

FELHŐALAPÚ SZÚKÁR MONITORING NORVÉGIÁBAN

Molnár Tamás

Soproni Egyetem, Erdészeti Tudományos Intézet, Ökológiai és Erdőművelési Osztály

Kivonat

Norvégia erdőgazdasága és faipara szempontjából az egyik legfontosabb faj a lucfenyő (*Picea abies*). Az utóbbi években jelentkező, egyre súlyosabb szúgradációk (*Ips* spp.), azonban súlyos károkat okoznak, különösen az ország déli részén fekvő fenyvesekben. A szúkárók nagyterületű és hatékony monitoringjához elengedhetetlen a távérzékelési technológiák és a mesterséges intelligencia használata. A Norvég Bioökonómiai Intézet távérzékelési szúkár-monitoring csoportja 2024 nyarán a Sentinel-2 műholdak és a Google Earth Engine felhőrendszer segítségével monitorozta Dél-Norvégiát. Az alkalmazott Gradient Boost nevű gépi tanulási algoritmus által előállított osztályozás révén sikerült 10x10 méteres terepi felbontású osztályozott kártérképeket előállítani a 2020-es és 2024-es évekre. Az eredmények kimutatták a szúkár által leginkább érintett területeket, mint például Oslo-t, Siljan-t és Rødberg-et.

Kulcsszavak: szúkármonitoring, Norvégia, távérzékelés, Sentinel-2 műhold, felhőszolgáltatás, Google Earth Engine

CLOUD-BASED BARK BEETLE MONITORING IN NORWAY

Abstract

Norway spruce (*Picea abies*) is one of the most important tree species for the Norwegian forestry and timber industry. However, the increasing severity of the bark beetle gradation (*Ips* spp.) in recent years is causing serious damage, especially in the spruce forests in the south of the country. The use of remote sensing technologies and artificial intelligence is essential for large-scale and effective monitoring of bark beetle damage. The remote sensing monitoring team of the Norwegian Institute of Bioeconomy Research monitored southern Norway in the summer of 2024 using Sentinel-2 satellites and Google Earth Engine. We applied the Gradient Boost Machine Learning algorithm to create classified maps at 10x10 m spatial resolution for the years 2020 and 2024. The results showed the areas most affected by bark beetle damage, such as Oslo, Siljan, and Rødberg.

Keywords: bark beetle monitoring, Norway, remote sensing, Sentinel-2 satellite, cloud computing, Google Earth Engine

BEVEZETÉS

A távérzékelés napjainkban kulcsfontosságú eszközzé vált az erdőmonitoringnak is, hiszen az állományok állapotának változására számos lehetőséget kínál. Az egyik legsokoldalúbban alkalmazható technológia a műholdas távérzékelés. Az Európai Űrügynökség (ESA) által üzemeltetett Copernicus program részeként pályára állított Sentinel-2 műholdak segítségével nagybontású űrfelvételekkel rendelkezünk bolygónk erdeiről.



A műholdképek feldolgozása révén rendkívül hasznos tematikus erdőtérképek és idősoros elemzések készíthetők az állományokról, amelyek a terepi erdőkárok felmérést igen hatékonyan támogatni tudják. A Sentinel-2 műholdak 2-5 naponta tudnak térinformációt biztosítani, így egy kár felmérése majdnem valós időben megtörténhet. Az erdőkárok elemzésén és az erdőgazdálkodás téradataival való támogatásán túl hosszú távon a klímaváltozás hatásainak monitorozására is alkalmas a technológia, melynek változásával egyre gyakrabban tapasztalunk egyre súlyosodó károkat.

Norvégiában a 37%-os erdőszűltség mellett kb. 8 millió hektárt borítanak erdők. Az erdőállományok fajösszetétele jelentős hatással van az ország erdőgazdálkodására, ahol domináns állományok tűlevelűek. A norvég luc (*Picea abies* (L.), H. Karst 1881) a legelterjedtebb, ami 30%-os arányban található meg. Ezt követi a feketefenyő (*Pinus nigra*, J.F. Arnold 1785) 5%-kal, majd az erdei fenyő (*Pinus sylvestris*, Linnaeus 1753) 4%-kal, tehát összesen az erdőterületeknek majdnem 40%-a fenyő. Norvégia erdőgazdálkodása szempontjából a luc a legfontosabb évi 5-6 millió m³-es kitermeléssel.

