

ORSZÁGOS TUDOMÁNYOS DIÁKKÖRI KUTATÁS

**Interferometrikus koherencia mezőgazdasági  
alkalmazhatóságának vizsgálata**

SIPŐCZ JÁZMIN

*Geofizikus MSc.*

Témavezető:

FRIEDL ZOLTÁN

*Távérzékelési szakértő, Lechner Nonprofit Kft.*



**ELTE**  
EÖTVÖS LORÁND  
TUDOMÁNYEGYETEM

Geofizikai és Űrtudományi Tanszék

Budapest, 2021

# Tartalomjegyzék

|                                                        |           |
|--------------------------------------------------------|-----------|
| <b>1. Bevezetés.....</b>                               | <b>2</b>  |
| <b>2. Irodalmi áttekintés .....</b>                    | <b>3</b>  |
| 2.1 Szintetikus apertúrájú radar (SAR) jellemzői ..... | 3         |
| 2.2 Radiometria-intenzitás .....                       | 6         |
| 2.3 Interferometrikus koherencia .....                 | 6         |
| <b>3. Sentinel-1 műholdak.....</b>                     | <b>8</b>  |
| <b>4. Adatok és módszertan .....</b>                   | <b>10</b> |
| 4.1 Referenciaadatok.....                              | 10        |
| 4.2 Mezőgazdasági növények fejlődése .....             | 12        |
| 4.3 Radarképek feldolgozása.....                       | 13        |
| 4.4 Idősoros vizsgálat.....                            | 15        |
| 4.5 Kezdő- és végpont meghatározás .....               | 15        |
| 4.6 Szeparációs vizsgálat.....                         | 17        |
| 4.6.1 Távolságmátrix előállítása .....                 | 17        |
| 4.6.2 Keresztvalidáció.....                            | 18        |
| 4.7 Random Forest osztályozás .....                    | 18        |
| <b>5. Eredmények .....</b>                             | <b>22</b> |
| 5.1 Átlag idősorok eredményei .....                    | 22        |
| 5.2 Koherencia idősorok elemzése parcellánként .....   | 24        |
| 5.3 Kezdő- és végpont meghatározás eredményei .....    | 28        |
| 5.4 Szeparációs vizsgálat eredményei .....             | 32        |
| 5.4.1 Távolságmátrix elemzés eredményei .....          | 32        |
| 5.4.2 Keresztvalidáció eredményei .....                | 34        |
| 5.5 Osztályozás eredményei .....                       | 36        |
| <b>6. Összegzés, konklúzió .....</b>                   | <b>43</b> |
| <b>7. Köszönetnyilvánítás.....</b>                     | <b>46</b> |
| <b>8. Irodalomjegyzék .....</b>                        | <b>47</b> |
| <b>9. Függelék.....</b>                                | <b>50</b> |

# 1. Bevezetés

A műholdas távérzékelés egyik legfontosabb célja, hogy a Föld felszínről és a légköri folyamatokról információt gyűjtsön. Ezek az adatok fontosak a mezőgazdaság számára, hiszen lehetőséget biztosítanak az egyes növényfajták megkülönböztetésére, a növényzet fejlődésének monitorozására és a földeken végzett munkálatok detektálására, valamint segítik a gazdákat a jövőbeli döntéseik meghozatalában.

A passzív távérzékelés során az optikai szenzorok a nap sugárzásának a Földről visszavert elektromágneses sugárzásainak a különböző hullámhossztartományait mérik, ugyanakkor az időjárás, a napszakok változása, valamint légköri és egyéb tényezők is befolyásolják az eredményeket. Ezen hatások kiküszöbölésére képes a szintetikus apertúrájú radar (SAR), ami a saját mikrohullámú sugárzása miatt kulcsfontosságú aktív távérzékelési módszer. A SAR szenzor a felszínről visszavert jel amplitúdóját és fázisát méri, amelyek a korábbi kutatások alapján már hatékonyan bizonyultak a felszín osztályozás szempontjából (BARGIEL, 2017; KENDUIYWO ET AL., 2018). További információkat az idősoros interferometrikus SAR (InSAR) alkalmazásával lehet szerezni, amelynek egyik fontos terméke az interferometrikus koherencia. Ez a paraméter szintén biztató eredményeket mutatott korábbi vizsgálatok során (VICENTE-GUIJALBA ET AL., 2018; MESTRE-QUEREDA ET AL., 2020).


A koherencia a jelek fázisértékének a korrelációját vizsgálja, így a felszíni változások detektálására is alkalmas, ezáltal a növények fejlődésének és a mezőgazdasági tevékenységek vizsgálatára is felhasználható lehet. A koherencia alacsony értékeket ad az időbeli változások hatására. Ez különösen érdekes lehet a vegetációs időszakban, vagyis amikor a növény fejlődésnek indul, akkor ez a jelenség a koherencia idősorokon hogyan jelenik meg. A mezőgazdasági területeken különösen nagy az időbeli változékonyság az emberi beavatkozás és a vegetáció következtében, ezért ezen időszak alatt az alacsony koherencia értékek dominálása várható, míg azon kívül magas értékek lehetnek jellemzőek. Mindezek ismeretében felmerült, hogy a koherencia idősorokon meg lehet-e határozni a növény fejlődési szakaszait, avagy egyéb hatások elnyomják-e ezeket a szakaszokat.

A kutatásom fő tevékenységeként magyarországi mezőgazdasági területek koherencia idősorát, illetve a módszer gyakorlati alkalmazásának lehetőségeit vizsgáltam. Célom az volt, hogy megállapítsam, érdemes-e a koherenciát alkalmazni a mezőgazdaságban, úgymint a növények fejlődésének nyomon követésére, illetve az egyes növényfajták elkülönítésére.

## 2. Irodalmi áttekintés

### 2.1 Szintetikus apertúrájú radar (SAR) jellemzői

A műholdakon elhelyezett szintetikus apertúrájú radar az aktív távérzékelési módszerek közé tartozik, mivel a műszer polarizált elektromágneses hullámokat sugároz ki, amelyeket felvételez, miután azok a Föld felszínéről visszaverődtek. A szintetikus apertúra kifejezés arra utal, hogy egy nagyobb radar antennát szimulálnak, mivel a nagyobb antennaméret jobb felbontást eredményez. Ez úgy érhető el, hogy amíg a radar az adott objektumot a folyamatos sugárzása által felvételezi és ezen felvételek átfednek, addig matematikai eljárással a felvételek fókuszálása történik (ESA EARTH ONLINE, 2021). Az adott objektum tehát mindaddig részt vesz a képképzésben, amíg a besugárzás éri. Ennek eredményeként azimut irányban – repülési irányának megfelelően – jelentősen jobb felbontás érhető el. Ezzel a jelfeldolgozási technikával kapott képek olyanok, mintha egy nagyobb antennával készültek volna, és a szintetikus apertúra a műszer által megtett távolságnak felel meg (1. ábra).




1. ábra: A szintetikus apertúrájú radar (SAR) elve (BÁNYAI ET AL., 2014). A műszer adott pillanatban több kilométer távot képes egyszerre besugározni (bal) és ahogy a műhold halad előre az egyes felvételek között átfedés figyelhető meg. A felvételek fókuszálásával a kapott kép olyan, mintha egy nagyobb méretű antennával készült volna és a felbontása javul (néhány méter) (jobb).

A radar frekvencia 300 MHz és 300 GHz közötti tartományba tehető, ami az elektromágneses spektrum mikrohullámú sávjába esik. Ebben a tartományban csökken a légkör csillapító hatása, ezáltal a kisugárzott hullámok a légkörön keresztülhatolva képesek információkat biztosítani a felszínről (ESA EARTH ONLINE, 2021). A SAR technológia előnye tehát, hogy az alkalmazott frekvencia miatt független az időjárástól és folyamatos mérést tud biztosítani. A következő képlettel leírható a frekvencia és a hullámhossz közti összefüggés:

$$c = \lambda \cdot f, \quad (1)$$

ahol  $c$  a fénysebesség (m/s),  $\lambda$  a hullámhossz (m), és  $f$  a frekvencia (Hz). Ennek megfelelően a látható fénynél kisebb frekvenciájú hullámok (300 MHz – 300 GHz) hullámhossza centiméteres nagyságrendű. A hullámhossz az a paraméter, ami meghatározza a hullámok behatolókéességét a felszíni objektumok közé. Az operatíván használt műholdas SAR rendszerek között három hullámhossz tartományt különböztetünk meg: az X-, a C- és az L-sávós radarokat (ESA EARTH ONLINE, 2021). A felhasználási céloknak megfelelően lehet megválasztani az éppen megfelelő hullámhossz nagyságát. Az X-sáv hullámhossza a legkisebb, amely 2,5 – 3,75 cm, ennek következtében ez a tárgyak felületéről már visszaverődik, míg a nagyobb hullámhosszú (3,75 – 7,5 cm) C-sáv már nagyobb behatolással bír. A legnagyobb hullámhosszú (15 – 30 cm) L-sáv biztosítja a legnagyobb behatolást, ami növényzet esetén teljesen áthatolhat azon, egészen a talajig.

A  $v$  sebességgel mozgó műholdon elhelyezett SAR műszer oldalirányban – range irányban – bocsátja ki az impulzusokat, ami már egy kisugárzott jel esetén is több km hosszú, úgynevezett swath széles területet képes felvételezni, amelyet a 2. ábra szemléltet. A range irányú felbontás a kisugárzott jel sáv szélességétől függ, és ez független az azimut irányú felbontástól, ezért egy chirp jelet bocsát ki a szenzor. A chirp jel hosszú impulzusokat tartalmaz lineáris frekvenciamodulációkkal, amelynek a visszaérkezési ideje és a Doppler-frekvenciája alapján tömörítési művelet elvégzésével egy jobb felbontású felvétel érhető el (ESA EARTH ONLINE, 2021).



2. ábra: A SAR felvételezés geometriája, ahol a műhold  $v$  sebességgel halad,  $H$  felszín feletti magasságban és  $\theta$  szögben bocsátja ki a hullámokat range irányban (MOREIRA ET AL.,2018 alapján).

A range irányú monitorozás esetén megkülönböztetünk Slant és a Ground Range síkokat, amelyek a 2. ábrán láthatóak. A felvételek Slant Range irányban készülnek, ami a műszer és az objektumok távolságát határozza meg és ennek az iránynak a felszínre vetítésével kapható meg Ground Range irány. Alapvetően az adatok Ground Range helyzetbe való transzformációja még nem korrigált geometriailag, ez a feldolgozás során a topográfiai korrekcióval érhető el (ESA SENTINEL-1 TUTORIALS, 2020). A sugárzás oldalirányban történik, ezért szükséges bevezetni a  $\theta$  beesési szöget, amelyet a műszer függőleges vonala és a kibocsájtott sugárzás között mérünk (2. ábra). Ez a szög a reflektált hullámok erősségét is befolyásolja azáltal, hogy minél nagyobb a szög, annál jobban csökken a jel erőssége.

A kisugárzott impulzusok másik meghatározó tulajdonsága a hullámhossz mellett a hullámok polarizáltsága. A SAR műszer által továbbított jelek horizontális (H) vagy vertikális (V) elektromos térben polarizált síkhullámok lehetnek. A regisztrált jelekre szintén ez vonatkozik azzal a különbséggel, hogy felváltva tudja érzékelni mindkét polarizációt a szenzor. Ezek alapján lehetőség van HH és VV co-polarizált csatornákra, amelyek esetén a kisugárzott és az érzékelt hullámok polarizációja azonos. Ugyanakkor, ha megváltozik a hullámok polarizációja a visszaverődés következtében, akkor HV és VH cross-polarizált csatornákat is lehet használni. Az utóbbi esetekben a jel gyengülése tapasztalható, ami a különböző reflexiókkal hozható összefüggésbe (ESA EARTH ONLINE, 2021).

A SAR felvételezés hátránya a zajosság, mivel a koherens sugárzás miatt a hullámok a tárgyakról visszaverődve interferenciát szenvednek, így kiolthatják vagy épp erősíthetik egymást. Ez a felvételeken véletlenszerű „só-bors” hatás formájában rontja a felvételek minőségét, amelyet speckle zajnak neveznek (ESA EARTH ONLINE, 2021). Ezen hatás csökkentését átlagolási módszerek segítségével lehet elérni, mint például a multilook eljárás, amely során  $N$  darab úgynevezett look, range és/vagy azimut irányban átlagolódik. Ennek eredményeként a speckle zaj hatása csökken, és a radiometrikus felbontás jelentős javulást mutat a térbeli felbontás rovására. A multilook méretétől függően lehet további térbeli szűrőket alkalmazni, ami a speckle hatás további csökkenését eredményezi.

A műszer a visszavert impulzusok alapján, a megvilágított területről egy pixel hálózatot készít, amelyben az egyes pixelek a reflektált jel amplitúdójáról ( $y$ ) és a fázisáról ( $\phi$ ) szerzett információk, melyek komplex számok formájában kerülnek rögzítésre (BÁNYAI ET AL., 2014):

$$z = ye^{i\phi} = y \cos \phi + i(y \sin \phi). \quad (2)$$

## 2.2 Radiometria-intenzitás

A klasszikus SAR alapú felvételezés során az amplitúdó értéknek van nagy szerepe, amelynek a négyzetét, azaz a jel intenzitását ( $y^2$ ) szokták felhasználni. A felvételezett értékeket a felszín topográfiája és az objektum fizikai, elektromos tulajdonságai is befolyásolják, mint az adott szóró objektum anyaga, alakja, durvasága, nedvességtartalma és permittivitása (MOREIRA ET AL., 2013).

A vízszintes felületekről a hullám szétszóródik, így a jel gyengül, ezzel szemben durva felület esetében a felvételezett jel erőssége nagyobb lesz. Ugyanakkor a nedvességtartalmat is figyelembe kell venni, mert víz hatására az objektum dielektromos állandója megnő, amely a visszavert jel nagyságának növekedését eredményezi. A topográfia szempontjából három torzulás fajtát lehet megkülönböztetni, mint árnyék, lejtő-rövidülés és áthajlás formájában. Ezen jelenségek csak a hegyvidéki területeken jelentkeznek, a sík területeken nem befolyásolják az eredményeket. Ezenkívül a hullámhossz/frekvencia, a polarizációs mód és a beesési szög is jelentősen befolyásolja a visszavert jel erősségét. Minél nagyobb a kisugárzott hullám frekvenciája, annál nagyobb a visszavert jel erőssége is, illetve a co-polarizált jelek is erősebb radarválaszt generálnak. A beesési szög is érdemben befolyásolja a radiometriai intenzitás értékét a növényzet esetében. A kisebb beesési szög esetében a talaj hatása erősebb, míg nagy beesési szög esetén a növényzet hatása erősebb.

