

XXVIII. Reál- és humántudományi Erdélyi Tudományos Diákköri Konferencia (ETDK)

Babeş–Bolyai Tudományegyetem

Földrajz kar – Földrajz szekció

**Geotérbeli elemzés Donyeckben – Milyen nyomokat hagy a
háború az úrfelvételeken?**

Témavezetők:

dr. Temerdek-Ivan Kinga, kutató

Babeş–Bolyai Tudományegyetem

Magyar Földrajzi Intézet

dr. Török Ibolya, egyetemi docens

Babeş–Bolyai Tudományegyetem

Magyar Földrajzi Intézet

Szerző:

Székely Boglárka

Babeş–Bolyai Tudományegyetem

Geomatika szak, I. év

Kolozsvár

2025. május 15-18.

Bevezető

Ukrajna 2022 februárja óta háborúban áll Oroszországgal, amely számos fegyveres összecsapást követelt maga után, jelentős károkat okozva ezzel nemcsak az infrastruktúrában, hanem az épületekben is. A konfliktusos zónák leginkább Ukrajna keleti- délkeleti részén vannak. Közigazgatásilag az ország 24 régióra (oblast) van felosztva, amelyekből Luhanszk, Donyeck, Zaporizhia és Kherson régiók (a Krími Autonóm Köztársaság mellett) orosz megszállás alatt állnak. Az ország más területein is harcok folynak, viszont dolgozatomban Donyeck régió változásaira fókuszáltam 2022-2024 között.

Donyeck régió, Ukrajna keleti részén helyezkedik el (lásd 1. ábra), már a 2022-ben kitört háború előtt is konfliktusos zónának számított. Ukrajna nehézipari központja, altalajkincsekben (főleg szénben és fémércekben) gazdag terület, számos ipari komplexummal (gépgyárak, acélművek, vegyipari komplexum, hőerőművek) rendelkezik. A régióban kulcsfontosságú szerepet betöltő városok Donyeck – a régió központja és Mariupol, az ipari kikötőváros, az Azovi-tenger legnagyobb forgalommal rendelkező kikötője volt a háború kitörése előtt, amely így szintén a konfliktus középpontjába helyezte. A régió etnikai megoszlása tetőzi az Orosz-Ukrán konfliktushelyzetet, mivel jelentős az orosz anyanyelvű lakosság.

A háború mindenki számára nehézségeket, káoszt okoz, ami a statisztikai adatokban is meglátászik, mivel hivatalos adatok csak a háború előtti időszakokból érhetőek el Ukrajnában. Ezen statisztikai adatok helyettesítésére, becslésére tudjuk felhasználni például a dolgozatban feldolgozott éjszakai űrfelvételeket, amelyek a népességi adatokat egészíthetik ki, a háború kitörése előtti és utáni felszínborítottság változását vagy épp a megrongálódott épületek számának statisztikáját. Így a távérzékelt adatok feldolgozásával pontos adatokkal szolgálhatunk a kárfelmérésben, rehabilitációban.



1. ábra: Donyeck elhelyezkedése Ukrajna térképén (saját szerk.)

1. Célkitűzések

A dolgozat célkitűzése a háború során keletkezett változások vizsgálata, amelyet négy különböző módszert alkalmazva végeztünk:

1. A megsemmisült épületek beazonosítása SAR-Sentinel-1 radarfelvételeket használva, 2022-2023-2024 években Donyeck és Mariupol városokban

A megsemmisült épületek detektálása a háború kitörése előtti- és utáni radarfelvételeket felhasználva. A károk kimutatása az ENSZ UN-SPIDER – Földrengés okozta károk detektálása Sentinel-1 adatokkal – útmutatóját követve, az Európai Űrügynökség ESA SNAP (Sentinel Application Platform) és QGIS szoftverek használatával történik. Ezt a régió két legnagyobb és legfontosabb városaira (Donyeck és Mariupol) külön-külön alkalmazva és összehasonlítva a különböző évek felvételeit.

2. Éjszakai fénydinamika Donyeck régióban: tér-időbeli változások éjszakai műholdfelvételek alapján (VIIRS, 2022–2024)

Donyeck régió éjszakai fényeinek megfigyelése és összehasonlítása a háború kitörése előtti- és utáni időszakokban (2022 január-2024 augusztus között) éjszakai felvételek alapján.

Az éjszakai felvételek elemzése Xu et al., 2024 nyomán történik, a NASA Black Marble adatbázisának – Daily Lunar BRDF Adjusted Nighttime Lights (VNP46A3) elemét felhasználva, ArcGIS Pro-ban feldolgozva.

3. NDVI-index összehasonlítása Donyeck térségében: termőföldek felismerése Sentinel-2 adatok alapján (2021–2024 június)

Donyeck régió vegetációs indexeinek (NDVI) elemzése Sentinel-2 műholdfelvételek alapján, amely segítségével beazonosíthatjuk a földhasználat változásait. A változások kialakulásához az általános környezeti tényezőkön kívül a népesség változása és a háborús összecsapások is hozzájárulhatnak. Az NDVI széles körben használt index a föld termékenységeinek kimutatására, általában előnyben részesítik más vegetációs indexekkel szemben (Ivits & Cherlet, 2016; Reith et al., 2021).