A norvég erdők kiemelten fontosak gazdasági és klímavédelmi okokból is. Az erdőket ugyanakkor számos veszély fenyegeti, közülük az egyik legkomolyabb a betűzőszú (*Ips typhographus* (Linnaeus, 1758)) invázió, amely egyre jelentősebb károkat okoz a fenyvesekben a melegedő klímával összefüggésben. A norvégiai szűkárók súlyosságát jól szemlélteti, hogy 2019-ben az erdőgazdaságoknak 118 millió m³ egészségügyi termelést kellett végezniük, ami 8-51-szerese az 1970 és 2010 közötti évi átlagos vágási mennyiségeknek (2,3–14,5 millió m³) (Gohli et al., 2024). A korábban elszórt vagy foltokban jelentkező károsodások mára nagyobb, összefüggő területeken is megjelennek.

A szűkárók hatékony nyomon követése nélkülözhetetlen a hatékony erdőgazdálkodási és természetvédelmi intézkedések szempontjából. Az utóbbi években a távérzékelési technológiák, különösen a műholdak és a mesterséges intelligencia új lehetőségeket nyitottak az erdőmonitoringban, azon belül a biotikus károsítók pl. a szú kártételének úrfelvételeken történő felmérésében.

A szűkárók monitorozása az utóbbi években egyre nagyobb figyelmet kapott, mivel főként Európa északi és középső részét érintik nagymértékben. Norvégiában a szűkárók nyomon követésére különböző távérzékelési módszereket alkalmaznak. Hernández & Ståhl (2022) és Hollaus & Wagner (2021) tanulmányai rámutatnak arra, hogy a Sentinel-2 adatok és a távérzékelési technikák hatékonyak a szűkárók azonosításában és a károk mértékének értékelésében Norvégiában. A hasonló termőhelyi adottságú Svédországban Hedin & Olsson (2023) illetve Gustafsson & Nilsson (2023) mutatták be, hogyan alkalmazhatók a Sentinel-2 adatok a szűkárók monitorozására és az erdők állapotának felmérésére. A szintén legnagyobb részét boreális klímájú Finnországban Pölönen & Vanhatalo (2023) hasznosította Sentinel-2 úrfelvételeket és a gépi tanulást a szűkárók nyomon követésére és a károk felmérésére.

Közép-Európa számos országában is folynak hasonló kutatások. Günther & Böttcher (2023) tanulmánya bemutatja Németországban, hogy a Sentinel-2 adatok gyors és hatékony eszközként szolgálnak a szűkár terjedésének monitorozásában, ami kulcsfontosságú a védekezési stratégiák kialakításában. Hasonlóan, Jansen & Müller (2022) a multispektrális és hiperspektrális képalkotás jelentőségét hangsúlyozzák a fertőzések korai felismerésében. Csehországban Škerlep & Novák (2023) valamint Míková & Zima (2022) tanulmányai foglalkoznak a Sentinel-2 műholdképek felhasználásával végzett szűkárók észlelésével és a távérzékelési adatok terepi adatokkal való összevetésével. Magyarországon Kovács & Tóth (2023), Németh & Csányi (2022) és Molnár & Király (2023) foglalkoznak a Sentinel-2 adatok és a gépi tanulási technikák alkalmazásával a szűkárók monitorozására és a károk felmérésére. Ezek a kutatások hangsúlyozzák a távérzékelési technikák és a gépi tanulási

modellek fontosságát az erdőegészség és a kártevők monitorozásában, és rámutatnak arra, hogy a Sentinel-2 adatok széleskörű alkalmazásával jelentős előrelépést lehet elérni az erdőmonitoringban.

A Norvég Bioökonómiai Intézet (NIBIO) távérzékelési szúrkármonitoring csoportjának célja 2024 nyarán az volt, hogy a meglévő mellett új modellek pontosságát vizsgálja a Kilden erdőportálon (skogportal). A meglévő Vision Transformer (ViT) modell (Daniel et al. (2020) mellett ebben az évben két további új modellt fejlesztettünk ki, az egyik a mélytanulás (Deep Learning) Convolution Neural Network (CNN) módszerét alkalmazza (Kaselimi et al. 2023), a másik a felhőalapú (Cloud computing) gépi tanulást (Machine Learning). A három megfigyelőrendszer célja ugyanaz volt, az erdők állapotának megfigyelése a szúrkárokkal összefüggésben műholdas képfeldolgozás és mesterséges intelligencia segítségével, ugyanakkor jelen cikk csak a felhőalapú módszert taglalja részletesebben. A többféle módszer tesztelését az egyre fokozódó mértékű és méretű szúrkárok indokolták (1. ábra).