## 2.3 Interferometrikus koherencia

Az interferometrikus SAR (InSAR) alkalmazásának köszönhetően a fázis információk bevonásával további adatokat lehet gyűjteni a Föld felszínéről. Megkülönböztethetünk single-pass és repeat-pass interferometriát. Ha egy műholdon két vevő antenna (single-pass) is található, amelyek egyszerre felvételezik a reflektált jeleket, akkor a mért fázisok különbsége által a felszín topográfiája meghatározható. A repeat-pass interferometria segítségével a felszín változása detektálható, mivel a műszer az adott területet újra felvételezi néhány nappal vagy akár hónapokkal később. Ennek a leggyakoribb felhasználása a felszínmozgások vizsgálata. Az idősoros vizsgálatok esetében, az InSAR alkalmazásának egyik terméke a koherencia. Ez a különböző időpontokban készült felvételek egyes pixeleihez tartozó fázisértékek ( $\phi$ ) korrelációjának kiszámítása által elsősorban az interferogram minőségének a mérésére szolgál, de a felszín időbeli stabilitását is lehet vele vizsgálni.

Interferometrikus koherenciának, avagy a komplex korrelációs koefficiensnek pontosan két különböző időpontban készült komplex radarkép korrelációját nevezzük, amely

segítségével a felvételezések közötti időbeli változásokat, illetve a zajt lehet detektálni. Meghatározása a következő (ROSEN ET AL., 2000):

$$\gamma = \frac{E\{S_1 S_2^*\}}{\sqrt{E\{S_1 S_1^*\}} \sqrt{E\{S_2 S_2^*\}}}, \quad (3)$$

ahol  $E\{\}$  a valószínűség operátor, és  $S_1$  és  $S_2$  a két komplex, co-regisztrált felvételt jelent. A koherencia értéke nulla és egy között várható. Alacsony értékeket akkor kaphatunk, ha a két felvétel nem korrelál egymással, és ennek a dekorrelációnak az elsődleges oka a felvételezések között eltelt időbeli változás, továbbá a zaj, a geometria és egyéb tényezők is negatívan befolyásolhatják a koherencia értékét. A felvételek minőségének meghatározására is jó a koherencia számítás, mivel ha a kapott értékek egy küszöbérték alá csökkennek – ezt 0,2-nek vettem –, akkor azokat érdemes a továbbiakban fenntartásokkal kezelni. Magas koherencia értékek ott várhatóak, ahol nem történik jelentős változás, mint például a települések esetén, ahol az épületek helyzete nem változik az időben, és amennyiben a koherencia értéke egy, akkor az feltehetően hibás eredmény. A koherencia értékeit befolyásolhatja továbbá a felszín topográfiája, a pontatlan co-regisztráció, valamint a felszín tulajdonságai (ESA EARTH ONLINE, 2021).

A koherencia idősorok előállításához az időbeli és a térbeli bázisvonal fogalmakat kell definiálni. Térbeli vagy merőleges bázisvonalról beszélhetünk, amikor a műszer újrafelvételezi ugyanazt a területet, de a pontos helyzete eltér az előző alkalomhoz képest. Ilyenkor a pozíciók közötti merőleges távolságot hívjuk térbeli bázisvonalnak. A túl nagy térbeli bázisvonal (több km) alacsony koherenciát eredményezhet. Az időbeli bázisvonal fogalma alatt a felvételezések közt eltelt idő értendő. A legkisebb időbeli bázisvonal tehát a műhold legközelebbi visszatérésekor készült felvételek között található (ESA EARTH ONLINE, 2021).

Abban az esetben, ha  $N$  darab felvétel áll rendelkezésre, akkor a koherencia számításához összesen  $(N - 1) \cdot (N - 1)$  féle párosítás lehetséges, de minél nagyobb az időbeli bázisvonal, annál jobban befolyásolja az eredményeket az időbeli változás. Következtetésképpen, ahogy azt a szakdolgozatomban is tapasztaltam, az időbeli bázisvonal növelésével a koherencia értéke jelentősen csökken a mezőgazdasági területeken, mivel ezeken a területeken nem találhatók stabil szórópontok (MESTRE-QUEREDA ET AL., 2020; SIPÖCZ, 2021). Ezenkívül, ha az időbeli bázisvonal értéke már nagyon nagy, akkor az automatikusan a koherencia értékek szignifikáns csökkenését vonja maga után. Ennek következtében a párosításokat célszerű úgy alakítani, hogy mindig kronológiai sorrendben egymást követő felvételek között történjen a számítás.

### 3. Sentinel-1 műholdak

A kutatáshoz szükséges műholdfelvételeket a Sentinel-1 műholdcsalád biztosította a műholdon elhelyezett SAR szenzor által, amelyekhez globálisan ingyenes a hozzáférés minden felhasználó számára.

Az Európai Űrügynökség (ESA) a Föld felszínének és a légkörének tanulmányozása céljából elindította az Európai Copernicus Földmegfigyelési Programot, amelyben összesen öt Sentinel műhold küldetés került kidolgozásra. A Sentinel-1 misszió ezek közül az első, aminek feladatai közé tartozik többek között a szárazföldek, a vízzel és jéggel borított területek térképezése, valamint a természeti katasztrófák észlelése. Mára a misszió két műholdat tartalmaz, amelyek közül az első (Sentinel-1A) 2014-ben, a másodikat (Sentinel-1B) 2016-ban bocsájtotta fel az ESA Föld körüli pályára. Ezek a műholdak kvázipoláris, azonos napszinkron pályán keringenek, amely inklinációja  $98,18^\circ$ . A felszín felett 693 km magasan elhelyezkedő pályán a műholdak 12 naponta térnek vissza ugyanazon földrajzi hely fölé. Annak érdekében, hogy egy adott területről jobb időbeli felbontást lehessen elérni, a műholdpár között a fáziskülönbség  $180^\circ$ , emiatt a Sentinel-1 visszatérési ideje és ezáltal az időbeli felbontása hat napra redukálódik.

A műholdak egy C-sávú szintetikus apertúrájú radar segítségével 5,405 GHz frekvencián készítik a felvételeket (ESA SENTINEL ONLINE, 2021). A SAR műszer képes a VV és HH polarizáció mellett duál-polarizált módban működni, amely azt jelenti, hogy az oldalirányban kibocsájtott hullámok esetében megválasztható, hogy horizontálisan vagy vertikálisan legyen polarizált. Ugyanakkor már párhuzamosan tudja érzékelni mindkét polarizációt. Ez a funkció lehetővé teszi a HH+HV és VV+VH csatornákat, ezáltal a különböző polarizációk hatását együtt lehet vizsgálni.


A felszín monitorozásához négyféle felvételezési mód áll rendelkezésre, amelyek különböző felbontású képeket eredményeznek. Magyarországon az Interferometric Wide Swath (IW) mód érhető el, VV+VH duál-polarizációs módban. Az IW felvételezés során a beesési szög tartománya  $32,9^\circ - 43,1^\circ$ , ezáltal egy 250 km széles swath kerül felvételezésre, amelyen belül nagy geometriai felbontás (5 – 20 m) elérése a cél. Ennek érdekében a felvételezett 250 km széles területet további három sub-swath részre bontják, azimut iránnyal párhuzamosan, amelyeket egy új, úgynevezett TOPSAR technika segítségével felvételeznek. A Terrain Observation by Progressive Scans SAR, vagyis a TOPSAR képalkotó eljárás eredményként egy homogén, jó minőségű kép kapható az egyes swath-on belül, ezáltal az

azimut irányú felbontás tovább csökken (DE ZAN ÉS MONTI-GUARNIERI, 2006). Ennek következtében a range irányú felbontás 2,7 m – 3,5 m, míg az azimut irányú felbontás 22,5 m – 22,7 m között változik sub-swath-tól függően (ESA SENTINEL ONLINE, 2021).

A felvételek összesen háromféle terméktípusba sorolhatók, amelyek a különböző feldolgozottsági szintjük alapján különülnek el egymástól. A nyers felvételeket nulladik szintű termékeknek nevezzük, amelyek még alapvetően tömörített és fókuszálatlan adatokat tartalmaznak, ezért csak specifikus esetben ajánlott a használatuk. Ezek a felvételek képezik a magasabb szintű termékek alapját, amelyeket további feldolgozási lépések elvégzése által kaphatunk, a műholdpályának és a műhold helyzetének ismeretében.

A kutatásomban első szintű feldolgozott termékeket használtam fel, amely neve a Single Look Complex (SLC). Ezen termékek slant range geometriában készült fókuszált adatokat tartalmaznak, amelyek az amplitúdó értékek mellett a fázisra vonatkozó információkat is tartalmazzák komplex számok formájában. Emiatt nem végeznek rajta multilook eljárást, így az interferometrikus alkalmazások számára a fázisértékek nem vesznek el. Az IW módban készült, letöltésre kész SLC termékek összesen hat képből tevődnek össze, mivel minden egyes sub-swath (három darab) a két polarizációs csatornának megfelelően külön képként kerül feldolgozásra. A feldolgozás során lehetőségünk lesz a különálló részek egyesítésére.

A kutatáshoz IW módban készült első szintű SLC termékeket használtam fel a 2018-as évből, ami a hatnapos visszatérési idő miatt, január 4-től december 30-ig összesen hatvan terméket jelent. Minden felvétel a 153-as relatív orbit, leszálló pályán készült és az első felhasznált felvétel magyarországi lefedettségét a 3. ábra mutatja be.




3. ábra: A kutatáshoz felhasznált Sentinel-1 által 2018. január 4-én készült SLC termék magyarországi lefedettségét mutatja a piros téglalap.

## 4. Adatok és módszertan


### 4.1 Referenciaadatok

A kijelölt kutatási terület Pest, Heves és Jász-Nagykun-Szolnok megye határán helyezkedik el (4. ábra). A területhez tartozó referenciaadatokat a Magyar Államkincstár szolgáltatta az Anonimizált Kérelem adatbázis (ANONIMIZÁLT KÉRELEM ADATBÁZIS, 2018) alapján. Az adatbázis a parcellák területét, geometriáját, valamint az azon parcellára bejelentett termesztett növény típusait ismerteti a 2018-as évre vonatkozóan.



4. ábra: A referenciaterület (felül) és azon belül az egyes parcellák (alul) elhelyezkedése 2018-as évre vonatkozóan (Mindkét térkép EOY koordináta-rendszerben készült).

A kutatás során a területre jellemző nyolc leggyakoribb haszonnövény típusait vizsgáltam, amelyek a következők: kukorica, lucerna, napraforgó, őszi árpa, őszi búza, őszi káposztarepce, őszi tritikálé és tavaszi zöldborsó. A referenciaadatok előállításánál törekedtem a „nadrágszík” parcellák kiszűrésére, vagyis nem vettem figyelembe azokat a területeket, amelyeknek a hosszúsága jóval meghaladta a szélességét és az utóbbi nem éri el a legalább a két pixel szélességének a méretét. Továbbá az egy hektárnál kisebb földeket is kiszűrtem az adatrendszerből. Az így kapott referenciaadatokat az osztályozáshoz használtam fel, amely összterülete 56512 hektár lett. A növények további részletesebb elemzéséhez szükséges volt lecsökkenteni a parcellák számát, ekkor növénytípusonként 25 – 25 parcellát választottam ki, kivétel a zöldborsó és a tritikálé esete. Ezen típusokból csupán 15 parcellát vizsgáltam meg, mivel a területen jóval kevesebb található belőlük, így összesen 180 parcellát elemeztem külön (5. ábra). A kiválasztás során törekedtem arra, hogy az egyes parcellák területe öt hektárnál nagyobb legyen és lehetőleg ne kerüljön sok olyan parcella egymás mellé, amelyeken azonos növények fejlődnek. Megkülönböztetés céljából az egyes parcellák mindegyikéhez saját azonosító számot, id-t rendeltem. Ehhez először a táblaterületek alapján növekvő sorrendbe állítottam a parcellákat növényenként, majd egyéni azonosítót rendeltem hozzájuk a következő sorrend alapján: búza (1 – 25), árpa (26 – 50), repce (51 – 75), kukorica (76 – 100), napraforgó (101 – 125), lucerna (126 – 150), borsó (151 – 165) és tritikálé (166 – 180).



5. ábra: A szűrt adatrendszer parcelláinak elhelyezkedése (EOV koordináta-rendszerben).

## 4.2 Mezőgazdasági növények fejlődése

Az eredmények későbbi értelmezéséhez elengedhetetlen, hogy röviden ismertessem az egyes növénytípusokat a fenológiájuk szempontjából. A fontosabb információkat az 1. táblázat mutatja be.

|                       | Vetés                     | Szárbaindulás                   | Kalászhányás                     | Virágzás                       | Betakarítás                    |
|-----------------------|---------------------------|---------------------------------|----------------------------------|--------------------------------|--------------------------------|
| Kukorica              | április                   | május                           | június – július<br>(címerhányás) | június -<br>augusztus<br>eleje | október                        |
| Lucerna               | augusztus -<br>szeptember | április - május                 | -                                | -                              | augusztus -<br>szeptember      |
| Napraforgó            | április                   | május                           | -                                | július -<br>augusztus          | augusztus -<br>szeptember      |
| Őszi árpa             | ősz eleje                 | április                         | május eleje                      | május vége                     | június - július<br>eleje       |
| Őszi búza             | ősz eleje                 | március - április               | május vége                       | június eleje                   | június közepe -<br>július vége |
| Őszi<br>káposztarepce | ősz eleje                 | március vége -<br>április eleje | -                                | április - május                | június                         |
| Őszi tritikálé        | ősz eleje                 | március - április               | május                            | június eleje                   | június vége -<br>július        |
| Tavaszi<br>zöldborsó  | március                   | -                               | -                                | -                              | június vége -<br>július eleje  |

*1. táblázat: A vizsgált mezőgazdasági növénytípusok fő fejlődési szakaszainak (fenofázisainak) jellemző időszakai.*

Az 1. táblázat alapján megfigyelhető az árpa, a búza és a tritikálé hasonlósága. A tritikálét a búza és a rozs keresztezésével fejlesztették ki. Mindháromról elmondható, hogy kalászos haszonnövény és a fejlődési periódusuk is szinte megegyezik. A növények vetését ősz elején végzik el, amit egy hosszú alapszakasz követ, amikor a növény kikel, majd megtörténik a bokrosodás. A növények szárbaindulása majd csak a tavaszi időszakban következik be, amit a kalászhányás követ. Az őszi búza esetén a kalászhányás május végén és június elején történik, amíg az őszi árpa kalásza már május elején megjelenik. Ezt a kisárgulás, azaz a kiszáradás követi és megkezdődik a gabona érése. Az árpa korábbi beérése miatt, az aratása június második felére tehető, míg a búza és a tritikálé esetén a betakarítás június közepétől egészen július végéig is eltarthat.

A repce fejlődéséről azt érdemes tudni, hogy a kalászos növényekhez hasonlóan szintén ősz elején történik a vetése. Ritkább esetekben előfordul, hogy már ilyenkor szárba szökik a növény, de zömében ez a folyamat március végén és április elején következik be. A repcének nagyon jellegzetes citromsárga virága van, amely akár április végétől egészen május közepéig megcsodálható. Az aratás előtt a növényzet száradása, majd a betakarítása általában júniusban történik.