4. Donyeck régió felszíni változásainak vizsgálata 2021-2024 években, nagy felbontású (3 m) PlanetScope műholdfelvételekkel

Felszíni változások vizsgálata 2021 és 2024-es PlanetScope mozaikok alapján a széles körben alkalmazott Random Trees-Machine Learning osztályozási módszerrel (Phan et al., 2020; Li et al., 2016; Rodriguez-Galiano et al., 2012). Mintaterületeket készítve a Random Trees módszerbe illesztve többféle döntési fát hoz létre, amelyből a legjobb kiválasztása után Kappa-együtthatóval validálunk.

2. Irodalmi áttekintés

A különböző konfliktusok-háborúk, vagy természeti katasztrófák nyomán lerombolt épületek detektálása elengedhetetlen a károk felméréséhez, a humanitárius segélyek elosztásához és az újjáépítési munkálatok hatékonyabb tételéhez az érintett területeken (Racek et al., 2025). A kárfelmérés gyakran kihívást jelent a hatóságok, kutatók vagy szakértők számára az adatok hiánya vagy korlátozott hozzáférhetősége miatt. A károk észlelésére szolgáló hagyományos módszerek, mint például terepi felmérések vagy nagy felbontású műholdképek elemzése lassú és költséges, néha pedig a területhez vagy az adatokhoz való korlátozott hozzáférés miatt elérhetetlenek. A károk időben történő felmérése fontos a gyors döntéshozatal és a humanitárius segélyek elosztása szempontjából. Ebben szolgálhatnak segítségül a nagy felbontású műholdfelvételek, amelyek segítségével nagyon gyorsan kárfelmérést lehet végezni. Ezek az adatok azonban vagy költség ellenében, vagy korlátozottan állnak rendelkezésre, ami akár megakadályozhatja a tudományos közösség hozzáférését

(Bennett et al., 2022). Másrészt számos olyan, ingyen elérhető, különböző műholdas programokból származó távérzékelte adat áll rendelkezésre, amelyek bizonyítottan hatékonyak az épített felületek (Holobacă et al., 2019; Feng et al., 2021; Oşlobanu et al., 2021), a lerombolt épületek (Aimaiti et al., 2022; Bennett et al., 2022; Racek et al., 2025) vagy a környezetre gyakorolt hatások megfigyelésére (Fakhri & Gkanatsios, 2021; Huang et al., 2023).

Az éjszakai műholdfelvételek igen értékes adatforrást jelentenek egy terület társadalmi-gazdasági adatainak megismerésére, amennyiben ezek az adatok hiányoznak, nem megfelelő minőségűek vagy elavultak az adott területen. Az éjszakai fények intenzitását (Nighttime Lights – NTL) széles körben alkalmazzák a lakossági jövedelem becslésére (Ivan et al., 2020; Li et al., 2013), gazdasági tevékenység mutatójaként (Mellander et al., 2015; Pérez-Sindín et al., 2021), a társadalmi tevékenység mutatójaként (Andries et al., 2023), népességdinamika mutatójaként (Rogers et al., 2023; Stathakis & Baltas, 2018) vagy városnövekedés nyomonkövetése céljából (Yin et al., 2019; Zheng et al., 2022). Quan et al., 2023 az éjszakai fények intenzitását olyan régiókban, ahol hiányos vagy nehezen elérhető a statisztikai adatok, a fenttarthatóság becslésére használták. Huang et al., 2023 a háború hatásainak nyomonkövetésének és a népességdinamika becslésének kihívásaival szembenézve megállapították, hogy az éjszakai fények nagyon hasznosak a népesség nyomonkövetésében konfliktushelyzetekben, naprakész statisztikai adatok hiányában. Chen, 2020 az éjszakai fényeket a migrációelemzés eszközeként felhasználva bizonyította a felvételek igen értékesek a Human Migration Flow tanulmányozásában, leginkább azért, mert ezek az adatok szubnacionális szinten legtöbbször hiányosak vagy egyáltalán nem elérhetőek. Martinez et al., 2023 megállapították, hogy az éjszakai fények a konfliktusok, háborúk vagy természeti katasztrófák sújtotta területeken értékes információkat szolgáltatnak az infrastrukturális károkról.

Az NDVI széles körben használt mutató, más tanulmányokban sikeresen használták például a Száhel-övezet fái fenológiai vizsgálatára (Fitts et al., 2025), mezőgazdasági kutatási célokra (Houborg & McCabe, 2016), terméshozam-becslések pontosítására (Roznik et al., 2022), a földterületek termékenységének kimutatására (Temerdek-Ivan et al., 2025).

A fentebb leírtakból kiindulva, az ingyenesen elérhető műholdfelvételek igen értékes forrást jelenthetnek katasztrófa sújtotta területeken a lerombolt, megsérült épületek észlelése és kárfelmérése érdekében, ezek keletkezésének okától függetlenül. Ezeken kívül hiányos statisztikai adatok kiegészítésében szintúgy hasznunkra válhatnak.

E dolgozatban különböző, ingyen elérhető távérzékelési adatokat dolgoztunk fel: SAR-Sentinel-1, Sentinel-2, PlanetScope és VIIRS-Night-time lights felvételek. Ezeket felhasználva elemeztük a 2022-ben kitört Orosz-Ukrán háború során keletkezett változásokat, károkat Donyeck régióban.