1. ábra: A rødberg-i nagyterületű erdőkárokról 2024 júliusában készült fénykép. Fotó: Dr. Marius Hauglin
Figure 1: Larger scale forest damage in Rødberg, July 2024. Photo: Dr. Marius Hauglin

ANYAG ÉS MÓDSZER

Terepi adatok

A NIBIO kutatói által kifejlesztett Kilden erdőportál és a SR16 erdészeti térkép pontos és sokrétű adatbázist szolgáltat norvég erdők távérzékelési monitorozásához. A Kilden portál átfogó információkat szolgáltat az erdőállapotokról és az erdők változásáról. Az SR16 térkép részletes térbeli

információkat szolgáltat az erdőkről különböző léptékeken úgy, hogy integrálja a légi lézeres felméréseket, optikai műholdképeket és az országos erdőállomány adattár adatait is (Astrup et al. 2019, Hauglin et al).

Távérzékelés Sentinel-2 műholdakkal

Az Európai Űrügynökség (ESA) Sentinel-2 műholdjai az európai léptékű térképezés és földmegfigyelés egyik legfontosabb eszközei 2015-től. A Sentinel-2 (S-2) műholdak multispektrális szenzorokkal rendelkeznek, amelyek lehetővé teszik a földfelszín változásainak részletes nyomon követését (ESA, 2024a). Az S-2 műholdak folyamatosan biztosítanak friss adatokat a vegetációról, a talajról és más környezeti tényezőkről, amelyeket számos kutatásban használnak a természeti károk és környezeti degradáció azonosítására, így például a szűkárók monitorozására is. Mivel 2024 szeptemberétől a Sentinel-2 A, B és C műhold is a konstellációban repül, a korábbi két műhold helyett jelenleg három is a pályán van (ESA, 2024b).

Az S-2 műholdképekből két spektrális indexet számítottunk ki. Ezen indexek a Normalizált Vegetációs Index (Normalized Difference Vegetation Index, NDVI) és a Normalizált Nedvesség Index (Normalized Difference Water Index, NDWI) voltak, amelyeket gyakran használnak a vegetáció állapotának megfigyelésére a fotoszintetikus aktivitással és a lombkorona nedvességével kapcsolatban.

A fotoszintetikus aktivitás és az ezzel összefüggő egészségi állapot mérésére a Normalizált Vegetációs Indexet (NDVI) (1) használják a leggyakrabban, melynek számítása módja (Rouse et al. 1974):

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

ahol, a NIR a közeli infravörös, a RED a vörös csatatornában mért felszíni reflektancia érték.

A Normalizált Nedvesség Index (NDWI) a lombkorona és a talaj nedvességtartalmára érzékeny nedvességi vagy víz index (Gao 1996), aminek a képlete (2) a következő:

$$NDWI = \frac{NIR - SWIR}{NIR + SWIR} \quad (2)$$

ahol, a NIR a közeli infravörös, a SWIR a rövidhullámú infravörös csatatornában mért felszíni reflektancia érték.

Google Earth Engine

A Google Earth Engine (GEE) egy rendkívül hatékony eszköz az akár globális léptékű térinformatikai elemzésekhez. Gorelick et al. (2017) bemutatták, hogy a GEE hogyan teszi lehetővé a földmegfigyelését és a távérzékelési adatok gyors feldolgozását, amelyek az erdészeti kutatások során is jól hasznosíthatóak. A GEE felhőalapú infrastruktúrája lehetővé teszi tematikus erdőterképek készítését és elemzését is egy platformon belül.

Módszerem a GEE felhőalapú szolgáltatásának használatán alapul, amely számos lehetőséget kínál a földmegfigyelésére, beleértve az erdők egészségi állapotának monitorozását. Ehhez a

programomat JavaScript nyelven írtam a GEE alkalmazás programozási felületén. A program az S-2 műholdképeit és a GEE-be épített mesterséges intelligencia gépi tanulási algoritmusát használja.

A modellem bemeneti adatai a NIBIO erdőállomány állapot térképéből származtatott tanító és teszt pontok voltak. Ezek az adatkészletek raszteres formátumúak, 2020-ból származnak, és a dél-norvégiai Fritzsche Erdészeti Zrt. területét fedik le, ahol minden pixel kategorizált: egyéb erdő (0), egészséges erdő (1), holt erdő (2) és tarvágás (3). Az egyéb erdő kategória az alacsony záródású állományokat jelöli. A tanítóadatok összterülete körülbelül 343000 ha, míg a tesztadatoké 3800 ha.