A lucernát is ebben az őszi periódusban szokták elvetni, amely egy pillangósvirágú, évelő növény. Jelentőségét az adja, hogy kitűnő tápanyag raktárral rendelkezik és sokoldalúan felhasználható. A vegetációs ciklusa évenként többször ismétlődik, hiszen ezt a takarmánynövényt egy nyári időszak alatt többször (háromszor, négyszer) kaszálják. Az utolsó kaszálást általában szeptemberben végzik el.

Szintén a pillangósvirágúak családjába tartozik a tavaszi zöldborsó, amit már március környékén el lehet vetni, mivel jól tűri a hideget. A borsó érettségét a hüvelyek színéből lehet megállapítani, amely június végén, július elején következik be, majd megkezdődik a betakarítása.

További tavaszi vetésű haszonnövények közé soroljuk a napraforgót, amelynek vetése után 60 – 80 nappal kezdődik a virágzása. A napraforgó virágát júliustól egészen szeptemberig figyelhetjük meg. Legkésőbb szeptember végéig meg szokott történni a betakarítása is, ami után pedig a kukoricaföldek aratása kezdődik meg. A kukoricának címere fejlődik, amely júniustól júliusig is eltarthat és teljesen éretté a szeptemberi és októberi időszakra válik.

### **4.3 Radarképek feldolgozása**

A referenciaterület kiválasztása után, letöltésre kerültek a Copernicus Open Access Hub (COPERNICUS OPEN ACCESS HUB, 2021) weboldáról, a kutatás területét lefedő, 2018-ban készült duál-polarizációs (VV+VH) felvételek, amelyek feldolgozásához a Sentinel Application Platform (SNAP) szoftvert (SNAP, 2021) és a QGIS (QGIS, 2021) térinformatikai programot használtam. A feldolgozás egyes lépéseit az ESA Sentinel-1 Tutorials (2020) alapján végeztem el, amely alapján kinyertem a kutatásomhoz szükséges koherencia értékeket, valamint a kalibrált intenzitás értékeket (sigma0).

A 2.4 fejezetben tárgyaltak alapján, a koherencia számítása két felvétel között történik, ezért a hatvan darab letöltött felvételt kronológiai sorrendbe rendeztem, majd minden egymást követő képpár között elvégeztem a feldolgozást. A vizsgálatokat tehát hatnapos bázisvonallal készítettem el, mivel a növekvő bázisvonal használatával nem lehet érdemi megállapításokat tenni a növények fejlődési folyamataira vonatkozóan az adott területről, valamint a legjobb eredményt a legrövidebb bázisvonallal lehet elérni (SIPŐCZ, 2021). Először a felvételekből kivágtam a vizsgálathoz szükséges területet és az egyes burst-öket egyesítettem a zéró Doppler-idejük szerint, majd a multilook operátort alkalmaztam. Eredményeként  $17,5 \cdot 22,6$  m-es térbeli felbontást és 14 – 15 m-es átlagos négyzetes pixel felbontást kaptam. A multilook eljárás egyfajta szűrőként is funkcionál, ilyen paraméterek mellett érdemes további térbeli

szűrőt is alkalmazni a speckle zaj csökkentésére. Erre a célra a Lee Sigma filtert (LEE ET AL., 2009) használtam, amely a nagyobb foltokat kisimítja, de geometriai alakzatokat és az éles széleket különböző felszínek között megőrzi. A SNAP szoftverben még topográfiai korrekciót is végeztem, amely az egyes felvételek slant range geometria által okozott torzulásokat korrekcióba veszi SRTM 1 SEC HGT (USGS, 2015) digitális magassági modell (DEM) felhasználásával, ezáltal WGS 84 koordináta-rendszer helyes kép kapható. Ezután a QGIS térinformatikai szoftverben a felvételeket WGS 84-ből EOV koordináta-rendszerbe transzformáltam, amely során a pixelek 15 m felbontásra való újramintázása is megtörtént. Az így kapott képeket VV és VH polarizáció szerint külön válogatva összevontam és megkaptam  $2 \cdot 59$  sávú koherencia stack képet.

A koherencia értékek legyártása után  $\sigma^0$  értékek feldolgozása következett, amikor a felvételek egyesével kerültek feldolgozásra. Ebben az esetben radiometrikus kalibrációt végeztem, amelynek lényege, hogy a műszer által felvételezett amplitúdó értékeket, a következő képlet alapján (ESA, 2015):

$$\sigma^0 = \frac{DN^2}{A_{dn}^2 K} \sin(\alpha), \quad (4)$$

szigma nought-tá ( $\sigma^0$ ) konvertálja, ahol  $\alpha$  a beesési szög,  $DN$  a digitális amplitúdó érték,  $A_{dn}$  a pixel átskalázási érték és  $K$  a kalibrációs konstans. A  $\sigma^0$  a felszíni szóró objektumokról reflektált radar jel normalizált értéke egységnyi felületre vetítve. Erre az egyes felvételek közti időbeli, műszer térbeli és leképezési paraméterek különbsége miatt van szükség és ezáltal a visszavert radarjel erőssége kapható meg  $0 - 1$  intervallumon. Ezt követően alkalmaztam a multilook eljárást és a Lee Sigma Speckle filtert. Hasonlóan a koherenciás feldolgozáshoz, leszűkítettem a felvételek területét és a topográfiai korrekciót is elvégeztem, majd az egyes pixelek értékeit egy logaritmikus skálára transzformáltam decibel mérőszámmal és így  $-35$  dB és  $+10$  dB között kaptam  $\sigma^0$  értékeket. Végül a QGIS szoftverben ugyanazokat a szükséges lépéseket hajtottam végre, mint a koherencia esetén azzal a különbséggel, hogy ebben az esetben a stack kép  $2 \cdot 60$  sávot tartalmaz időrendben.

A hatvan darab felvétel feldolgozása időigényes folyamat, ezért ennek a gyorsításának érdekében, a SNAP szoftver lehetőséget nyújt az egyes lépések összekötésére egy gráf segítségével, majd parancssorban történő futtatására. A futtatást Python (PYTHON, 2021) programnyelv segítségével végeztem.

#### 4.4 Idősoros vizsgálat

A Sentinel-1 termékeinek feldolgozása után, az említett soksávós képekből az egyes parcellákhoz tartozó adatok kinyerése, majd azokból idősoros görbék előállítása következett. Ehhez a folyamathoz a QGIS Temporal Spectral Profile Tool (TEMPORAL/SPECTRAL PROFILE TOOL, 2021) került alkalmazásra, Pythonban futtatva. A modul lehetőséget nyújt, hogy parcellánként kinyerje az egyes sávokból a poligonok területi statisztikáit, amelyek az idősorok előállításához elengedhetetlenek. Ezen adatok közé tartozik a parcellába eső pixelek száma, a parcellák pixeleinek az átlaga, valamint azok átlagos szórása. A futtatás eredményeit ezután külön táblázatokba rendeztem a módszerek, a két polarizált sáv és a növénytypusok szerint és a kapott átlag és szórás értékekből előállítottam az idősorokat ábrázoló grafikonokat.

Készítettem a koherencia és a sigma0 adatokból növénytypusonként átlag idősorokat, ahol időpontonként a 25 vagy 15 parcella értékeit átlagoltam. További elemzések szempontjából együttesen is ábrázoltam a parcellák görbéit, de a részletesebb elemzéshez szükséges parcellánként is külön-külön megvizsgálni az idősorokat. Elkészítettem ezért egyenként is olyan grafikonokat, amelyeken a VV és VH polarizált mód értékei együtt láthatóak.


A koherencia idősorok esetében figyelembe kellett venni, hogy a kapott értékek mindig két felvétel közötti változást reprezentálják, így a számított adatokat a grafikonokon minden esetben a későbbi időponthoz rendelve ábrázoltam, és ezt az értelmezés folyamán is figyelembe vettem. A koherencia idősoroktól az – 1.2 fejezetben leírtak alapján – azt várom, hogy az egyes görbék értékei a növények fejlődésével párhuzamosan lecsökkennek, egészen az aratás bekövetkezéséig, ami után az értékek újra visszaállnak a kezdeti állapotra.

#### 4.5 Kezdő- és végpont meghatározás

Továbbiakban megvizsgáltam, hogy a radar változókból származtatott idősoros profilokból meghatározható-e valamilyen fejlődésre jellemző idősor, esetünkben egy kezdő és egy végpont. Ezt a számítást a koherencia és sigma0 görbékre is elvégeztem összehasonlítás céljából az egyes növények fejlődésére vonatkozóan.

Az alapötletet az optikai felvételeknél az NDVI esetén használt módszer adta (KLISCH ÉS ATZBERGER, 2014), ahol a kapott görbékre meghatározzák egy növény fejlődési ciklusának kezdetét és végét. Az eljárás menete, hogy először a görbe minimum és az utána következő maximum érték különbségét képezik, amely értéket időszakos amplitúdónak neveznek el. Majd ennek az amplitúdó értéknek veszik a 20%-át és hozzáadják a minimum értékhez, és ahol ez

az érték metszi a görbét, megadja a növény fejlődésének a kezdetét, illetve hasonló szisztéma alapján végpontot. A 6. ábra illusztrálja a folyamatot.



6. ábra: A növény fejlődési szakaszainak meghatározása NDVI görbéken (KLISCH ÉS ATZBERGER, 2014).

Ezt a módszert átalakítottam úgy, hogy az egyes koherencia és a sigma0 görbékre is elvégezhető legyen, amely valójában a koherencia görbék viselkedésének ismeretében született meg. A sigma0 görbékre is ez került alkalmazásra, azzal a különbséggel, hogy az egyes lépéseknél nem maximumot, hanem minimumot, illetve a növekedés helyett a csökkenést vettem figyelembe.

A koherencia görbéknél először egy kiválasztott időintervallumban megkerestem azt a legnagyobb értékű pontot, amely után az értékek csökkenni kezdenek, ami a koherencia esetében a növény fejlődésnek indulását reprezentálja. Ebben az esetben ezt az értéket a növények különböző fejlődésének megfelelően szükséges volt változtatni. A búza, az árpa, a repce, a lucerna és a tritikálé kezdő maximumát március és április között kerestem, a tavaszi vetésű kukorica, napraforgó és zöldborsó esetén pedig április végétől május végéig. Ezután a végpont értékét és dátumát kerestem meg, azt feltételezve, hogy a végpont az aratáshoz köthető. Ez a tevékenység egy nagy időbeli változást jelent a számítás szempontjából, ezért az aratás bekövetkezése után kapott érték még alacsony, ami után újra jelentős mértékű növekedés tapasztalható a görbéken. Ezt a legnagyobb meredekségű növekedést kerestem szintén különböző időszakokban növényenként.

Az őszi vetésű növényeknél június közepétől július végéig tartó időszakra datáltam az aratást, egyedül a lucerna esetén a végpontot szeptember végéig vizsgáltam. A tavaszi vetésű

növényeknél szeptember elejétől október végéig tartó időszakot jelöltem ki végpont keresésre. Ez utóbbiak alól a borsó parcellák kivételnek számítottak, ahol az aratást június-július hónapokban vizsgáltam. A növekedés előtti, vagyis a kisebbik értékű időpontot vettem végül végpontnak. Ez az érték azt jelenti tehát, hogy a kapott időpontot megelőző hat napban történhetett meg a növények betakarítása.

A sigma0 görbénél azonban figyelembe kell venni, hogy napi mérési értékeket ad, ezért a legnagyobb mértékű csökkenés bekövetkezése után, szintén az alacsonyabb értékű pontot választottam végpontnak, ami az aratással feleltethető meg. Ha megkaptam ezt a két időpontot, akkor még a köztük lévő legalacsonyabb értéket kerestem meg, majd a kezdő maximum értékből kivontam a minimum értékkel vett különbségének a 20%-át. Ahol a kapott érték metszette a görbét, azt vettem a növény fejlődés kezdetének.

## 4.6 Szeparációs vizsgálat

A kutatás részeként tovább elemeztem a koherencia és a sigma0 idősorokat aszerint, hogy a különböző radar változók alkalmasak-e a nyolc haszonnövény elkülönítésére. A szeparációs vizsgálatokat PACSKÓ (2017) TDK dolgozata alapján végeztem el a kapott idősorokra, március 5. és október 1. közötti időablakban. Ez az időszak azért lett kiválasztva, mert az összes növény vegetációs folyamata beleesik és mivel a legnagyobb és leglátványosabb időbeli változások a területen ekkor következnek be. A számításokhoz a Sentinel-1 által pontosan 36 felvételezett időpont került így felhasználásra.

### 4.6.1 Távolságmátrix előállítása

A módszerrel összesen négy távolságmátrixot állítottam elő, mivel a koherencia és a sigma0 idősorokra külön alkalmaztam polarizációs csatornánként (VV+VH). Először a mátrix létrehozásához növénytípusonként kiszámítottam időpontonként a parcellához tartozó értékek átlagát, így létrehozva az átlaggörbét. Ezt követően minden egyes parcella idősoros görbét összehasonlítottam az átlaggörbékkel, vagyis időpontonként kiszámítottam a távolságukat és ezt négyzetre is emeltem. Végül a kapott értékeket időpontonként ( $i$ ), majd parcellánként ( $j$ ) is összegeztem. A számítás tehát a következőképpen néz ki, ha a repce távolságát a búzától szeretném megkapni:

$$\sum_j \sum_i (repce_j^i - búza_{j_{\text{átlag}}}^i)^2. \quad (5)$$

Az így kapott  $8 \cdot 8$ -as mátrix megadja, hogy mennyi az egyes növények „távolsága” ebben az időszakban az átlaggörbéjüktől, illetve a többi növény átlagától. Ezáltal megkapható,

hogy az egyes növényfajták, melyik növényfajta mutatnak hasonlóságot a legjobban és melyikektől lehet elkülöníteni őket a legjobban (PACSKÓ, 2017). Összességében azt várom, hogy minden növény görbéje a saját átlaghoz hasonlítson a legjobban, vagyis a távolságuk kisebb legyen, mint a másik hét növény átlagától számított érték.