3. Módszertan

3.1. A megsemmisült épületek beazonosítása SAR-Sentinel-1 radarfelvételeket használva, 2022-2023-2024 években Donyeck és Mariupol városokban

Dolgozat ezen részében a régió két legnagyobb és legfontosabb városára esik fókusz, Donyeckre és Mariupolra, amelyek területén számos épület rongálódott vagy megsemmisült meg. Ezek detektálására Sentinel-1 (SAR) felvételeket használtunk, 2022 január-április, 2022 január-2023 január és 2022 január-2024 januári időpontokra, az ENSZ UN-SPIDER – [Földrengés okozta károk detektálása Sentinel-1 adatokkal](#) (letöltve: 2025. 04. 10) – útmutatóját alkalmazva. A felvételek az Európai Unió Copernicus programjának weboldaláról lettek letöltve, – Copernicus Browser (<https://dataspace.copernicus.eu/>) – ahol ezek ingyenesen elérhetők. A radarfelvételek kiválasztásánál az összehasonlíthatóság érdekében fontos leellenőrizni ezek azonosságát – fontos, hogy az összehasonlítandó felvételek azonos sávon (orbit path), azonos pályán (orbit) – emelkedő/süllyedő (ascending/descending) – legyenek és azonos polarizációval (polarization) rendelkezzenek. A felvételek az ESA (Európai Űrügynökség) SNAP (Sentinel Application Platform) szoftverét használva kerültek feldolgozásra, amely egy szintén ingyenesen elérhető program. A feldolgozási lánc nagy része SNAP-ben történt. Első lépés a nyers radarfelvételek megnyitása úgy az előtte, mint az utána időszakokra. Ezeket a *Synchronise Image Views* paranccsal való szinkronizálása, majd a kutatási területre nagyítva: *jobb klikk* a felvételre → *Spatial Subset from View* paranccsal kivágatok készítése követte. Ezeket a lépéseket elvégezve lecsökken a műveletek végrehajtási ideje és a hibázási lehetőség, minél kisebb a vizsgált terület, annál gyorsabb és pontosabb lesz a vizsgálat eredménye. Következő lépés a felvételek geometriai korrekciója. Ez a lépés azért szükséges, hogy az eredmények pontosak, koordinátában legyenek, így az elemzés is könnyebben végrehajtható és pontosabb lesz. A geometriai korrekciót a *Radar* menüpont *Apply Orbit File* parancsával mindkét felvételre alkalmazzuk. Ezután a radiometriai kalibrálás következik, amely a radarreflexió értékeit, azaz a nyers felvételek olyan digitális számértékeit, amelyek a radar szenzorja által detektált sugárzás intenzitását jelölik, mérhető fizikai egységbe, decibelbe

(dB) alakítja. A kalibrációs műveletet egy logaritmikus függvény segítségével végzi a program, amellyel standardizálja az adatokat és normalizálja az adatértékek eloszlását, ezáltal könnyen felhasználhatóvá teszi a GIS szoftverek számára. A kalibrálás nem változtatja meg az adatokat, de növeli a hisztogram frekvenciáinak kontrasztját, ezzel az adatok jobb kezelhetőségét is lehetővé teszi (Miranda & Meadows, 2015). Ezt a *Radar* menüpont *Radiometric* → *Calibration*: processing parameters: *VV polarization* → *Output sigma0 band* parancsaival alkalmazzuk. Következő lépés a zajszűrés (Speckle filtering), amely segítségével eltávolítjuk a radarszenzor működésével keletkező zajt, Yommy et al. (2015) nyomán a *Refined Lee* módszert alkalmazva. A műveletet a *Radar* menüpont → *Speckle Filtering* → *Single Product Speckle Filter: Refined Lee* parancsaival végezhetjük el. A felszíni korrekcióra (Terrain Correction) azért van szükség, mert a föld felszínén magasabban elhelyezkedő és a radar dőlési irányával megegyező dőlésszögben elhelyezkedő objektumok hamarabb visszaverik a radar által kibocsátott elektromágneses sugarakat, dőlési torzulást okozva a felvételen, azaz közelebbnek tűnnek, mint a föld felszínén valójában vannak. Ezt egy digitális domborzatmodell és a pályainformációkat felhasználva végzi a program a *Radar* menüpont → *Geometric* → *Terrain Correction* → *Range-Doppler Terrain Correction* parancsokat követve. Az előfeldolgozás utolsó lépése a dB-ből/dB-be való lineáris konverzió (Linear Conversion to/from dB). Ezt a lépést alkalmazva szintén egy logaritmikus függvényt használ a program, a hisztogram egy jobban kezelhető skálára való kiterjesztésével (Histogram Stretching). A folyamat a *Raster* menüpont → *Data Conversion* → *Converts bands from/to dB* parancsokat alkalmazva történik. Ezután a tényleges feldolgozás folyamata következik, amelyhez SNAP-ben a *Radar* menüpont → *Coregistration* → *Stack Tools* → *Create Stack* parancsával társítjuk az előtte-, utáni felvételeket, amelyen elvégezzük a tényleges változásvizsgálatot (Change Detection), a *Radar* menüpont → *SAR applications* → *Change Detection* lépéseit követve. Az eredményeket GeoTIFF formátumban exportáljuk, amelyeken QGIS szoftverben további feldolgozásokat végzünk, elsőként a GeoTIFF fájlok megjelenítését változtatjuk meg a *Properties* → *Symbology* → *Render Type* → *Paletted/Unique Values* → *Classify* lépéseket követve. Ezt a raszterek vektorra alakítása követi, amelyet a *Raster* → *Conversion* → *Polygonize (Raster to Vector)* lépésekkel. Ez a lépés az összes érintkező raszteres pontot poligonra alakítja. Erre azért van szükség, hogy az eredményeket más adatokkal könnyen össze tudjuk hasonlítani. Mindegyik képkockának (pixelnek) van egy, a feldolgozás során keletkezett értéke, amely értékek 0-tól akár több ezerig terjedhetnek. Ezeket az értékeket a két felvétel közötti változások mértéke és a terület nagysága befolyásolja, azaz minél nagyobb változás történt és minél nagyobb a terület, annál nagyobb értékek keletkeznek. A feldolgozás utolsó