A NIBIO az SR16 erdészeti erőforrástérkép részeként erdőmaszkot is szolgáltat. Ez a térkép a lucfenyő képpontjaira lett szűrve, ahol 15 m feletti a fmagasság és 800 m alatti a tengerszint feletti magasság, amik ideálisak a szű gradációkhoz. Továbbá a vezetékek 15 méteres sávja is ki van vágva a maszkból. Ezt használtam erdőmaszkként. Mindhárom geoadatbázist raszteres formátumból vektoros pontokká alakítottam át, hogy a GEE felhőbe feltölthető legyen. Az eredeti adatállomány méretének csökkentése érdekében az egyes osztályokból (egyéb erdő, egészséges erdő, holt erdő, kivágás) véletlenszerű mintavételt alkalmaztam, megtartva összesen 50000 pontot. Ehhez az előfeldolgozáshoz a QGIS 3.22.6 szoftvert használtam.

A GEE-beli módszer több lépésből áll a kívánt cél eléréséhez. Elsőnek az S-2 felvételeket Dél-Norvégia területére szűrtük, majd az alacsony felhőzetre (<5%) és a vegetációs időszakra (május-szeptember) szűkítjük tovább a feldolgozandó adatokat. A háromszoros szűrés biztosítja a kívánt területre és időablakra vonatkozó legjobb minőségű kompozitot, ami lehetőleg felhőmentes és térképi hézagok nélküli. Az mintaterületet (AOI) hat S-2 úrfelvétel területével (32VMK, 32VML, 32VMM, 32VNL, 32VNM, 32VPM) alapján határoztuk meg, amelyek Dél-Norvégiát fedik le, egyenként 100x100 km-es területtel.

A GEE számára újszerű erdőmaszkot készítettünk a hat SR16 csempe (az S-2 csempe területével megegyező terület) összevonásával, amelyet a műholdképek vágásához használtak erdőmaszkként. Mivel minket a 2020-as év érdekelt, amikor a földi adatokat gyűjtötték, és az idej, 2024-es év, mindkét évre lefuttattam a kódot. Az S-2 kompozit 2020-ban 46 képből, míg 2024-ben 29 képből készült.

Miután feltöltöttük a terepi adatokat a Google felhőbe és előállítottuk az S-2 kompozitokat is egy lekérdezéssel, a képfeldolgozás következő lépése a gépi tanulás alkalmazása volt. A Gradient Boost (GB) algoritmust alkalmaztuk a képosztályozáshoz (Friedman 2001). A GB az összes S-2 sávot és két spektrális indexet, tehát összesen 14 sávot használt az algoritmus tanításához. Ezen indexek a Normalizált Vegetációs Index (NDVI) és a Normalizált Nedvességi Index (NDWI) voltak, amelyeket széles körben használnak a vegetáció állapotának megfigyelésére a fotoszintetikus aktivitással és a lombkorona nedvességtartalmával összefüggésben. Négy osztály volt mind a tanító, mind a validáló adatokhoz: egyéb erdő (0), egészséges erdő (1), holt erdő (2) és tarvágás (3). Ezekkel az osztályokat a terepi adatok alapján alakítottuk ki és a tanításhoz, valamint a validáláshoz egységesen használtuk fel őket.

A GB többi bemeneti paramétereit illetően 100 darab döntési fát használt az algoritmus, a tanulási arány (shrinkage) 0.1, az adatok mintavételezési aránya 1, az egyes fák maximális csomópont száma 20, a veszteségi függvény típusa LeastSquares és a randomizálás (seed) 0 volt. A GB-t 2020-as adatokkal tanítottuk és a 2020-as, valamint a 2024-es műholdképekre is lefuttattuk az osztályozót. Mind a 2020-as, mind a 2024-es kompozitok a felhőszűrt, vegetációs időszakot mutató legjobb minőségű pixelekből álltak össze.

Hibamátrix

A hibamátrixot pixel alapú osztályozási eredmények értékelésére használjuk, ahol az oszlopok a valós osztályokat, a sorok pedig a modell által becslteket mutatják. Négy osztályt alakítunk ki a mátrixban, ezek a következők:

- Valódi Pozitív (VP): amikor a modell helyesen jósolta meg a pozitív osztályt,
- Valódi Negatív (VN): amikor a modell a negatív osztályt jósolta meg helyesen,
- Hamis Pozitív (HP): amikor a modell tévesen pozitívnak jósolta az esetet, de valójában negatív volt,
- Hamis Negatív (HN): amikor valójában pozitív volt, de a modell tévesen negatívnak jósolta az esetet.