#### **4.6.2 Keresztvalidáció**

Második vizsgálatként keresztvalidációt végeztem, mivel a távolságmátrix esetében az összegzés miatt a kiugró/szóró parcella értékek nem kapnak nagy hangsúlyt, így szükséges ezeket külön is megvizsgálni. Ezen módszeren belül tehát az összes parcella görbáját külön vizsgáltam és az egyes parcellákhoz nyolc értéket rendelem. Először kiszámítottam az éppen kiválasztott görbének időpontonként a távolságát az átlaggörbétől, annyi különbséggel a 4.6.1-es fejezethez képest, hogy ebben az esetben az adott növény átlaggörbéjébe nem számítom bele az aktuálisan vizsgált görbét, majd ezt megismétlem a maradék parcellákra és kapott értékeket parcellánként kiátlagoltam. Így ez az érték fogja mutatni, hogy az adott parcella mennyire tér el valójában az átlaggörbétől. A másik hét érték a további növényfajták teljes átlagától vett távolságát mutatja, szintén időben átlagolva az egyes parcellákra (PACSKÓ, 2017). Ezeket az értékeket grafikonokon ábrázoltam a parcellák függvényében. Az előző módszerhez hasonlóan az eredményektől ugyanazt vártam, hogy a növény saját átlagához viszonyított értéke legyen minden parcella esetében a legkisebb, illetve, ha az összes parcellát vizsgálom akkor a számítás során kapott egyes értékek elkülönüljenek.


### **4.7 Random Forest osztályozás**

Végezetül a koherencia és sigma0 adatokon klasszifikációt végeztem, amellyel tovább vizsgáltam a növények elkülöníthetőségét. Az osztályozást a Random Forest osztályozóval végeztem el, amely során a korábban (4.2 fejezet) ismertetett nyolcféle mezőgazdasági növényfajtával dolgoztam. A számítások során ugyanazt az időszakot használtam fel, mint az előző fejezetben, vagyis március 5-től október 1-ig.

Az osztályozás célja, hogy egy kiválasztott kép pixeleit előre meghatározott kategóriákba vagy osztályokba soroljuk. Az algoritmus a kép tartalma alapján keres az adott osztályokra jellemző tulajdonságokat, amely alapján később meg tudja őket különböztetni. A számítógépalapú interpretációk egyik típusa a felügyelt osztályozók, amely azt jelenti, hogy először tanítóadatokon megtanulja, hogyan néznek ki az egyes osztályok, majd ez alapján sorolja be a kép pixeleit. Ebbe a kategóriába sorolható a Random Forest osztályozó is, ami egy

együttes (ensemble) típusú gépi tanulási algoritmus. Más néven kombinált osztályozási módszernek is nevezik, mivel döntési fák halmazát számítja ki és ezek alapján végez többségi szavazást az egyes osztályokról (BRIEMAN, 2001). A módszer előnyei közé tartozik, hogy gyors és skálafüggetlen, vagyis eltérő jellegű és skálájú adatok is tud együtt kezelni. Hátrányként lehet megemlíteni, hogy könnyen alul- vagy felülmintavételezhetővé válik és az osztályok területi arányára is érzékeny. Fontos továbbá, hogy az algoritmus nem veszi figyelembe az időt, azaz minden egyes időpontú képet és réteget egymástól független változóként kezel.

A számítások elvégzése előtt szükséges a referenciaadat tanító- és tesztalmazra való felosztása. A tanítóadat alapján készíti el az osztályozó a modellünket, amely felhasználásával a kép minden pixelét besorolja valamilyen osztályba. Fontos, hogy a referenciaadatokban az osztályok mintaszámai jellemzően nem egyenlően oszlanak el, amire az osztályozó érzékeny lehet. Más szavakkal a különböző osztályokról nagyságrendileg több adat lehet, mint más osztályokról, ezért minél jobban törekedtem arra, hogy a tanítóadatokban az osztályok minél jobban kiegyenlítették legyenek. Erre azt megoldást választottam, hogy a dolgozatban a tanítóadatokhoz minden osztályból 50 parcella került véletlenszerűen kiválasztásra, így csökkentve az egyes osztályok közti nagyságbeli különbséget. A maradék parcellák képezték a tesztadatot, amely az osztályozásunk minőségének a vizsgálatára szolgál majd. A tanító- és tesztadat felosztását a 7. ábra mutatja be.



7. ábra: A referenciaadat tanítóadatra (a) és a tesztadatra (b) való felbontása.

Miután megtörtént a felbontás, a Shape fájlok raszterizálása következett, hogy a programba be tudjuk hívni matematikai tömbként. Fontos kikötést, hogy a raszterek méretének és a felbontásának meg kell egyeznie a koherencia és sigma0 értékeket tartalmazó soksávós raszterével. Az összes felhasznált referenciaadat parcellák és pixelek számát a 2. táblázat foglalja össze osztályonként. Megfigyelhető a borsó esetén, hogy ebből volt a legkevesebb parcella, de a tanítóadathoz kiválasztott parcellák mérete nagyobb volt, így ez az osztály lett második legjobban betanítva.

|                    | Referenciaadatok |                | Tanítóadatok    |               |                     | Tesztadatok     |                |
|--------------------|------------------|----------------|-----------------|---------------|---------------------|-----------------|----------------|
| Osztályok          | Parcellák száma  | Pixelek száma  | Parcellák száma | Pixelek száma | Osztályok eloszlása | Parcellák száma | Pixelek száma  |
| Őszi búza          | 2489             | 852159         | 50              | 17195         | 12,3%               | 2439            | 834964         |
| Napraforgó         | 1896             | 677234         | 50              | 20725         | 14,8%               | 1846            | 656509         |
| Kukorica           | 855              | 248049         | 50              | 13832         | 9,9%                | 805             | 234217         |
| Őszi árpa          | 646              | 199280         | 50              | 15903         | 11,3%               | 596             | 183377         |
| Őszi káposztarepce | 611              | 266786         | 50              | 23429         | 16,7%               | 561             | 243357         |
| Lucerna            | 463              | 136682         | 50              | 11952         | 8,5%                | 413             | 124730         |
| Őszi tritikálé     | 179              | 47618          | 50              | 13904         | 9,9%                | 129             | 33714          |
| Tavaszi zöldborsó  | 137              | 59293          | 50              | 23296         | 16,6%               | 87              | 35997          |
| <b>Összes</b>      | <b>7276</b>      | <b>2487101</b> | <b>400</b>      | <b>140257</b> |                     | <b>6876</b>     | <b>2346865</b> |

2. táblázat: A referenciaadatok, a tanítóadatok és a tesztadatok jellemzése növényfajtákra.

A Random Forest osztályozó alkalmazása Python programnyelvben történt, amelyhez az scikit-learn könyvtárcsomag (PEDREGOSA ET AL., 2011) algoritmusát használtam fel. Az osztályozás során a GDAL (GeoSpatial Data Abstraction Library) nevű függvénykönyvtár is szükség volt, hogy tudjam kezelni a távérzékelt és térinformatikai adatokat (GDAL/ORG CONTRIBUTORS, 2021). A Random Forest futtatásához fel kell építeni egy felparamétrezhető osztályozó modellt. A két legfontosabb paraméter a döntési fák száma és a döntési fák magassága. Természetesen további paraméterek is megadhatók (pl.: a minimum levelek száma vagy a maximális csomópontok száma), de ezekkel a dolgozat keretein belül nem foglalkoztam. Az algoritmus ezek alapján minden egyes mintára felállít több véletlenszerű döntési fát egy bizonyos magasságig, majd megvizsgálja a fák erősségét. Minden fa lead egy szavazatot és végül a különböző erősségű fákat, különböző súlyozással veszi figyelembe az osztályozó. Az így előállt modellt ekkor lehet illeszteni a tanítóadatokhoz és ezután következhet a kép osztályozása a modell alapján.

Az osztályozás lefutásakor megkaptam az osztályozott képet, amit az adott növények referenciaterületére kivágtam, mivel az osztályozó minden pixel értéket besorolt valamilyen előre meghatározott kategóriába, amik valójában nem ezek a kategóriák. Az így előállított növényterkép mellett megkaptam az egyes sávok fontosságát a számítások során, valamint az osztályozásra vonatkozó tévesztési mátrixot ( $T$ ), az osztályozott kép és a tesztadat pixelszintű összehasonlításából. Ez a mátrix azt mutatja meg, hogy az egyes pixelek hova sorolódnak be egymáshoz képest. A tévesztési mátrix főátlójában ( $T_{ii}$ ) található azoknak a pixeleknek a száma, amiket az adott növény esetén helyesen osztályozott, az ezen kívüli tagok pedig a rosszul osztályozott pixelek számát ismerteti. A tévesztési mátrixból az osztályozás jellemzésére

szolgáló különböző pontossági értékek számolhatók ki, amik közül a négy leggyakrabban használt pontosságot számoltam ki: teljes (overall) pontosságot ( $OA$ ), az előállítói (producer's) pontosságot ( $PA$ ), a felhasználói (user's) pontosságot ( $UA$ ) és a kappa pontosságot ( $K$ ) (CONGALTON ÉS GREEN, 2008).

A teljes pontosságot a következőképpen lehet kiszámítani:

$$OA = \frac{\sum_{i=1}^N T_{ii}}{\sum_{i=1}^N \sum_{j=1}^N T_{ij}} * 100, \quad (6)$$

vagyis az átlóban található pixelek és az összes pixel számának a százalékos arányát adja meg. Ez a pontosság megmutatja, hogy a tesztadatok pixeleinek hány százalékát sikerült helyesen osztályozni. A teljes pontosság összességében jellemzi a térképünket, ugyanakkor ez a mérték nem veszi figyelembe az osztályok közötti kiegyensúlyozatlanságot, ezért van szükség finomabb pontossági érték kiszámítására. A kappa pontosságot azért érdemes kiszámítani, mert úgy adja meg a program az osztályozás pontosságát, hogy a pontonkénti egyezés (átlóban található pixelek száma) és a képpontonkénti területi egyezésen (az egyes sorokban és oszlopokban található pixelek számának a szorzatának az összege) alapul. Ez a mérték jobban figyelembe veszi, ha egy nagyobb kategória jobb pontosságot vagy egy kisebb osztály rosszabb pontosságot ad, vagyis érzékenyebb az osztályonkénti pontosságra. A kappa számítása a következő egyenlet szerint történik:

$$K = \frac{N * D - \sum_{i=1}^M O(i) * S(i)}{N^2 - \sum_{i=1}^M O(i) * S(i)} * 100, \quad (7)$$


ahol  $N$  az összes pixel száma,  $D$  a helyesen osztályozott, vagyis az átlóbeli pixelek szám,  $M$  az osztályok száma,  $O(i)$  a tévesztési mátrix  $i$ -dik oszlopban található pixelek számának összege és  $S(i)$  a tévesztési mátrix  $i$ -dik sorában található pixelek számának összege. Minél nagyobb értéket kapunk, annál jobban sikerült az osztályozás.

Az előállítói és a felhasználói pontosság az egyes osztályokra vonatkozó pontosságot adja meg különböző szempontok szerint. Az előállítói pontossága meghatározza, hogy az adott osztályba potenciálisan tartozó területeknek hány százalékát sikerült megtalálni. Számításához az adott osztály helyesen besorolt pixeleinek a számát kell elosztani a felhasznált adathalmazban található pixeleinek számával. Ezzel szemben a felhasználói pontosság megmutatja az adott osztályban helyesen térképezett elemek arányát. Az értéke alapján arra lehet következtetni, hogy a térképen milyen gyakorisággal fordulnak elő az egyes osztályok. Ez az érték úgy kapható meg, hogy az osztályonként pontosan kategorizált pixelek számát elosztjuk az adott kategóriába sorolt összes pixel számával. Ennek a két értéknek nem kell megegyeznie osztályonként, ezáltal jobban ki lehet értékelni a kapott eredményeket.

## 5. Eredmények

### 5.1 Átlag idősorok eredményei


Az előállított átlag koherencia idősorok a nyolc vizsgált növényre a 8. ábrán láthatóak. A hatnapos bázisvonalú idősorokról elmondható, hogy minden növény fejlődési időszaka kirajzolódik a grafikonokon. Ez a jelenség a koherencia értékek és szórásuk csökkenésének, valamint a polarizációs görbék egymásra simulásának formájában jelenik meg, mivel az egyes felvételek közötti időbeli változás hatására a koherencia lecsökken. A grafikonok alapján a SAR csak a szárbaindulás szakaszától kezdve érzékeli a növények fejlődését. Az idősorokon a koherencia értékek 0,3 és 0,9 között mozognak, ami arra utal, hogy jó eredményeket kaptam. A 0,3 körüli alacsony értékek sorozata egészen a betakarítási időszakig tart, majd az aratás után a koherencia értékek újra növekedni kezdenek a vegetáció hiánya miatt. Például a napraforgó esetén a csökkenés májusban következik be, majd a koherencia újra növekedésnek indul szeptember elejétől kezdve, vagyis a betakarítás után. A lucerna során hosszabb ez az intervallum a növény többszöri kaszálásának hatására. Mivel ez az alacsony koherenciájú időszak növényenként eltérő, ezért valóban ígéretes paraméter lehet az osztályozás során a koherencia, bár a búza és az árpa, valamint a kukorica és a napraforgó esetén is hasonló az idősorok lefutása, így nehezen lehet őket elkülöníteni.



8. ábra: Az átlag koherencia idősorok hatnapos bázisvonallal a nyolc növényre.

Megfigyelhető továbbá a grafikonokon a VH és VV értékek közötti különbség is. A két görbe hasonló fejlődést mutat az év során, kivétel a borsó esete, viszont a VV polarizáció esetén a görbék nagyobb értékeket vesznek fel a VH módhoz képest. Ez abból következhet, hogy a cross-polarizált jel gyengül a visszaverődés során, így nehezebben vehető ki csak általa a növény fejlődése.

A fenti koherencia idősorok alapján az átlag sigma0 idősorokról szintén megállapítható, hogy a növényenként más és más görbe rajzolódik ki, a fejlődési szakaszuknak megfelelően. A növények átlag sigma0 idősorait a 9. ábra mutatja be.



9. ábra: Az átlag sigma0 idősorok hatnapos bázisonnal a nyolc növényre.


A grafikonok alapján ugyanúgy fellelhető a búza és az árpa hasonló fejlődése, illetve a tritikálé görbéi is hasonlóak, míg a kukorica és a napraforgó kevésbé hasonlóak. A koherencia átlag idősorokhoz képest egy fordított irányú fejlődés figyelhető meg, azaz a növények szárbaindulásával a sigma0 értékek többnyire növekednek, kivétel a búza és az árpa esete. Ezeken a görbéken előbb egy csökkenés következik be, majd utána nőnek a sigma0 értékek.

A két polarizációról elmondható, hogy a VH értékek mindig a VV görbék alatt maradnak, sőt el is válnak itt teljesen, így a növény fejlődése mindkettőn megfigyelhető. Továbbá bár jellemzően a VV és VH idősorok hasonló lefutást mutatnak, a repce, lucerna és borsó esetében nagyobb dinamika figyelhető meg a VH görbéken.

## 5.2 Koherencia idősorok elemzése parcellánként

Ebben a fejezetben az egyes parcellák görbéinek (A függelék) jellemzőit és ehhez kapcsolódó megfigyeléseimet mutatom be, mivel az átlag idősorok alapján nem lehet megfigyelni azokat a görbéket, amik eltérő viselkedést mutatnak az átlaggörbékhez képest.