lépése a 0 értékkel rendelkező poligonok törlése. Ha az érték 0, akkor ott nem történt változás, így nincs szükségünk a továbbiakban ezekre. Az *Attribútum táblázat* megnyitásával → *Filter by Expression*: DN oszlopba írt érték: 0 → *Select features* – ez kiemeli a 0 értékeket → *Edit* → *Delete* → *Save Edits* lépéseket követve. A folyamat jobb átláthatósága érdekében egy folyamatábrát készítettem, amelyben lépésről-lépésre leírtam a műveletek sorrendjét:



2. ábra: A megsemmisült épületek detektálásának folyamata

3.2. Éjszakai fénydinamika Donyeck régióban: tér-időbeli változások éjszakai műholdfelvételek alapján (VIIRS, 2022–2024)

A dolgozat ezen részében a VIIRS fényességadatait használtuk, amelyeket 2022 januárjától 2024 augusztusig minden hónapra letöltöttünk. Az ingyenesen elérhető műholdfelvételek a NASA LAADS DAAC (<https://ladsweb.modaps.eosdis.nasa.gov/search/>) weboldaláról lettek letöltve. A rendelkezésre álló Suomi National Polar-orbiting Partnership, VIIRS (Visible Infrared Image Radiometer Suite) éjszakai felvételek közül (lásd 1. táblázat) a dolgozatban a VNP46A3 műholdfelvételei voltak használva. A 2012-óta elérhető felvételek 500 m-es felbontással rendelkeznek és az éjszakai fények havi, összesített értékeit mutatják.

3.1. táblázat: Éjszakai felvételek adatbázisai

Adatbázis	Felbontás	Elérhetőség
VNP46A1	500 m	Napi
VNP46A2	500 m	Napi
VNP46A3	15 arcsec (~500 m)	Havi
VNP46A4	15 arcsec (~500 m)	Éves

Az éjszakai felvételeket 2022 januárjától 2024 augusztusáig minden egyes hónapra le lettek töltve és fel lettek dolgozva. Az adatok .h5 (HDF5) formában lettek letöltve, amelyek ezután ArcGIS Pro szoftverben .tiff formátumba lettek átalakítva, a *Raster to Other Format* eszközzel. A kapott rasztereket ezután Donyeck régió körvonalára való kivágás az *Extract by Mask* eszközzel követte, így a felvételek a régió körvonalát követik. Az éjszakai fények rasztereket 0-10-ig terjedő skálán, min-max normalizációs módszerrel normalizáltuk a felvételek havi szintű összehasonlíthatósága és a fényintenzitás különbségének kiemelése érdekében (Martinez et al., 2023). A raszterek normalizálása a Raster Calculator eszközzel volt kiszámítva, az alábbi képletet alkalmazva:

$$\hat{x} = \frac{x - \min(x)}{\max(x) - \min(x)} \times 10$$

Ahol: x – a nyers, kivágott raszter

Min – a pixelek legkisebb értéke


Max – a pixelek legnagyobb értéke

10 – skálázási tényező, a 0-10 közötti értékek összegzésére

A raszterek minimális és maximális értéke a Calculate Statistics eszközt felhasználva volt kiszámítva.

A normalizált rasztereket ArcGIS Pro-ban hasonlítottam össze, amely lehetővé tette, hogy térképek, grafikonok és animációk formájában kiemeljük az éjszakai fények havi változásait Donyeck régióban.

A műveletek jobb átláthatósága érdekében egy folyamatábrát készítettem:



3. ábra: Az éjszakai felvételek feldolgozási folyamata

3.3. NDVI-index összehasonlítása Donyeck térségében: termőföldek felismerése Sentinel-2 adatok alapján (2021–2024 június)

A legújabb technológiai fejlesztések lehetővé teszik a mezőgazdasági területek vizsgálatát nagy térbeli felbontásban. Az elemzéshez felhasznált a felvételek az Európai Unió Copernicus Programjának weboldalán elérhető – Copernicus Browser (<https://dataspace.copernicus.eu/>) – Sentinel-2 műholdfelvételek voltak, 2021 és 2024 június hónapokra. Az NDVI-index (Normalized Difference Vegetation Index) számításához szükséges multispektrális sávok a vörös és a közeli-infravörös (Rouse et al., 1973; Tucker, 1979), ezek a Sentinel-2 esetében a B4 és B8 sávok. Június a vegetáció csúcspontját jelöli, azt az időszakot, amikor a növényzet teljesen kifejlődött, a növények ekkor a legzöldebbek. Sentinel-2 felvételek alapján már számos tanulmányban sikeresen számítottak NDVI értékeket a terméshozam becslésének pontosítására (Roznik et al., 2022), a földterületek termékenységének kimutatására (Temerdek-Ivan et al., 2025), hatékony és széles körben használt mutató lévén a vegetáció tér- és időbeli változásainak megfigyelésére (Candiago et

al., 2015). Az NDVI széles körben használt index a föld termékenységének kimutatására, általában előnyben részesítik más vegetációs indexekkel szemben (Ivits & Cherlet, 2016; Reithh et al., 2021). A dolgozatban az NDVI értékek mindegyik felvételre az alapképletet (Jiang et al., 2008) használva – $NDVI = (NIR-RED) / (NIR+RED)$ – voltak kiszámítva.

