover categories. *Acta Geographica Debrecina. Landscape & Environment Series*, 10(3/4), 194.
114. Tanos, P., Kovács, J., Kovács, S., Anda, A., & Hatvani, I. G. (2015). Optimization of the monitoring network on the River Tisza (Central Europe, Hungary) using combined cluster and discriminant analysis, taking seasonality into account. *Environmental Monitoring and Assessment*, 187(9), 575.
115. Thenkabail, P. S. (2015). *Remotely sensed data characterization, classification, and accuracies*. CRC Press.
116. Tiner, R. W., Lang, M. W., & Klemas, V. V. (Eds.). (2015). *Remote sensing of wetlands: Applications and advances*. CRC Press.
117. Török, P., Helm, A., Kiehl, K., Buisson, E., & Valkó, O. (2018). Beyond the species pool: Modification of species dispersal, establishment, and assembly by habitat restoration. *Restoration Ecology*, 26, S65-S72.

118. Tsai, F., Lin, E., & Yoshino, K. (2007). Spectrally segmented principal component analysis of hyperspectral imagery for mapping invasive plant species. *International Journal of Remote Sensing*, 28(5), 1023-1039.
119. Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127-150.
120. Turner, B., Meyer, W. B., & Skole, D. L. (1994). Global land-use/land-cover change: Towards an integrated study. *Ambio.Stockholm*, 23(1), 91-95.
121. Underwood, E. C., Ustin, S. L., & Ramirez, C. M. (2007). A comparison of spatial and spectral image resolution for mapping invasive plants in coastal California. *Environmental Management*, 39(1), 63-83.
122. USGS ESPA. Available online: <https://espa.cr.usgs.gov> (accessed on 31 January 2020).
123. van der Linden, S., Rabe, A., Held, M., Jakimow, B., Leitão, P. J., Okujeni, A., Schwieder, M., Suess, S., & Hostert, P. (2015). The EnMAP-Box—A toolbox and application programming interface for EnMAP data processing. *Remote Sensing*, 7(9), 11249-11266.
124. Van der Meer, Freek D, Van der Werff, Harald MA, Van Ruitenbeek, F. J., Hecker, C. A., Bakker, W. H., Noomen, M. F., Van Der Meijde, M., Carranza, E. J. M., De Smeth, J. B., & Woldai, T. (2012). Multi-and hyperspectral geologic remote sensing: A review. *International Journal of Applied Earth Observation and Geoinformation*, 14(1), 112-128.
125. Varga, O., Nagy, I. G., Burai, P., Tomor, T., Lénárt, C., & Szabó, S. (2018). Land cover analysis based on descriptive statistics of Sentinel-2 time series data. *Landscape & Environment*, 12(2), 1-9.
126. Wei, J., Huang, W., Li, Z., Sun, L., Zhu, X., Yuan, Q., Liu, L., & Cribb, M. (2020). Cloud detection for Landsat imagery by combining the Random Forest and superpixels extracted via energy-driven sampling segmentation approaches. *Remote Sensing of Environment*, 248, 112005.
127. Weller, M. W. (1999). *Wetland birds: Habitat resources and conservation implications*. Cambridge University Press.
128. Were, K., Dick, Ø., & Singh, B. (2013). Remotely sensing the spatial and temporal land cover changes in Eastern Mau forest reserve and Lake Nakuru drainage basin, Kenya. *Applied Geography*, 41, 75-86.
129. Xie, Y., Sha, Z., & Yu, M. (2008). Remote sensing imagery in vegetation mapping: A review. *Journal of Plant Ecology*, 1(1), 9-23.
130. Xu, H. (2006). Modification of Normalised Difference Water Index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033.
131. Xu, H., Caramanis, C., & Mannor, S. (2009). Robustness and generalization of Support Vector Machines. *Journal of Machine Learning Research*, 10, 1485-1510.

132. Y. Qu, H. Qi, B. Ayhan, C. Kwan, & R. Kidd. (2017). DOES multispectral / hyperspectral pansharpening improve the performance of anomaly detection? Paper presented at the - 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 6130-6133. doi:10.1109/IGARSS.2017.8128408
133. Yuan, F., Sawaya, K. E., Loeffelholz, B. C., & Bauer, M. E. (2005). Land cover classification and change analysis of the twin cities (Minnesota) metropolitan area by multitemporal Landsat remote sensing. *Remote Sensing of Environment*, 98(2-3), 317-328.
134. Zhao, B., Yan, Y., Guo, H., He, M., Gu, Y., & Li, B. (2009). Monitoring rapid vegetation succession in estuarine wetland using time series MODIS-based indicators: An application in the Yangtze River Delta area. *Ecological Indicators*, 9(2), 346-356.
135. Zlinszky, A., Mücke, W., Lehner, H., Briese, C., & Pfeifer, N. (2012). Categorizing wetland vegetation by airborne laser scanning on Lake Balaton and Kis-Balaton, Hungary. *Remote Sensing*, 4(6), 1617-1650.