Először a búza és az árpa esetét ismertetem. A két haszonnövény idősorai hasonlóságot mutatnak, ami megfelel a várakozásoknak, hiszen a fejlődési periódusuk szinte megegyezik. A csökkenés április elején kezdődik és június végétől, július elejétől újra növekedés következik be, ami megfelel vegetációs időszaknak. A korábban bemutatott átlaggörbék nem a legalkalmasabbak a pontosabb elemzések elvégzéséhez, ezért elkészítettem a 10. ábra grafikonjait. Ezeken a búza és az árpa parcellák koherencia görbéit együtt ábrázoltam.



10. ábra: Búza (felső sor) és árpa (alsó sor) parcellák koherencia idősorai együtt ábrázolva VH és VV polarizációk szerint, amiken megfigyelhető, hogy hasonló fejlődésűek (ápr.-jún.).


A 10. ábra alapján észrevehető, hogy több parcella esetén is a növények fejlődés kezdetének megfelelő csökkenés hosszabb időn keresztül tart, így a görbéken egy ferde lefutás figyelhető meg. Erre a jelenségre példa a búzaföldek esetén az 1. (11. ábra), a 6., a 15. és a 17. parcella. Ezzel szemben az árpa görbéknél már nehéz a ferde lefutásukat elkülöníteni, mivel jóval több ilyen eset tapasztalható. Ezekről a parcellákról az feltételezhető, hogy később,

illetve lassabban kezdtek el fejlődni, mivel valószínűsíthetően vizenyős területek vagy valamilyen káros hatás következtében a növények nagy része elhalt. Mindezek alapján arra következtettek, hogy az űrfelvételek segítségével lehetséges az egyes parcellák minőségének megfigyelése. A többi növény idősorain is megjelenik ez a ferde lefutás egy-egy parcella esetén. A 11. ábrával szeretném érzékeltetni, egy rosszul és egy jól fejlődő parcella különbségét.




11. ábra: Az 1. búza parcella koherencia idősora (bal), amin látszik, hogy ezen a területen a növények lassabban fejlődtek (ferde lefutás), illetve egy jól fejlődő búzaföld koherencia idősora (jobb).

A 10. ábra grafikonjain az is látszik, hogy május 30. környékén több esetben az értékek kiugranak. Ez a jelenség azért is érdekes, mivel ebben az időszakban még biztosan változások következnek be a növények fejlődése által, amelyek hatására a koherencia értékeknek alacsonyan kéne maradniuk. Először ezt az anomáliát az időjárás hatásának feltételeztem. Utánajárva kiderült, hogy nem történt ilyen esemény a felvételezés órájában, így erre a jelenségre nem sikerült magyarázatot találni. A kiugrás továbbá megfigyelhető a repce, valamint a tritikálé esetén is (10. ábra, 12. ábra). A sigma0 idősorok görbéin (9. ábra) viszont semmilyen változás nem jelentkezett május végén egyik grafikonon sem.




12. ábra: Az 52. repce parcella koherencia idősora (bal) és a 171. tritikálé koherencia idősora (jobb), amelyek példák a május 30-án megfigyelhető érték kiugrásra.

A repce parcellák koherencia idősorain megfigyelhető, hogy a növény fejlődési időszaka április elejétől körülbelül július elejéig tart (13. ábra). Ugyanakkor az előbb említett május 30-án észlelt kiugrás is fellelhető ezen az ábrán, mind a VH, mind a VV görbéken.




13. ábra: Repce parcellák koherencia görbéinek együttes ábrázolása VH (bal) VV (jobb) polarizációk szerint. A repce fejlődési időszaka csak a VV görbéken figyelhető meg.

Az egyes parcellák koherencia görbéit külön is megvizsgáltam, melynek eredményeként azt tapasztaltam, hogy a kapott görbék közül egyik se adja vissza igazán a repcére jellemző fejlődési időszakot. Megfigyelhető az idősorokon, hogy a VH polarizációs értékek nem csak a növény fejlődésekor maradnak alacsonyak, hanem előfordul, hogy az értékek ősz elejéig is a 0,3 körül ingadoznak. Ekkor néhány VV kiugrás figyelmeztethet az esetleges aratás megtörténésére, de utána a VV görbe is újra lecsökken. Előfordul több esetben az is, hogy az év hátralevő részében az eredmény a növekvő bázisvonalú koherencia görbékre hasonlít a VH polarizáció esetén, ami azt jelenti, hogy egy bizonyos idő után a koherencia értéke egy bizonyos számhoz konvergál. E két eset szemléltetésére jó példa többek között az 51. és a 61. parcella koherencia idősorának esete, ami a 14. ábrán figyelhető meg. Ennek eredményeként azt gondolom, hogy a repce fejlődésének kimutatására a koherencia módszere nem alkalmas.




14. ábra: Az 51. (bal) és a 61. (jobb) repce parcellák koherencia idősorai, ami szemlélteti, hogy a koherencia idősorok alapján nem állapítható meg a növény fejlődése a repce esetén.

Következőnek a kukorica és a napraforgó koherencia idősorait mutatom be, amelyeken a növények hasonló vegetációs periódusának megfelelően azonos jellemzők figyelhetők meg (15. ábra). Mivel mindkét növény tavaszi vetésű, ezért a fejlődésük májusban kezdődik, ahogy az a grafikonokon is látható. Az aratás dátuma az idősorok alapján szeptemberre datálható, viszont a kukorica betakarítása biztosan később következik be a valóságban, így ez nem pontos.



15. ábra: Kukorica (a-b) és napraforgó (c-d) parcellák koherencia idősorai együtt ábrázolva VV és VH polarizáció szerint. Megfigyelhető, hogy a két növény idősora nagyon hasonló.




16. ábra: Lucerna parcellák koherencia görbéinek együttes ábrázolása VH (bal) VV (jobb) polarizációk szerint, amiken nehezen vehető ki a növény fejlődési időszaka.

A lucerna parcellák görbéin (16. ábra) az jelenik meg, hogy a tavaszi időszaktól kezdve alacsony koherencia értékek láthatóak, egészen az utolsó kaszálásig. Ez augusztus és

szeptember környékén szokott bekövetkezni. Ez a fejlődési szakasz a VH idősorokon alig vehető ki, míg ezen időszak alatt a VV koherencia görbék zavaros viselkedése tapasztalható.

A görbék zavaros viselkedése szintén megjelenik a zöldborsó, valamint a tritikálé parcellák esetén is (17. ábra). A borsóföldek idősorain a koherencia értékek a VH görbéken már márciusban lecsökkennek, ezzel szemben a VV görbéken a csökkenés csak április közepénél következik be. A borsó márciusi vetése miatt úgy gondolom, hogy a VV görbék viselkedése követi le pontosabban a valóságot. Az értékek növekedése június-július környékén kezdődik, ami megfelelő a borsó vegetációs ciklusának. A tritikálé esetén szintén megállapítható, hogy inkább a VV görbék segítségével lehet lehatárolni a növény fejlődési szakaszait. Május 30. környékén viszont a koherencia értékek jellemzően megnövekednek, ami szintén zavarja a görbék elemzését. Ezek alapján a VH görbéket e két növénynél nem tartom alkalmasnak a fejlődés vizsgálatára.




17. ábra: Zöldborsó (felső sor) és tritikálé (alsó sor) parcellák koherencia idősorai együtt ábrázolva VV és VH polarizáció szerint. A VH görbékről nem állapítható a növény fejlődése.

### 5.3 Kezdő- és végpont meghatározás eredményei

A kezdő- és végpont számításos módszer alapján igyekeztem meghatározni a növények fejlődésének valószínűsíthető kezdetét és az aratás időpontját az egyes koherencia idősorokon. A kapott eredmények alapján összevetettem a koherencia görbéket a sigma0 idősorokkal,

amikre szintén elvégeztem a vizsgálatot. Mindkét idősor elemzésekor figyelembe kell venni, hogy a kapott dátumokat megelőző hat nap is hozzátartozik az eredményhez, vagyis napra pontosan nem lehet lehatárolni például az aratást, hiszen csak időintervallumban lehet gondolkodni a hatnaponta készült felvételek alapján.


Az eljárás eredményeként a búza parcellák esetén a kezdőpontok zömmel április elejére esnek és ez megfelel a növények szárbaindulási időszakának. A végpontot vizsgálva az aratás feltételezhető ideje júliusra tehető, bár kilenc parcella végpontja polarizáltságonként eltért. Ennek az lehet a magyarázata, hogy a koherencia VH görbéin nem történik a júniusi-júliusi időszakban jelentős mértékű értéknövekedés, amihez az aratást kötni lehetne. A VV idősor alapján ugyanakkor mindig sikerült egy olyan végpontot meghatározni, ami összevethető a sigma0 idősorokra számolt végpontokkal. Egyezésnek azt vettem, ha az időpontok között maximum hat nap változás van, ami két felvételezés között eltelt időnek felel meg. Ezek alapján összességében a kezdőpontok esetén eltérés tapasztalható, míg a végpontok alapján előfordult egyezés is. A sigma0 idősorokra számolt kezdőpontok már polarizáltságonként is eltérőek, vagyis a VV módnál április végi és májusi időpontok (feltételezhetően a kalász fejlődés) adódtak, míg a VH polarizáció esetén májusi időpontok mellett még jelentős számban március végi és április eleji időpontok (szárbaindulási állapot) is előfordultak (18. ábra). Így ezzel a módszerrel nem sikerült azonosságokat találni az idősorok között teljes mértékben, mivel csak a végpontok egyeztek meg a két módszernél.



18. ábra: A 15. búza parcella koherencia (bal) és sigma0 (jobb) idősora a meghatározott kezdő- és végpontokkal. A sigma0 kezdőpontok esetén a piros a VH és a kék a VV.

Az árpa parcellák esete nagyon hasonló az előbb ismertetetthez. A kezdőpontok ebben az esetben is a koherencia görbék alapján, április elejére estek, míg a sigma0 görbéken márciustól májusig kaptam időpontokat. Ez alapján nem vethetőek össze. A koherencia végpontok június végére és júliusra tehetőek, ami többször is egyezik a sigma0 idősorokra kapott eredményekkel.


A repcére a kezdő- és végpont számításakor kapott értékekről annyit sikerült megállapítani, hogy a kezdőpontok a koherencia esetén április elejére tehetőek. Ezzel szemben a sigma0 görbéken március végi időpontok feleltethetőek meg a növény fejlődésének kezdetére. A végpontok esetében zömében június végi és júliusi időpontokat kaptam, viszont ezek alapján kilenc repceföldnél tapasztaltam egyezést a koherencia és a sigma0 görbék között. Ezen megfigyelésekre példa az 58. repce parcella esete, amelyet a 19. ábrán lehet megfigyelni.



19. ábra: Az 58. repce parcella koherencia (bal) és sigma0 (jobb) idősorai kezdő- és végpontokkal, amik nem egyeznek meg, így nem lehető fel azonosság közöttük.

Következőnek a kukorica parcelláit vizsgáltam, amelyek koherenciára kapott kezdőpontjai 18 esetben megegyeznek a két polarizációra és ezek májusi időpontok egy parcella kivételével, amikor június elején kezdődik a növény szárbaindulása a számítás alapján. A végpontok, vagyis az aratások időpontjai szintén azonosak VV és VH koherencia idősorok alapján három eset kivételével és szeptemberre vagy októberre tehetőek. Ezek az eredmények megfelelnek a növény valós fejlődésének, valamint az idősorokon látottaknak. Ezen időpontok összevetése a sigma0 görbéknél kapott eredményekkel nem volt sikeres. Hat napon belüli egyezést csak hét parcella esetén tapasztaltam a kezdőpontoknál, míg nyolc parcellánál a végpont egyezett.


A napraforgó parcelláira kapott időpontokat megvizsgálva arra jutottam, hogy ezzel a módszerrel a koherencia esetén sikerült jól lehatárolni a növény fejlődésének kezdetét, amit a májusi kezdőpontok jelölnek. A végpontokra viszont októberi időpontokat kaptam, amelyet már a görbéken is megfigyeltem, de ekkor már általában a napraforgó betakarítási időszakának vége, így ez téves (20. ábra). A sigma0 idősorok esetén a végpontokra valóságnak megfelelőbb szeptemberi időpontokat és májusi kezdőpontokat kaptam, tehát egyezést itt sem tapasztaltam.



20. ábra: A 109. napraforgó parcella koherencia (bal) és sigma0 (jobb) időszora a meghatározott kezdő- és végpontokkal. A számítás alapján a koherencia görbe végpontja tévesen októberre esik, mivel ekkor a napraforgót már betakarították.

A számítás alapján a fejlődés kezdete a lucerna koherencia időszorai esetében áprilisra tehető, viszont a sigma0 idősorokkal ez az eredmény nincs összhangban, és ugyanez tapasztalható a végpontoknál is. A végpontok között ugyan augusztusi és szeptemberi időpontok szerepelnek, de több mint hat nap elcsúszás van nem csak a két idősor, hanem azokon belül a polarizációk között sincs teljes egyezés az esetek többségében.

A tavaszi vetésű zöldborsó koherencia időszorai alapján április végi kezdőpontokat kaptam, két parcella kivételével hat napon belüli egyezéssel. Bár a sigma0 kezdőpontokkal nem volt sikeres az összevetésük, mivel a VV esetben 11 parcellánál májusi időpontok adódtak, míg a VH-ra kapott kezdőpontoknál egyezést tapasztaltam. A végpontokat megfigyelve hat parcellánál volt azonosság, de minden esetben júniusi vagy júliusi időpontokat kaptam. Ezt az egyezést a 21. ábrán is meg lehet figyelni.



21. ábra: A 152. tavaszi zöldborsó parcella koherencia (bal) és sigma0 (jobb) időszora a meghatározott kezdő- és végpontokkal, amely esetében azonos kezdő- és végpontokat kaptam a két időszorra.

Az őszi tritikálé esetén azt tapasztaltam, hogy a koherenciára kapott kezdőpontok mind a valóságnak megfelelően április eleji időpontok, míg a sigma0 kezdőpontokra a búza és az árpa esetéhez hasonlóan keveredés tapasztalható. Ezzel szemben a végpontokra júniusi és júliusi időpontokat kaptam, de ekkor polarizációnként is eltértek az eredmények, így az összevetés ekkor sem volt sikeres a sigma0 idősorokkal.