Az NDVI értékek -1 és +1 között mozognak; az értékek minél inkább +1-hez közeleiek, annál sűrűbb és egészségesebb növényzetre utalnak, a 0-hoz közeli, vagy negatív értékek gyér növényzetre, vagy a növényzet hiányára utalnak. A földterületek termőképesség szerinti osztályozásához 0.2-nél magasabb küszöbértéket használtunk, hasonlóan a szakirodalomban használt értékekhez (Temerdek-Ivan et al., 2025; Klimavičius et al., 2023; Angearu et al., 2020). A vizsgált területen a 0.2 alatti NDVI-értékek beépített területeket, vízzel borított felszíneket, valamint terméketlen, elhagyatott vagy kopár területeket jelölnek. A 0,2 fölötti NDVI-értékeket mezőgazdaságilag hasznosított, produktív területekként értelmeztük, a mezőgazdasági termőterületek azonosítása céljából. A műholdfelvételek feldolgozása ArcGIS Pro és Google Earth Engine szoftverek felhasználásával történt.

3.4. Donyeck régió felszíni változásainak vizsgálata 2021-2024 években, nagy felbontású (3 m) PlanetScope műholdfelvételekkel

Ebben a részben, Donyeck régió felszíni változásait vizsgáltuk, a Planet Labs Inc. - PlanetScope műholdfelvételei alapján. Ezek a műholdak napi szintű, teljes lefedettséget biztosítanak a Föld egész területére, 3 m-es felbontásban. A vizsgálatokhoz 2021 és 2024 júniusi mozaikokat használtunk.

A földhasználati minták elemzéséhez a Random Trees Machine Learning osztályozási módszert alkalmaztuk, amely az ArcGIS Pro-ban elérhető Random Forest algoritmus (Breiman, 2001) implementációja. Ezt a módszert széles körben alkalmazzák a távérzékelési adatok osztályozására, és kifejezetten pontos eredményeket ad (Phan et al., 2020; Li et al., 2016; Rodriguez-Galiano et al., 2012). Első lépésként mintaterületeket készítettünk minden egyes osztályhoz (lásd 2. táblázat). A Random Trees osztályozási módszer több különböző döntési fát hoz létre, mindegyiket a mintaterületek egy véletlenszerű részhalmazán betanítva. Mindegyik csomópontnál, egy véletlenszerű részhalmazát használja az adatok homogénebb alcsoportokra való felosztásához. Minden egyes fa egy-egy előrejelzést készít, és a legtöbb szavazatot kapott eredmény kiválasztásával adja meg a végeredményt (Blickensdörfer et al., 2021; Mohandoss et al., 2021; Nguyen et al., 2013; Al-Abadi et al., 2023).

2. táblázat: Random Trees-mintaterületek

Felszínborítás	Mintaszám
Erdő	50
Beépített terület	80
Mezőgazdasági terület	80
Gyep	25
Víz	25
Kopár talaj / Csupasz talaj	25

Az osztályozási módszer pontosságát a Kappa-elemzéssel, egy

A Kappa-együttható a következő képlettel lett kiszámítva (Rwanga et al., 2021):

$$k = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} x_{+i})}$$

Ahol: k – a Kappa-érték

N – a pixelek száma

x_{ii} – az i sorban és i oszlopban lévő adatok

x_i – az i sor értékeinek összege

x_{+i} – az i oszlop értékeinek összege

A k értékei 1 és 0 között mozogtak, ahol az 1- a megfigyelt és a becsült osztályok között szinte tökéletesen megegyeznek az adatok, a 0-hoz közeli értékek pedig gyenge (poor) vagy enyhe (slight) egyezést mutattak a 3. táblázat szerint (Rwanga et al., 2021; Landis et al., 1977):

3. táblázat: Kappa-értékek értelmezése

Kappa statistics	Strength of agreement
<0.00	Poor

0.00 - 0.20	Slight
0.21 - 0.40	Fair
0.41 - 0.60	Moderate
0.61 - 0.80	Substantial
0.81 - 1.00	Almost perfect


4. Eredmények

4.1. A megsemmisült épületek beazonosítása SAR-Sentinel-1 radarfelvételeket használva, 2022-2023-2024 években Donyeck és Mariupol városokban

4.2. 4.2. Éjszakai fénydinamika Donyeck régióban: tér-időbeli változások éjszakai műholdfelvételek alapján (VIIRS, 2022–2024)


A 3.2 alpontban leírt módszertant követve az éjszakai műholdfelvételek feldolgozásra kerültek. Ezek eredményeként 2022 januárjától 2024 augusztusáig minden hónap felvételét térképre vittük. Itt meg kell említeni, hogy úgy 2022-ben, mint 2023 és 2024-ben is a júniusi felvételek hiányosnak minősültek, így ezek nem kerültek fel a térképeinkre.