A mátrix osztályaiból különböző mérőszámokat számítunk, ezeket a pontosság, a precizitás, a szenzitivitás, a specificitás, az F1-érték és a teljes pontosság. Számításuk az alábbiak szerint történik:

- Teljes pontosság (3) azaz a helyes előrejelzések aránya az összes előrejelzéshez képest,

$$TP = \frac{VP+VN}{VP+VN+HP+HN} \quad (3)$$

- Precízió (4): tehát a pozitívként jósolt esetek közül a valóban pozitív esetek aránya,

$$P = \frac{VP}{VP+HP} \quad (4)$$

- Szenzitivitás (5): a valódi pozitív esetek közül a modell által helyesen azonosított esetek aránya,

$$SZ = \frac{VN}{VP+HN} \quad (5)$$

- Specificitás (6): ami a valódi negatív esetek közül a modell által helyesen negatívnak azonosított esetek aránya,

$$S = \frac{HP}{VN+HP} \quad (6)$$

- Negatív Prediktív Érték (7): a negatívként jósolt esetek közül a valóban negatív esetek aránya.

$$NPE = \frac{VN}{VN+HN} \quad (7)$$

Gyártói Pontosság (GP) képlete (8):

$$GP = \frac{\text{helyesen besorolt pixelek száma az osztályban}}{\text{osztályba besorolt összes pixel száma}} * 100 \quad (8)$$


Felhasználói Pontosság (FP) képlete (9):

$$FP = \frac{\text{helyesen besorolt pixelek száma az osztályban}}{\text{osztályba besorolt összes pixel száma}} * 100 \quad (9)$$

EREDMÉNYEK ÉS MEGVITATÁSUK

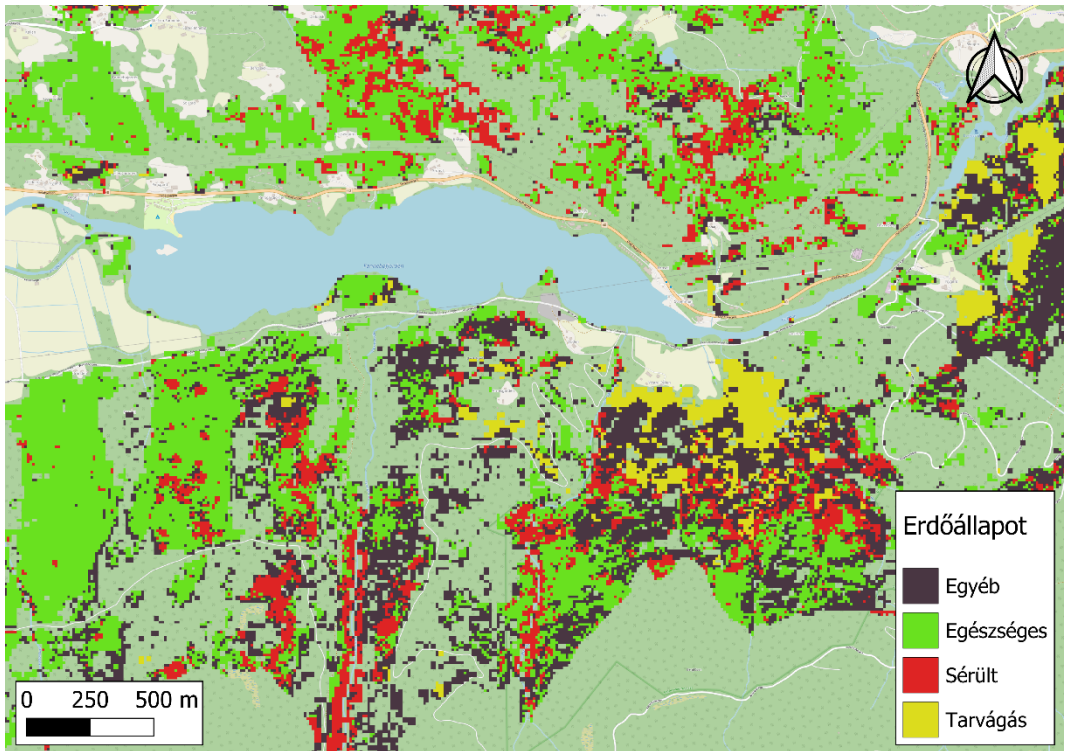
Eredményként online osztályozott térképeket gyártottunk 10x10 m-es felbontásban, négy tematikus osztállyal. A térképek 2020 nyarának kiválasztott időpontjaira (2020.06.26., 2020.07.31., 2020.08.15.), 2020 teljes nyarára 2024-re is elkészültek. A 2020-as térképek Fritzsche Erdőgazdaság területére vonatkoztak, de a 2024-es térképek egész Dél-Norvégiát lefedték. Minden térképet tif formátumban, a CRS 25832 segítségével exportáltunk, először a Google Drive-ra, majd később a számítógépre.