A módszer hatékonyságát a 3. táblázat foglalja össze, amely alapján összeségében elmondható, hogy ezzel az eljárással a koherencia görbéken a kezdőpont, vagyis a szárbaindulás időszaka összeségében jól lehatárolható, míg a betakarítás időszakának meghatározása kevésbé bizonyult sikeresnek. Továbbá a sigma0 idősoroknál kapott időpontok alapján megállapítható, hogy összevetve a koherenciával szintén nem megfelelő ez a módszer.

|                    | Kezdőpont     |               |           |           | Végpont       |               |           |           |
|--------------------|---------------|---------------|-----------|-----------|---------------|---------------|-----------|-----------|
|                    | Koherencia VH | Koherencia VV | Sigma0 VH | Sigma0 VV | Koherencia VH | Koherencia VV | Sigma0 VH | Sigma0 VV |
| Őszi búza          | 100%          | 100%          | 52%       | 8%        | 64%           | 92%           | 92%       | 84%       |
| Őszi árpa          | 100%          | 100%          | 60%       | 0%        | 80%           | 88%           | 76%       | 68%       |
| Őszi káposztarepce | 92%           | 100%          | 100%      | 92%       | 40%           | 40%           | 20%       | 24%       |
| Kukorica           | 92%           | 92%           | 100%      | 92%       | 96%           | 100%          | 72%       | 80%       |
| Napraforgó         | 96%           | 96%           | 100%      | 100%      | 36%           | 32%           | 100%      | 100%      |
| Lucerna            | 100%          | 100%          | 100%      | 88%       | 92%           | 80%           | 96%       | 96%       |
| Tavaszi zöldborsó  | 87%           | 93%           | 100%      | 100%      | 93%           | 93%           | 100%      | 100%      |
| Őszi tritikálé     | 100%          | 100%          | 80%       | 20%       | 87%           | 87%           | 87%       | 93%       |

3. táblázat: A kezdő- és végpont meghatározási módszer sikerességének összefoglalása.

## 5.4 Szeparációs vizsgálat eredményei

### 5.4.1 Távolságmátrix elemzés eredményei

A kapott távolságmátrixok a 4. táblázatban láthatók, amelyek soraiban a megjelölt növényeknek az oszlopokban megjelölt növények átlaggörbéjétől számított távolsága található.

Mindkét radarparaméter és polarizáció esetét megvizsgálva eredményeként az jött ki, hogy az adott növény minden esetben a saját átlagára hasonlít a legjobban. Ez abból következik, hogy az egyes sorokban az adott növény saját átlagától vett távolságok a legkisebbek, vagyis a főátlóban található értékek. Összességében elmondható, hogy ezen módszer alapján az egyes növények elkülöníthetőek a kiválasztott időszakban.


|               | Átlagok    |          |          |          |          |            |          |         |           |
|---------------|------------|----------|----------|----------|----------|------------|----------|---------|-----------|
|               |            | Búza     | Árpa     | Repce    | Kukorica | Napraforgó | Lucerna  | Borsó   | Tritikálé |
| Koherencia VV | Búza       | 9,97     | 12,3     | 13,84    | 27,64    | 26,99      | 18,53    | 24,79   | 11,73     |
|               | Árpa       | 12,15    | 9,81     | 15,44    | 29,61    | 30,66      | 23,79    | 20,48   | 14,57     |
|               | Repce      | 14,58    | 16,34    | 10,72    | 32,07    | 31,28      | 17,12    | 32,5    | 13,46     |
|               | Kukorica   | 26,5     | 28,65    | 30,2     | 8,85     | 11,14      | 22,65    | 34,9    | 22,5      |
|               | Napraforgó | 26,11    | 29,94    | 29,6     | 11,38    | 9,09       | 18,84    | 34,49   | 21,65     |
|               | Lucerna    | 11,89    | 17,31    | 9,73     | 17,13    | 13,06      | 3,33     | 32,57   | 7,9       |
|               | Borsó      | 20,66    | 18,05    | 24,84    | 25,63    | 27         | 29,31    | 11,77   | 21,68     |
|               | Tritikálé  | 5,5      | 7,32     | 6,11     | 12,65    | 11,99      | 7,2      | 14,37   | 4,46      |
| Koherencia VH | Búza       | 3,18     | 4,11     | 4,69     | 5,4      | 5,16       | 4,58     | 5,98    | 4,14      |
|               | Árpa       | 4,54     | 3,62     | 6,45     | 6,57     | 7,26       | 6,82     | 7,33    | 5,66      |
|               | Repce      | 4,49     | 5,83     | 3        | 8,71     | 8,15       | 4,15     | 8,85    | 4,31      |
|               | Kukorica   | 4,83     | 5,56     | 8,32     | 2,61     | 3,3        | 6,6      | 5,7     | 5,79      |
|               | Napraforgó | 4,73     | 6,39     | 7,91     | 3,44     | 2,75       | 5,63     | 5,3     | 5,82      |
|               | Lucerna    | 2,54     | 4,35     | 2,3      | 5,14     | 4,02       | 1,15     | 6,01    | 2,36      |
|               | Borsó      | 3,94     | 4,49     | 5,78     | 3,65     | 3,79       | 5,18     | 2,26    | 4,77      |
|               | Tritikálé  | 2,09     | 2,75     | 2,31     | 3,43     | 3,36       | 2,25     | 4,03    | 1,52      |
| Sigma0 VV     | Búza       | 1584,98  | 2963,11  | 11300,95 | 6093,22  | 12280,18   | 3980,73  | 7435,8  | 2658,29   |
|               | Árpa       | 2894,63  | 1516,49  | 7454,59  | 3941,03  | 8034,02    | 4627,18  | 4282,11 | 3405,5    |
|               | Repce      | 11485,6  | 7707,71  | 1769,61  | 5018,38  | 9280,53    | 8191,46  | 3805,1  | 8565,31   |
|               | Kukorica   | 5546,12  | 3462,42  | 4286,66  | 1037,88  | 4201,19    | 5839,85  | 2337,99 | 5395,69   |
|               | Napraforgó | 12638,9  | 8461,18  | 9545,58  | 5106,96  | 1943,66    | 13816,63 | 6212,45 | 13448,2   |
|               | Lucerna    | 3671,33  | 4386,27  | 7697,44  | 6077,55  | 13148,5    | 1275,59  | 6953,07 | 1926,8    |
|               | Borsó      | 4411,27  | 2560,15  | 2122,07  | 1584,26  | 3462,05    | 4307,27  | 900,78  | 3900,41   |
|               | Tritikálé  | 1543,39  | 2034,01  | 4978,03  | 3515,29  | 7803,33    | 1291,33  | 3900,24 | 900,61    |
| Sigma0 VH     | Búza       | 2085,31  | 3299,14  | 16044,54 | 7297,6   | 9000,46    | 6408,62  | 6408,62 | 2985,02   |
|               | Árpa       | 2728,36  | 1514,43  | 10428,18 | 5761,44  | 6755       | 3080,01  | 3412,58 | 2575,58   |
|               | Repce      | 17012,57 | 11966,99 | 3053,35  | 20083,93 | 20947,36   | 14321,67 | 10683,4 | 13753,2   |
|               | Kukorica   | 6651,59  | 5686,2   | 18469,88 | 1439,3   | 1988,5     | 5100,33  | 7362,72 | 6745,72   |
|               | Napraforgó | 8603,67  | 6928,98  | 19582,53 | 2237,73  | 1688,52    | 6664,09  | 8128,72 | 8771,18   |
|               | Lucerna    | 4324,93  | 3759,77  | 13462,61 | 5855,33  | 7169,86    | 2194,29  | 5268,76 | 3019,3    |
|               | Borsó      | 3879,04  | 2423,88  | 5863,09  | 4576,26  | 5149,17    | 3129,74  | 1285,06 | 3271,01   |
|               | Tritikálé  | 1710,36  | 1808,96  | 7590,44  | 4354,39  | 5420,12    | 1665,53  | 3156,48 | 1170,53   |

4.táblázat: Távolagsátmatrixok a koherencia és a sigma0 görbékre, ahol a főátlókban található kiemelve az adott növény saját átlagától vett távolsága. Minden sorban az látható, hogy ezek a legkisebb értékek, vagyis sikeres a szeparáció.

### 5.4.2 Keresztvalidáció eredményei


Az eredményként kapott értékeket grafikonokon ábrázoltam növénytípusonként az egyes parcellák szerint. Így a nyolc növénytypust vizsgálva a koherencia, sigma0 és a két polarizáció alapján összesen 32 diagram készült. Az elkülöníthetőség szempontjából azt várom, hogy az adott növény saját átlagától vett távolsága ennél a vizsgálatnál is a legkisebb legyen.

Kiértékelve az egyes diagramokat készült el a 22. ábra, ami összefoglalja, hogy az egyes esetekben a parcellák hány százalékát sikerült megfelelően elkülöníteni. A táblázatot elemezve szembetűnő, hogy a legrosszabb eredmények a koherenciára születtek, míg a legjobbkat a sigma0 oszlopokban találhatók. Ez a tény szintén tovább erősíti azt a feltételezést, hogy a koherencia kevésbé alkalmas az ilyen irányú alkalmazáshoz.




22. ábra: Keresztvalidáció hatékonysága növénytípusonként az egyes radarparaméterek polarizációinak megfelelően. Az egyes értékek azt jelzik, hogy az adott parcellák esetén milyen százalékban volt sikeres az elválasztás.

A koherencia diagramok alapján nagy keveredés tapasztalható a búza, a repce és a tritikálé parcelláknál (23. ábra). Ez a növények hasonló fejlődésének tudható be, viszont azért érdekes, mert az árpa parcellákra kapott eredmények jobbak. Ugyanakkor a polarizációk között meglepő eltérés tapasztalható. Hat osztállynál a VH koherenciára jobb eredményt kaptam, míg kettőnél azonos arányban volt sikeres a szeparáció. A legsikeresebb szétválasztást a VH koherencia esetén a borsóra kaptam, amikor a 15 parcella közül 13-nál volt a legkisebb a borsóra kapott érték.




23. ábra: Keresztvalidáció VV koherenciára búza (bal) és VV koherenciára repcére (jobb) esetén. A két növény esetén parcellánként lebontva ábrázolom, hogy az adott növény melyik növény átlagához hasonlít a legjobban, vagyis ahhoz amelyikre a legkisebb érték adódik.

A koherenciára kapott kukorica és a napraforgó keresztvalidációjának értékei ugyan elválnak a többi növénytől, aminek a fő oka, hogy más időszakban vetik és fejlődik ez a két növény, de nehezen lehet őket elkülöníteni egymástól. Ezt a 24. ábra szemlélteti, amelyen a 116-os napraforgó parcella esetén eddig ismeretlen okból kiugrás figyelhető meg.



24. ábra: Keresztvalidáció VV koherenciára kukorica (bal) esetén és VH koherenciára napraforgó (jobb) esetén. Megfigyelhető, hogy a két növényre kapott értékek közel állnak egymáshoz mindkét polarizáció esetén.

A sigma0 idősorok keresztvalidációjakor a koherenciánál jobb eredményeket kaptam. Ezzel a szeparációs módszerrel sikerült a koherenciára kapott százalékos értékeket a legtöbb esetben javítani. Az árpa, a lucerna és a tritikálé esetén nem volt jelentős ez a javulás. A legsikertelenebb szétválasztás a VV sigma0 esetében született a tritikálé parcelláira. Továbbá elmondható, hogy a VV sigma0 esetről került ki a legtöbb 90% feletti eredmény, viszont a repcét minden parcella esetén sikerült elkülöníteni a többi osztálytól a VH sigma0 görbék alapján (25. ábra).



25. ábra: Keresztvalidáció VV sigma0-ra napraforgó esetén (bal), amikor 96%-ban sikerült szeparálni a többi növénytől és keresztvalidáció VH sigma0-ra repce esetén (jobb), amikor minden parcella esetén elvált a többi növénytől.

## 5.5 Osztályozás eredményei

Összesen hét osztályozást futtattam és minden esetben 300 döntési fával dolgoztam. Először azokat az eredményeket mutatom be, amelyeket a koherencia és a sigma0 értékek, valamint a polarizációs sávok figyelembevételével kaptam, és ekkor a famagasság 40 volt. Az első futtatás konfúziós mátrixa az 5. táblázatban figyelhető meg. Ez alapján megállapítható többek között, hogy jóval több pixel került a borsó osztályba, mint amennyi valójában volt, de ugyanez elmondható a tritikálé esetén is. Továbbá megfigyelhető, hogy a valós repce pixelek közül a legtöbbet valóban sikerült jól osztályozni.

|                      |            | Referencia pixelek |        |        |          |            |         |       |           |         |
|----------------------|------------|--------------------|--------|--------|----------|------------|---------|-------|-----------|---------|
|                      |            | Búza               | Árpa   | Repce  | Kukorica | Napraforgó | Lucerna | Borsó | Tritikálé | Összes  |
| Osztályozott pixelek | Búza       | 686951             | 11980  | 543    | 2545     | 4709       | 2891    | 140   | 4966      | 714725  |
|                      | Árpa       | 33711              | 149089 | 864    | 1243     | 3168       | 1177    | 316   | 2438      | 192006  |
|                      | Repce      | 7720               | 2429   | 239078 | 1236     | 2950       | 1842    | 575   | 411       | 256241  |
|                      | Kukorica   | 12982              | 1801   | 164    | 202710   | 11278      | 4475    | 276   | 843       | 234529  |
|                      | Napraforgó | 17328              | 3695   | 878    | 13122    | 625368     | 3331    | 506   | 604       | 664832  |
|                      | Lucerna    | 5554               | 1665   | 322    | 6599     | 2636       | 105890  | 87    | 875       | 123628  |
|                      | Borsó      | 6096               | 1949   | 1220   | 4340     | 3153       | 1207    | 33946 | 188       | 52099   |
|                      | Tritikálé  | 64622              | 10769  | 288    | 2422     | 3247       | 3917    | 151   | 23389     | 108805  |
|                      | Összes     | 834964             | 183377 | 243357 | 234217   | 656509     | 124730  | 35997 | 33714     | 2346865 |

5. táblázat: Az első osztályozás konfúziós mátrixa, melyet a koherencia és a sigma0 értékekkel együtt kaptam. Az egyes oszlopokban a valós pixel kategóriák helyezkednek el, amelyeket az adott osztályokba (sorok) kerültek az osztályozás során.


A további elemzések szempontjából szükséges ezen arányok számszerűsítése, vagyis a 4.7-es fejezetben ismertetett pontossági értékek kiszámítása, aminek az eredményeit a 6. táblázat foglalja össze. A táblázat alapján elmondható, hogy ebben az esetben a teljes pontossági eredmény (88,1%) és a kappa értéke szintén meghaladta a 80%-ot.

| Osztályok  | Koherencia + sigma0 |              |
|------------|---------------------|--------------|
|            | PA                  | UA           |
| Búza       | 82,3%               | 96,1%        |
| Árpa       | 81,3%               | 77,6%        |
| Repce      | 98,2%               | 93,3%        |
| Kukorica   | 86,5%               | 86,4%        |
| Napraforgó | 95,3%               | 94,1%        |
| Lucerna    | 84,9%               | 85,7%        |
| Borsó      | 94,3%               | 65,2%        |
| Tritikálé  | 69,4%               | 21,5%        |
|            | <b>OA</b>           | <b>88,1%</b> |
|            | <b>K</b>            | <b>84,7%</b> |

6. táblázat: Az osztályozás pontossági értékei a koherencia, a sigma0 értékek, valamint a VV és VH polarizációk együttes felhasználásával. Az OA a teljes pontosság, a K a kappa érték, a PA az alkotói pontosság és az UA a felhasználói pontosság.