A feldolgozások eredményeként először a háború közvetlen kitörése előtti- és utáni felvételeket érdemes emlitenünk, mivel itt a leg drasztikusabb a változás. Köztudottan 2022 februárjában Oroszország teljeskörű inváziót indított Ukrajna ellen, ezzel kezdetét vette az Orosz-Ukrán háború, amely számos fegyveres összecsapást követelt maga után. A támadások következtében számos kár keletkezett, többek között az infrastruktúrában is, amely az éjszakai fényeken is jól látható. A mellékelt ábra is jól mutatja, hogy amíg januárban még Donyeck teljes területén nagy intenzitása van az éjszakai fényeknek, addig áprilisra ez drasztikusan lecsökkent és csak a régióközpontban észlelhetők éjszakai fények. Meg kell jegyezni, hogy az egyes hónapok felvételein jelen lévő fehér foltok a felhős égbolt által keletkeztek, így ezek nem felhőmentes, tiszta felvételek.



A jobb szemléltetés és nyomon követhetőség érdekében térképmozaikokat készítettünk, amelyeken jól nyomon követhetők a háború eseményei, például a már előbb említett 2022 január-áprilisi fényforrások csökkenése. A 2022-es felvételek éjszakai fényei januártól májusig


csökkennek, de meg kell említeni a fényforrások növekedését is, amelyek a 2022 szeptember és a 2023 szeptember közötti felvételeken növekednek, majd 2023 októberétől ismét csökkennek. Ez a folyamatos fénydinamika változás mind a fegyveres támadások miatt történik.





4.3. Donyeck régió felszíni változásainak vizsgálata 2021-2024 években, nagy felbontású (3 m) PlanetScope műholdfelvételekkel


Év/Kategória	Erdő	Beépített	Mezőgazdasági terület	Fű/legelő	Vízfelszín	Csúsztalaj
2021	2936.35 km ²	4945.70 km ²	24694.67 km ²	12321.98 km ²	964.42 km ²	85.11 km ²
2024	2827.24 km ²	3698.91 km ²	23319.12 km ²	14903.05 km ²	716.43 km ²	483.48 km ²



Random tree 2021

Forest Grassland
Built-up Water

2021




Random tree 2024

Forest Grassland
Built-up Water

2024



4.4 NDVI-index összehasonlítása Donyeck térségében: termőföldek felismerése PlanetScope adatok alapján (2021–2024 június)



A termőföldek kiterjedése Sentinel-2 és NDVI (>0,2) alapján (2021–2024)

Év	Pixelek száma	Termőföldek területe
2021	384 308 082	38.43 km ²
2022	332 419 500	33.25 km ²
2023	353 888 120	35.39 km ²
2024	286 910 802	28.69 km ²

5. Következtetések

6. Irodalomjegyzék

1. ENSZ UN-SPIDER. (n. é.). Földrengés okozta károk detektálása Sentinel-1 adatokkal – lépésről lépésre. United Nations Office for Outer Space Affairs. Letöltve: 2025. április 10., <https://www.un-spider.org/advisory-support/recommended-practices/earthquake-damage-detection-sentinel-1/step-by-step>.
2. Racek, D., Zhang, Q., Thurner, P. W., Zhu, X. X., Kauermann, G. (2025). Detection of building destruction in armed conflict from publicly available satellite imagery. *Institute of Statistics, LMU Munich*.
3. Bennett, M. M., Van Den Hoek, J., Zhao, B., & Prishchepov, A. V. (2022). Improving satellite monitoring of armed conflicts. *Earth's Future*, 10, e2022EF002904. <https://doi.org/10.1029/2022EF002904>.
4. Holobacă I. H., Ivan K., Alexe M. (2019). Extracting built-up areas from Sentinel-1 imagery using land-cover classification and texture analysis. *International Journal of Remote Sensing*, 40 (20), 8054-8069. <https://doi.org/10.3390/rs15123096>.
5. Feng, X., Li, P., & Cheng, T. (2021). Detection of urban built-up area change from Sentinel-2 images using multiband temporal texture and one-class random forest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 6974–6986.
6. Oşlobanu, C., & Alexe, M. (2021). Built-up area analysis using Sentinel data in metropolitan areas of Transylvania, Romania. *Hungarian Geographical Bulletin*, 70(1), 3–18. <https://doi.org/10.15201/hungeobull.70.1.1>.
7. Aimaiti, Y.; Sanon, C.; Koch, M.; Baise, L.G.; Moaveni, B. War Related Building Damage Assessment in Kyiv, Ukraine, Using Sentinel-1 Radar and Sentinel-2 Optical Images (2022) *Remote Sens.*, 14, 6239. <https://doi.org/10.3390/rs14246239>.
8. Fakhri, F., & Gkanatsios, I. (2021). Integration of Sentinel-1 and Sentinel-2 data for change detection: A case study in a war conflict area of Mosul city. *Remote Sensing Applications: Society and Environment*, 22, 100505. <https://doi.org/10.1016/j.rsase.2021.100505>.
9. Huang, C., Hong, S., Niu, X., Wu, Q., Zhong, Y., Yang, H., & Zhang, H. (2023). Mapping of nighttime light trends and refugee population changes in Ukraine during the Russian–Ukrainian War. *Frontiers in Environmental Science*, 11, 1055100. <https://doi.org/10.3389/fenvs.2023.1055100>.
10. Xu, H., Barbot, S., & Wang, T. Remote Sensing Through the Fog of War: Infrastructure Damage and Environmental Change During the Russian-Ukrainian Conflict Revealed by Open-Access Data. *Natural Hazards Research*, Volume 4, Issue 1, (2024), Pages 1-7, ISSN 2666-5921, <https://doi.org/10.1016/j.nhres.2024.01.006>.
11. Miranda, N. & Meadows, R.J. (2015). *Radiometric Calibration of S-1 Level-1 Products Generated by the S-1 IPF*. European Space Agency. Issue 1. Revision 0. <https://sentinel.esa.int/documents/247904/685163/S1-Radiometric-Calibration-V1.0.pdf>
12. Yommy, Aiyeola Sikiru & Liu Rongke & Wu, And Shaung. (2015) *SAR Image Despeckling Using Refined Lee Filter*. 7th International Conference on Intelligent Human-Machine Systems and Cubrnetics. Hangzhou. Pp. 260-265. <https://ieeexplore.ieee.org/document/7334965/authors>.
13. Ivan, K., Holobacă, I.-H., Benedek, J., & Török, I. (2020). VIIRS Nighttime Light Data for Income Estimation at Local Level. *Remote Sensing*, 12(18), 2950. <https://doi.org/10.3390/rs12182950>.

14. Li, X.; Ge, L.L.; Chen, X.L. Detecting Zimbabwe's decadal economic decline using nighttime light imagery. *Remote Sens.* 2013, 5, 4551–4570.
15. Mellander, C., Lobo, J., Stolarick, K., & Matheson, Z. (2015). *Night-time light data: A good proxy measure for economic activity?* PLOS ONE, 10(10), e0139779. <https://doi.org/10.1371/journal.pone.0139779>.
16. Pérez-Sindín, X. S., Chen, T.-H. K., & Prishchepov, A. V. (2021). *Are night-time lights a good proxy of economic activity in rural areas in middle and low-income countries? Examining the empirical evidence from Colombia.* Remote Sensing Applications: Society and Environment, 24, 100647. <https://doi.org/10.1016/j.rsase.2021.100647>.
17. Yin, Z., Li, X., Tong, F., Li, Z., & Jendryke, M. (2019). Mapping urban expansion using night-time light images from Luojia1-01 and International Space Station. *International Journal of Remote Sensing*, 41(7), 2603–2623. <https://doi.org/10.1080/01431161.2019.1693661>.
18. Zheng, Y., He, Y., Zhou, Q., & Wang, H. (2022). Quantitative evaluation of urban expansion using NPP-VIIRS nighttime light and Landsat spectral data. *Sustainable Cities and Society*, 76, 103338. <https://doi.org/10.1016/j.scs.2021.103338>.
19. Andries, A., Morse, S., Murphy, R. J., Sadhukhan, J., Martinez-Hernandez, E., Amezcua-Allieri, M. A., & Aburto, J. (2023). Potential of Using Night-Time Light to Proxy Social Indicators for Sustainable Development. *Remote Sensing*, 15(5), 1209. <https://doi.org/10.3390/rs15051209>.
20. Rogers, G., Koper, P., Ruktanonchai, C., Ruktanonchai, N., Utazi, E., Woods, D., Cunningham, A., Tatem, A. J., Steele, J., Lai, S., & Sorichetta, A. (2023). Exploring the Relationship between Temporal Fluctuations in Satellite Nightlight Imagery and Human Mobility across Africa. *Remote Sensing*, 15(17), 4252. <https://doi.org/10.3390/rs15174252>.
21. Stathakis, D., & Baltas, P. (2018). Seasonal population estimates based on night-time lights. *Computers, Environment and Urban Systems*, 68, 133–141. <https://doi.org/10.1016/j.compenvurbsys.2017.12.001>.
22. Huang, C., Hong, S., Niu, X., Wu, Q., Zhong, Y., Yang, H., & Zhang, H. (2023). Mapping of nighttime light trends and refugee population changes in Ukraine during the Russian–Ukrainian War. *Frontiers in Environmental Science*, 11, 1055100. <https://doi.org/10.3389/fenvs.2023.1055100>.
23. Chen, X. (2020). Nighttime Lights and Population Migration: Revisiting Classic Demographic Perspectives with an Analysis of Recent European Data. *Remote Sensing*, 12(1), 169. <https://doi.org/10.3390/rs12010169>.