Osztályszinten az alkotói (PA) és a felhasználói (UA) pontossági értékeknél megfigyelhető, hogy minden osztály esetén a pontosságok 60% feletti, kivétel a tritikálé esete, amikor az UA érték 21,5%. Ez azt jelenti, hogy több olyan pixel került tévesen ebbe a kategóriába az osztályozás során, ami valójában nem tritikálé. A tévesztési mátrixot elemezve megállapítható, hogy majdnem háromszor annyi búza pixelt sorolt a tritikálék közé, mint az adott növény pixeleit. Az alkotói pontosság esetén is legalább 10%-kal alacsonyabb ez az érték a tritikálénál (69%), míg a többi osztálynál a pontossági értékek 80% feletti. A legsikeresebben a repce osztályozása sikerült, ekkor a PA 98,2% és az UA 93,3%, amely eredmény a keresztvalidációnál tapasztaltakkal összhangban van. Összességében megállapítható, hogy a koherencia és a sigma0 értékek együttes osztályozása sikeresnek bizonyult a területen.

A 26. ábrán bemutatom az osztályozás után kapott raszter képet összehasonlítva az eredeti referenciaadattal (a és b ábra). A két kép között szemmel látható eltérés nincs, ezért az eltéréseket a 26.c ábrán emelem ki a képeken.



26. ábra: A referenciaadat (a) és az osztályozott eredmények (b) ábrázolása. Az osztályozott kép a koherencia, a sigma0 értékek és a polarizációk együttes vizsgálatával készült. A kettő közötti különbségek kiemelésére szolgál a c ábra.

Ennél az osztályozásnál összesen 144 sáv került felhasználásra, az elején sorakoznak a VH (1 – 36) majd a VV (37 – 72) koherencia sávok, majd őket követik a VH (73 – 108) és VV (109 – 136) sigma0 sávok. Az osztályozás során, a korábban leírtak alapján, a Random Forest az egyes sávokat különböző súlyozással veszi figyelembe futtatás során, ezért érdemes ezeket az értékeket is megvizsgálni. A legnagyobb mértékben a VH sigma0 értékeket vette figyelembe az osztályozó. Első helyen a 85. és 86. sávok állnak, amelyek május 16-i és május 22-i időpontoknak feleltethetők meg és ekkor a növények már mind fejlődésnek indultak. A legbefolyásosabb sávok közé sorolhatóak még a VV sigma0 értékei is, ugyanakkor 3. (VH koherencia) és a 39. (VV koherencia) sávoknak is szerepet tulajdonított az osztályozó az első 15 között. Ez mindkét idősor esetében március 17-re esik, ami azért is érdekes, mert ekkor még a növények nem indultak szárba egyik esetben sem, így a koherencia értéke még magas. A fontossági sorrendben a 28. hely után egyre jelentősebb szerepet kaptak a VV koherencia, viszont a VH koherencia értékek majd csak a 86. helytől kezdve számítanak bele az osztályozásba. A lista legvégén is ezek az értékek szerepelnek. Tehát jelentősebb mértékben a sigma0 értékek domináltak az osztályozás során. Ezek alátámasztották a görbék megfigyelésekor tett megállapításaimat, viszont nem egyeznek a keresztvalidációs vizsgálat eredményeivel. Akkor a VV sigma0 esetén tapasztaltam jobb eredményeket VV polarizációhoz képest, míg a koherenciánál a VH polarizáció bizonyult összességében sikeresebbnek a szeparáció során. Ennek az ellentmondásnak az lehet az oka, hogy a szeparációs vizsgálat egy átlagos képet ad és az osztályozás egyszerre vesz figyelembe minden sávot és időpontot.


A következő osztályozáskor a koherencia és a sigma0 hatását külön vizsgáltam, az erre kapott pontossági értékeket a 7. táblázat tartalmazza, amely során szintén 40 volt a famagasság.

| Osztályok  | Koherencia VH+VV |              | Sigma0 VH+VV |              |
|------------|------------------|--------------|--------------|--------------|
|            | PA               | UA           | PA           | UA           |
| Búza       | 53,3%            | 87,3%        | 81,8%        | 96,0%        |
| Árpa       | 53,1%            | 38,0%        | 79,9%        | 77,1%        |
| Repce      | 89,4%            | 72,7%        | 98,3%        | 93,6%        |
| Kukorica   | 60,8%            | 48,9%        | 85,1%        | 87,8%        |
| Napraforgó | 74,6%            | 81,8%        | 95,3%        | 94,1%        |
| Lucerna    | 70,7%            | 70,5%        | 84,4%        | 81,9%        |
| Borsó      | 90,9%            | 28,9%        | 92,9%        | 64,3%        |
| Tritikálé  | 53,1%            | 11,7%        | 69,2%        | 19,9%        |
|            | <b>OA</b>        | <b>65,2%</b> | <b>OA</b>    | <b>87,6%</b> |
|            | <b>K</b>         | <b>57,2%</b> | <b>K</b>     | <b>84,1%</b> |

7. táblázat: Az osztályozás pontossági értékei, amikor külön vizsgáltam a koherencia és sigma0 hatását. Az OA a teljes pontosság, a K a kappa érték, a PA az alkotói pontosság és az UA a felhasználói pontosság

Először azt lehet megállapítani táblázat alapján, hogy a teljes pontosság és a kappa értékek, valamint az egyes osztályok pontossági értékei mindkét esetben csökkentek, az előző osztályozáshoz képest. Különösen jelentős mértékű változás következett be a koherencia alapján kapott eredményekben, ami megfelel a keresztvalidáció grafikonjainak a megfigyelése és a korábbi osztályozások utáni várakozásaimnak. A teljes pontossága ekkor 65,2%, szemben a sigma0 értékekre kapott pontosságokkal, amikor is a csökkenés maximum 4% mértékű, sőt a repce esetén például nem is történik változás. Így a teljes pontosság értékek között 22,4% különbség van, míg a kappák közötti differencia 26,9%. Mindkét paraméter esetén a tritikálé osztályozása sikerült a legrosszabbul, az UA értékek 20% alá csökkentek, mivel a búza is sokszor tritikáléként került azonosításra. A koherencia esetén 53,1%-ban sikerült a valóban tritikálé területeket ebbe a kategóriába sorolni, ami az árpára és a búzára kapott pontossággal megegyezik. A koherencia esetén a valós borsó és a valós repce parcellákat ~90%-ban sikerült a megfelelő osztályba rakni, viszont csak a búza és a napraforgó esetén kaptam 80% feletti felhasználói pontosságot. Ezzel szemben a sigma0-ra futatott osztályozásnál a PA és az UA értékek nem különböznek szignifikánsan, kivétel a tritikálé és a borsó esete. Ekkor szintén több búzát sorolt ezekbe a kategóriákba. A legjobban a repce és a napraforgó osztályozása sikerült, mindkét pontosság esetén 90% feletti értékekkel.

A két változó eltéréseit szintén megerősíti a 27. ábra, amelyen megfigyelhető a két radarparaméter közötti változás. Ez is azt mutatja, hogy csak a koherencia alapján nem megfelelő az eredmény, vagyis nem hordoz önmagában elegendő információt az osztályozáshoz.



27. ábra: A koherencia (a) és sigma0 (b) értékek alapján a helyesen és helytelenül osztályozott pixelek aránya. Jelentős változás a két ábra között, ami a koherencia és a sigma0 osztályozásbeli alkalmazhatóságát is reprezentálja.

Az osztályozás után a sávok fontosságát megvizsgálva megfigyelhető, hogy a koherencia esetén a VV polarizált felvételeknek van jelentősebb szerepe, bár az első 15 helyen két VH polarizációs sáv is fellelhető. A második fontossági helyen áll a március 17-én készült VH polarizált kép (3. sáv), ami az előző osztályozásokkor szintén elől volt a fontossági sorrendben. Emellett az április 4-i VH koherenciás sávnak is jelentőséget tulajdonít az osztályozó, ami után az értékek a legtöbb idősoron csökkenésnek indulnak. Tehát ez szintén alátámasztotta a korábbi megfigyelésemet, hogy a VV koherencia számításának nagyobb szerepe van, ezáltal jobb eredményeket lehet kapni. Ezzel szemben a sigma0 értékre futtatott osztályozás esetében az az eset áll elő, hogy nagyobb fontosságú szerepet a VH értékek kapnak, viszont a VV sávok nem a lista végén, hanem annak közepén találhatók. A fontossági sorrend végén pedig több VH sigma0 sáv található, amelyek főleg augusztusi és szeptemberi időpontok.

Legutoljára a polarizációk hatását vizsgálva futtattam le az osztályozásokat. Ennek a pontossági eredményeit a 8. táblázat szemlélteti. Ezt azért végeztem el, mert a korábbi eredmények alapján is szembetűnő volt a VH és VV idősorok eltérő alkalmazhatósága, így meg akartam vizsgálni, hogy a különböző polarizációk felhasználásával milyen eredményeket lehet kapni az osztályozás során. A felhasznált raszterek ekkor 36 sávot tartalmaztak, ezért a fmagasságot szükséges volt lecsökkenteni 20-ra.

|            | Koherencia VH |              | Koherencia VV |              | Sigma0 VH |              | Sigma0 VV |              |
|------------|---------------|--------------|---------------|--------------|-----------|--------------|-----------|--------------|
| Osztályok  | PA            | UA           | PA            | UA           | PA        | UA           | PA        | UA           |
| Búza       | 46,9%         | 84,9%        | 48,0%         | 85,9%        | 78,8%     | 95,2%        | 77,9%     | 94,0%        |
| Árpa       | 49,1%         | 33,7%        | 48,4%         | 36,1%        | 74,8%     | 69,4%        | 73,0%     | 70,2%        |
| Repcse     | 87,5%         | 68,1%        | 88,0%         | 68,7%        | 96,8%     | 92,6%        | 98,4%     | 93,1%        |
| Kukorica   | 44,0%         | 44,4%        | 61,0%         | 42,7%        | 78,8%     | 84,7%        | 67,0%     | 69,6%        |
| Napraforgó | 73,1%         | 76,9%        | 68,0%         | 81,0%        | 94,6%     | 93,9%        | 88,8%     | 87,5%        |
| Lucerna    | 56,4%         | 44,1%        | 69,4%         | 68,2%        | 81,9%     | 78,3%        | 75,4%     | 75,4%        |
| Borsó      | 79,5%         | 21,2%        | 90,4%         | 26,5%        | 83,1%     | 47,5%        | 90,8%     | 60,6%        |
| Tritikálé  | 48,5%         | 10,5%        | 50,0%         | 9,0%         | 64,8%     | 16,7%        | 67,5%     | 16,7%        |
|            | <b>OA</b>     | <b>59,4%</b> | <b>OA</b>     | <b>60,9%</b> | <b>OA</b> | <b>84,8%</b> | <b>OA</b> | <b>81,5%</b> |
|            | <b>K</b>      | <b>50,3%</b> | <b>K</b>      | <b>52,5%</b> | <b>K</b>  | <b>80,7%</b> | <b>K</b>  | <b>76,4%</b> |


8. táblázat: Az osztályozás pontossági értékei külön vizsgálva a koherencia és sigma0 értékeket polarizációk szerint. Az OA a teljes pontosság, a K a kappa érték, a PA az alkotói pontosság és az UA a felhasználói pontosság.

Az előző osztályozásokhoz képest a pontossági értékek még tovább csökkentek a két paraméteren belül. A leggyengébb teljes pontossági értéket (59,4%) a VH koherencia esetén kaptam és ebben az esetben a kappa értéke 50,3%-ra csökkent le. Tehát a VH koherencia a legkevésbé alkalmas a növény fejlődésének elemzésre, valamint az osztályozásra és ezt már a korábbi osztályozásokkor megfigyelt sávok fontossági sorrendje is alátámasztja. A VV koherencia teljes pontossági értéke 60,9%, ami mindössze 1,5% különbséget jelent a VV koherencia javára. Ez azt jelenti, hogy önmagában a koherencia nem elegendő az osztályozáshoz, de amennyiben csak koherencia adatok állnak rendelkezésre, akkor érdemes a két polarizációt együtt alkalmazni. A VH koherencia esetén szintén a tritikálé osztályozása volt a legsikertelenebb, ekkor a felhasználói pontossági érték 10,5%, és az alkotói pontosság 50% alá csökkent. A VV koherenciánál az UA értéke tovább csökkent (9%), míg a PA értéke 1,5%-al nőtt. A legtöbb esetben búzát sorolt tritikálénak, viszont majdnem ugyanannyi árpa és napraforgó is került ebbe az osztályba, mint amennyi tritikálé. A VH koherencia esetén 70% feletti pontosságot a PA értékekre a repcénél, a napraforgónál és a borsónál adódott, míg ez a VV esetben csak a repcére és a borsóra teljesül, bár közel volt a napraforgó és a lucerna PA értéke is. Mindkét polarizáció esetén az UA értéke a borsónál jelentősen alacsonyabb (< 30%) volt a PA értékhez képest. Az osztályozás során az UA értékek 70% feletti a VH és VV koherencia esetén is a búzára és a napraforgóra.

A sigma0 osztályozáskor mindkét polarizációra továbbra is 80% feletti teljes pontosság adódott, habár megfigyelhető a VH sáv sikeresebb mivolta. Ekkor osztályonként mindkét esetben a pontossági értékek 70% feletti eredményt mutattak az árpa, a kukorica, a borsó és a

tritikálé kivételével. A borsónak itt is a felhasználói pontossága alacsonyabb, míg az árpa esetén szintén az  $UA$  értéke a VH polarizációnál csak épphogy nem éri el a 70%-ot. A kukoricának az osztályozása pedig a VV esetben adott a  $PA$  értékre 67%-ot és az  $UA$  értékre 69,6%-ot.

A 28. ábra szemlélteti a két polarizáció hatását a koherencia és  $\sigma_0$  értékek osztályozásakor. Megfigyelhető, hogy az egymást követő képek sorrendjében (VH, VV koherencia és VH, VV  $\sigma_0$ ) a rosszul osztályozott területek aránya csökken.



28. ábra: A VH (a), VV (b) koherencia, és VH (c), VV (d)  $\sigma_0$  értékek alapján a helyesen és rosszul osztályozott pixelek aránya. Jelentős változás b és c ábra között figyelhető meg, ami a koherencia és a  $\sigma_0$  osztályozásbeli alkalmazhatóságát is reprezentálja.

A sávok fontossági sorrendjére az adódott, hogy a koherencia sávoknál jelentős szerepet a tavaszi időpontok kaptak és legkevésbé a június és júliusi időpontok számítottak hasznosnak. Ez azt jelenti, hogy amikor a koherencia értéke 0,3 körüli, akkor ez alapján nem érdemes az egyes növényeket elkülöníteni, ezzel szemben a  $\sigma_0$  osztályozáskor a legfontosabbak a májusi és júliusi sávok.