24. Quan, X., Song, X., Miao, J., Huang, C., Gao, F., Li, J., & Ying, L. (2023). Study on the substitutability of nighttime light data for SDG indicators: A case study of Yunnan Province. *Frontiers in Environmental Science*, 11, 1309547. <https://doi.org/10.3389/fenvs.2023.1309547>.
25. Breiman, L. Random forests. *Machine Learning* **2001**, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>.
26. Phan, T.N.; Kuch, V.; Lehnert, L.W. Land Cover Classification using Google Earth Engine and Random Forest Classifier—The Role of Image Composition. *Remote Sens.* **2020**, 12, 2411. <https://doi.org/10.3390/rs12152411>.
27. Li, X.; Chen, W.; Cheng, X.; Wang, L. A Comparison of Machine Learning Algorithms for Mapping of Complex Surface-Mined and Agricultural Landscapes Using ZiYuan-3 Stereo Satellite Imagery. *Remote Sens.* **2016**, 8, 514.
28. Rodriguez-Galiano, V.F.; Chica-Rivas, M. Evaluation of different machine learning methods for land cover mapping of a Mediterranean area using multi-seasonal Landsat images and Digital Terrain Models. *Inter. J. Digital Earth* **2012**, 7, 492–509.
29. Blickensdörfer, L.; Schwieder, M.; Pflugmacher, D.; Nendel, C.; Erasmi, S.; Hostert, P. Mapping of crop types and crop sequences with combined time series of Sentinel-1, Sentinel-2 and Landsat 8 data for Germany. *Remote Sens. Environ.* **2021**, 268, 112831. <https://doi.org/10.1016/j.rse.2021.112831>.
30. Mohandoss, D. P.; Shi, Y.; Suo, K. In *IEEE 11th Annual Computing and Communication Workshop and Conference (CCWC)*. Outlier Prediction Using Random Forest Classifier. **2021** doi:10.1109/ccwc51732.2021.9376077.
31. Nguyen, C.; Wang, Y.; Nguyen, H. Random forest classifier combined with feature selection for breast cancer diagnosis and prognostic. *J. Biomed. Eng.* **2013**, 6, 551-560. doi: 10.4236/jbise.2013.65070.
32. Al-Abadi, A.A.J.; Mohamed, M.B.; Fakhfakh, A. Enhanced Random Forest Classifier with K-Means Clustering (ERF-KMC) for Detecting and Preventing Distributed-Denial-of-Service and Man-in-the-Middle Attacks in Internet-of-Medical-Things Networks. *Computers* **2023**, 12, 262. <https://doi.org/10.3390/computers12120262>.
33. Rwanga, S.; Ndambuki, J. Accuracy Assessment of Land Use/Land Cover Classification Using Remote Sensing and GIS. *Int. J. Geosci.* 2017, 8, 611-622.
34. Landis, J.R.; Koch, G.G. A One-Way Components of Variance Model for Categorical Data. *Biometrics* 1977, 33, 671-679. <https://doi.org/10.2307/2529465>.
35. Ursu, C.-D., Benedek, J., & Temerde-Ivan, K. (2025). Accuracy Assessment of Four Land Cover Datasets at Urban, Rural and Metropolitan Area Level. *Remote Sensing*, 17(5), 756. <https://doi.org/10.3390/rs17050756>.

36. Angearu, C.-V., I. Ontel, G. Boldeanu, et al. 2020. "Multi-Temporal Analysis and Trends of the Drought Based on MODIS Data in Agricultural Areas, Romania." *Remote Sensing* **12**: 3940. <https://doi.org/10.3390/rs12233940>.
37. Candiago, S.; Remondino, F.; De Giglio, M.; Dubbini, M.; Gattelli, M.(2015) Evaluating Multispectral images and vegetation indices for precision farming applications from UAV images. *Remote Sens.*, 7, 4026–4047.
38. Fitts, Y., Tucker, C. J., Hiernaux, P., Auda, Y., & Kergoat, L. (2025). Using PlanetScope NDVI time series to detect the phenology of individual trees in the Sahel. *Remote Sensing of Environment*, 321, 114650. <https://doi.org/10.1016/j.rse.2024.114650>.
39. Houborg, R., & McCabe, M. F. (2016). High-Resolution NDVI from Planet's Constellation of Earth Observing Nano-Satellites: A New Data Source for Precision Agriculture. *Remote Sensing*, 8(9), 768. <https://doi.org/10.3390/rs8090768>.
40. Ivits, E., and M. Cherlet. 2016. *Land-Productivity Dynamics Towards Integrated Assessment of Land Degradation at Global Scales. EUR, Scientific and Technical Research Series*. Vol. **26052**. Luxembourg: Publications Office. <https://doi.org/10.2788/59315>.
41. Jiang, Z., A. R. Huete, K. Didan, and T. Miura. 2008. "Development of a Two-Band Enhanced Vegetation Index Without a Blue Band." *Remote Sensing of Environment* **112**: 3833–3845. <https://doi.org/10.1016/j.rse.2008.06.006>.
42. Klimavičius, L., E. Rimkus, E. Stonevičius, and V. Mačiulytė. 2023. "Seasonality and Long-Term Trends of NDVI Values in Different Land Use Types in the Eastern Part of the Baltic Sea Basin." *Oceanologia* **65**, no. 1: 171–181. <https://doi.org/10.1016/j.oceano.2022.02.007>.
43. Reith, J., G. Ghazaryan, F. Muthoni, and O. Dubovyk. 2021. "Assessment of Land Degradation in Semiarid Tanzania—Using Multiscale Remote Sensing Datasets to Support Sustainable Development Goal 15.3." *Remote Sensing* 13, no. 9: 1754. <https://doi.org/10.3390/rs13091754>.
44. Rouse, J.; Haas, R.; Schell, J.; Deering, D. (1973) Monitoring vegetation systems in the Great Plains with ERTS. In *Proceedings of the Third ERTS-1 Symposium NASA SP-351*, Washington, DC, USA, 10–14 December 1973; pp. 309–317.
45. Roznik, M., Boyd, M., & Porth, L. (2022). Improving crop yield estimation by applying higher resolution satellite NDVI imagery and high-resolution cropland masks. *Remote Sensing Applications: Society and Environment*, 25, 100693. <https://doi.org/10.1016/j.rsase.2022.100693>.
46. Temerdek-Ivan, K., Benedek, J., Török, I., Holobacă, I.-H., & Alexe, M. (2025). Determination of land degradation in Romania at a local scale using advanced analytical

techniques. *Land Degradation & Development*. Advance online publication.
<https://doi.org/10.1002/ldr.5450>.

47. Tucker, C.J., 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8, 127–150.