## 6. Összegzés, konklúzió

A dolgozatomban mezőgazdasági területeken vizsgáltam meg a Sentinel-1 műholdak által nyújtott, interferometrikus koherencia értékeknek használhatóságát és hasznosságát. A kutatást a 2018-as év Pest és Heves megye találkozásánál található mezőgazdasági területére végeztem el kukorica, lucerna, napraforgó, őszi árpa, őszi búza, őszi káposztarepce, őszi tritikálé és tavaszi zöldborsó parcellákon. Először az adott területre vonatkozó műhold felvételeket feldolgoztam, amelyek alapján előállítottam az idősorokat. Ezt követően egy kezdő- és végpont meghatározó módszerrel vizsgáltam a növény fejlődésének kezdetét és az aratás valószínűsíthető időpontját, amik alapján összevetettem a koherencia idősorokat a  $\sigma_0$  idősorokkal. Továbbiakban két szeparációs vizsgálat segítségével határoztam meg, hogy ezek az idősorok alkalmasak lennének-e osztályozásra. Végezetül hét különböző osztályozást futtattam, amely során az egyes bemenő paraméterek fontosságát is elemeztem.

A nyolc növénytípus hatnaponta számított koherencia idősorról bebizonyosodott, hogy az egyes növények fejlődésére jellemző időszakok leolvashatóak a grafikonokról, például a növények szárbaindulásának az időszaka megjelenik a grafikonon. Ezt a szórás értékek jelentős csökkenése is jelzi, illetve a parcellák aratásnak feltételezhető idejét is meg lehet az idősorok segítségével határozni. Az aratás a növény fejlődésének szempontjából egy jelentős változásnak számít, viszont a görbék alapján nem lehet ezt a dátumot elkülöníteni a többi, kisebb mértékű változástól. Egyedül az utána bekövetkező értékek növekedése jelzi, hogy megtörténhetett a betakarítás. Azon növénytípusoknak, amelyek fejlődési periódusa szinte megegyezik, az idősoraik is hasonló lefutást mutattak. Erre példa a búza-árpa és a kukorica-napraforgó párosítások. A repce esetén arra a megállapításra jutottam, hogy a koherenciával nem lehet a fejlődési időszakát jól lehatárolni, mivel az egyes idősorok tovább maradnak alacsonyan, mint ami a repce betakarításának időszaka.

Az idősorokon az egyes polarizációk különböző viselkedése is megfigyelhető. A koherencia esetén a VV görbék nagyobb értékeket vesznek fel a növények fejlődési időszakán kívül, mint a VH görbék, ami a cross-polarizált visszaverődés során bekövetkező jel gyengülés miatt következhet be. Ez a két görbe egymásra simul a növények fejlődésekor. A görbék további elemzése alapján a VV polarizációs koherencia idősorokat tartom alkalmasabbnak a növények vizsgálatára.

További eredményként sikerült megkülönböztetni azokat a parcellákat, amelyeken a növények rosszabbul fejlődtek, amit a koherencia grafikonok egy ferde lefutás jelzett. Ennek

következtében úgy gondolom, hogy a koherencia használható a jól és egészségesen fejlődő parcellák megkülönböztetésére a rosszul fejlődőktől.

A kezdő- és végpont meghatározással meghatároztam a koherencia idősorokon a növények fejlődésének valószínűsíthető kezdetét és az aratását, amelyek összességében a valóságnak megfelelnek, bár az aratás tényleges időpontját nem ismerem.

A sigma0 idősorokon ugyanúgy megfigyelhető volt az egyes növények fejlődési időszaka, ám ekkor az értékek a koherenciával ellentétben, nem csökkenésnek, hanem növekedésnek indultak. A két polarizációs görbe ekkor teljesen elkülönült, melyek közül a VV görbék vettek fel nagyobb értékeket. A koherencia sigma0 idősorokkal való összevetése már csak részben volt sikeres, mivel a legtöbb esetben különböző értékeket kaptam az egyes parcellák esetén a kezdő- és végpontokra.

A távolságmátrixok elemzése alapján megállapítottam, hogy minden növény a saját átlagához hasonlít legjobban, viszont a keresztvalidációs eredményeknél ez nem teljesül. A keresztvalidációs eredményeknél megfigyelhető, hogy az egyes növények szeparációja a koherencia esetén, azon belül is a VV polarizációs görbék alapján volt legkevésbé sikeres. Ezzel szemben a növények elkülönítése a VV sigma0 görbék alapján bizonyult a legmegbízhatóbbnak. Ez az eredmény nem felelt meg az elvárásoknak, mivel az eddigi megfigyeléseim alapján a koherencia esetén a VV polarizációt, míg a sigma0 esetén a VH polarizációt tartottam hasznosabbnak.

Legvégül többféle Random Forest osztályozást végeztem el a kiválasztott mintaterületen a nyolc növénytípusra. Először a koherencia és a sigma0 értékek, valamint a két polarizáció együttes felhasználását vizsgáltam különböző famagasságokkal. Ekkor a teljes pontosság 88,1%, míg a kappa értéke 84,7% lett. Az egyes sávok fontossági sorrendje ekkor a következőképpen alakult: VH sigma0, VV sigma0, VV koherencia, VH koherencia. Ez az eredmény ellentétes a keresztvalidáció során tapasztaltakkal, vagyis arra következtetek a vizsgálataim alapján, hogy az a szeparációs vizsgálat kevésbé alkalmas, illetve ez az osztályozás alátámasztja a VV koherencia hasznosabb mivoltát. Másodszor a koherencia és a sigma0 eltérő hatását vizsgálva futtattam az osztályozást, melynek eredményeként a pontossági értékek csökkentek, a koherencia esetén jelentősen (teljes pontosság: 65,2%, kappa: 57,2%). Utoljára a két polarizáció hatását vizsgáltam, ekkor kaptam a leggyengébb pontossági értékeket a VH koherencia esetén (teljes pontosság: 59,4%, kappa: 50,3%). Ezzel szemben a sigma0 pontosságok jelentősen nem változtak a három különböző típusú osztályozás során, még a

legrosszabb esetben (VV  $\sigma_0$ ) is a teljes pontosság értéke 81,5% volt. A koherencia sávoknál a tavaszi időpontok bizonyultak a legfontosabbnak, míg a nyári időpontok számítottak legkevésbé az osztályozás során. Összességében elmondható, hogy a koherencia önmagában nem alkalmas osztályozásra, viszont két polarizációval és a  $\sigma_0$  értékkel kibővítve 88%-os osztályozási teljes pontosság érhető el.

A koherencia komplex felhasználhatóságának érdekében érdemes további vizsgálatokat elvégezni olyan felszíni kategóriákon, amelyeket ebben a munkában nem elemeztem. Ilyen például erdős területek, gyepvel borított területek, városi területek vagy más jellegű mezőgazdasági területek, mint a gyümölcsös, szőlős.

## **7. Köszönetnyilvánítás**

Elsősorban Friedl Zoltánnak szeretném megköszönni, hogy elvállalta a témavezetést és a szakmai tudásával hozzásegített a dolgozat elkészítéséhez. Hálás vagyok a biztatásáért és a segítségéért. A Lechner Nonprofit Kft-nek szeretném ezúton is megköszönni, hogy lehetőséget kaptam gyakornoki tevékenységet végezni náluk és ezzel hozzájárultak a kutatásom elvégzéséhez. Az ott dolgozóknak is szeretném megköszönni a támogatásukat. Köszönetemet szeretném még kifejezni a Magyar Államkincstárnak a dolgozathoz biztosított adatokért. Továbbá szeretném megköszönni a családomnak és a barátaimnak a folyamatos támogatást, biztatást és a segítségüket. Végül, de nem utolsó sorban pedig köszönöm mindenkinek, aki végig olvasta a dolgozatomat és véleményezte a munkámat.

## 8. Irodalomjegyzék

- BÁNYAI, L., SZÜCS, E., KALMÁR, J., EPERNÉ PÁPAI, I., BÁN, D. (2014): Az InSAR technológia alapjai és a reflektáló felületek jellemzői. *Geomatikai Közlemények*, **17**: 59-68. ISSN:1419-6492
- BARGIEL, D. (2017): A New Method for Crop Classification combining Time Series of Radar Images and Crop Phenology Information. *Remote Sensing of Environment*, **198**(5325): 369-383. doi: 10.1016/j.rse.2017.06.022
- BRIEMAN, L. (2001): Random Forests. *Machine Learning*, **45**(1): 5-32. doi:10.1023/A:1010950718922
- CONGALTON, R. G., GREEN, K. (2008): Assessing the Accuracy of Remotely Sensed Data. *Principles and Practices*. CRC Press, 183.
- COPERNICUS OPEN ACCESS HUB, European Space Agency, <https://scihub.copernicus.eu/> [Copernicus Sentinel adatok 2018; letöltve: 2021.02.24]
- DE ZAN, F., MONTI-GUARNIERI, A. (2006): TOPSAR: Terrain Observation by Progressive Scans. *IEEE Transactions on Geoscience and Remote Sensing*, **44**(9): 2352–2360. doi:10.1109/TGRS.2006.873853
- ESA (2015): Radiometric Calibration of S-1 Level-1 Products Generated by the S-1 IPF. **1**: 1-13., European Space Agency – ESA, <https://sentinel.esa.int/documents/247904/685163/S1-Radiometric-Calibration-V1.0.pdf> [megtekintve: 2021.05.02]
- ESA EARTH ONLINE (2021): Synthetic Aperture Radar Land Applications Tutorial – Part I Background and Theory, European Space Agency – ESA, [https://earth.esa.int/documents/10174/2700124/sar\\_land\\_apps\\_1\\_theory.pdf](https://earth.esa.int/documents/10174/2700124/sar_land_apps_1_theory.pdf) [megtekintve: 2021.04.15.]
- ESA SENTINEL-1 TUTORIALS (2020): Displacement Mapping with Sentinel-1 IW TOPS data, European Space Agency – ESA, [http://step.esa.int/docs/tutorials/S1TBX%20TOPSAR%20Interferometry%20with%20Sentinel-1%20Tutorial\\_v2.pdf](http://step.esa.int/docs/tutorials/S1TBX%20TOPSAR%20Interferometry%20with%20Sentinel-1%20Tutorial_v2.pdf) [megtekintve: 2021.04.22.]

- ESA SENTINEL ONLINE (2021): Sentinel-1 SAR User Guide. European Space Agency – ESA, <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-1-sar> [megtekintve: 2021.04.20.]
- GDAL/ORG CONTRIBUTORS (2021): GDAL/OGR Geospatial Data Abstraction software Library. Open Source Geospatial Foundation, <https://gdal.org> [megtekintve: 2021.10.19.]
- KENDUIYWO, B. K., BARGIEL, D.; SOERGEL, U. (2018): Crop-Type Mapping from a Sequence of Sentinel 1 Images. *International Journal of Remote Sensing*, **39**(19): 1-22. doi:10.1080/01431161.2018.1460503
- KLISCH, A., ATZBERGER, C. (2014): Evaluating Phenological Metrics derived from the MODIS Time Series over the European Continent. *Photogrammetrie – Fernerkundung – Geoinformation*, **2014**(5): 409-421. doi:10.1127/1432-8364/2014/0233
- LEE, J-S., WEN, J-H., AINSWORTH. T. L. (2009): Improved Sigma Filter for Speckle Filtering of SAR Imagery. *IEEE Transactions on Geoscience Remote Sensing*, **47**(1): 202-213. doi:10.1109/TGRS.2008.2002881
- ANONIMIZÁLT KÉRELEM ADATBÁZIS (2018): Jogbirtokos: Magyar Államkincstár: <https://www.mvh.allamkincstar.gov.hu>
- MESTRE-QUEREDA, A., LOPEZ-SANCHEZ, J. M., VICENTE-GUIJALBA, F., JACOB, A. W., ENGBAHL, M. E. (2020): Time Series of Sentinel-1 Interferometric Coherence and Backscatter for Crop-Type Mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **13**: 4070-4084. doi:10.1109/JSTARS.2020.3008096
- MOREIRA, A., PRATS-IRAOLA, P., YOUNIS, M., KRIEGER, G., HAJNSEK, I., PAPATHANASSIOU, K. P. (2013): A Tutorial on Synthetic Aperture Radar. *IEEE Geoscience and Remote Sensing Magazine*, **1**(1): 6-43. doi: 10.1109/MGRS.2013.2248301
- PACSKÓ, V. (2017): Polarimetrikus deskriptorokból előállított fenológiai profilok vizsgálata – első eredmények, *ELTE TTK*
- PYTHON (2021): <https://www.python.org/downloads/> [megtekintve: 2021.02.17.]
- QGIS DEVELOPMENT TEAM (2021): QGIS Geographic Information System, Open Source Geospatial Foundation Project, 3.0.3; <http://qgis.osgeo.org> [megtekintve: 2021.02.10.]

- PEDREGOSA, F., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., GRISEL, O., BLONDEL, M., PRETTENHOFER, P., WEISS, R., DUBOURG, V., VANDERPLAS, J., PASSOS, A., COURNAPEAU, D., BRUCHER, M., PERROT, M. AND DUCHESNAY, E. (2011): Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, **12**: 2825-2830.
- ROSEN, P. A., HENSLEY, S., JOUGHIN, I. R., LI, F. K., MADSEN, S. N., RODRÍGUEZ, E., GOLDSTEIN, R. M. (2000): Synthetic Aperture Radar Interferometry. *Proceedings of the IEEE*, **88**(3): 333–382. doi:10.1109/5.838084
- SNAP (2021): ESA Sentinel Application Platform 7.0., <http://step.esa.int>
- SIPŐCZ, J. (2021): Interferometrikus koherencia alkalmazása a mezőgazdaságban, *ELTE TTK*
- USGS – UNITED STATES GEOLOGICAL SURVEY (2015): Shuttle Radar Topography Mission (SRTM) 1 Arc-Second Global, <https://lta.cr.usgs.gov/SRTM1Arc> [megtekintve: 2021.03.11.]
- VICENTE-GUIJALBA, F., JACOB, A., LOPEZ-SANCHEZ, J. M., LOPEZ-MARTINEZ, C., DURO, J., NOTARNICOLA, C., ZIOLKOWSKI, D., MESTRE-QUEREDA, A., POTTIER, E., MALLORQUI, J. J., LAVALLE, M., ENGBAHL, M. (2018): Sincohmap: Land-Cover and Vegetation Mapping Using Multi-Temporal Sentinel-1 Interferometric Coherence. *IGARSS 2018 –2018 IEEE International Geoscience and Remote Sensing Symposium*, 6631-6634. doi:10.1109/IGARSS.2018.8517926
- TEMPORAL/SPECTRAL PROFILE TOOL (2021): <https://github.com/DHI-GRAS/qgis-temporal-profile/> [megtekintve: 2021.03.25.]

## 9. Függelék

(A) A vizsgált parcellák egy hányadának a koherencia és sigma0 időszora