A térképek szemrevételezése után megállapíthattam, hogy várakozásainknak megfelelően a legtöbb erdő egészséges volt, de a szú okozta pusztulás és a tarvágások is megfigyelhetőek voltak, különösen Dél-Norvégia egyes területein (1. ábra). Ilyen volt 2020-ban Siljan területe (2. ábra), míg 2024-ben a Nore og Uvdal településhez tartozó Numedal-völgyben lévő Rødberg vagy Észak-Oslóban a Movatn és a Mellomkollen természetvédelmi terület közelében lévő Maridalen-völgyben. Az utóbbi két területen nagyobb mértékű károkat figyeltünk meg (2. és 3. ábra). Mindezen területeket a következő években figyelemmel kell kísérni a szúgradáció alakulását illetően, és nemcsak az erdészeti társaságokat, hanem a természetvédelmi hatóságokat is figyelmeztetni kell a szúkárok fokozódására.



2. ábra: Osztályozott kártérkép Oslo közelében 2024 nyarán. Jól láthatók a Mellomkollen rezervátumban lévő szúkárok és az erdőgazdálkodók által kezelt, tarvágott területek is

Figure 2: Classified forest damage map of Oslo, in summer 2024. The damage is visible caused by bark beetles in the Mellomkollen reserve and the clearcuts made by forest managers



3. ábra: Osztályozott kártérkép Rødberg közelében 2024 nyarán. Jól láthatók a rezervátumban lévő szűkárók és az erdőgazdálkodók által kezelt, tarvágott területek is

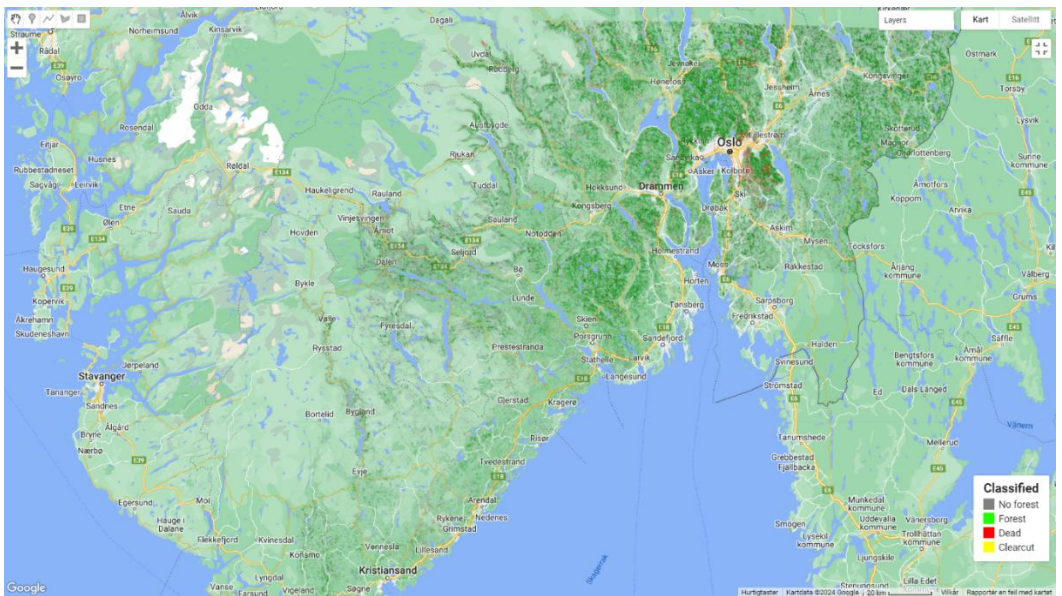
Figure 3: Classified forest damage map of Rødberg, in summer 2024. The damage is visible caused by bark beetles in the reserve and the clearcuts made by forest managers

Amikor összehasonlítottam az egyes osztályokba tartozó pixelek számát és egymáshoz viszonyított arányát, azt találtam, hogy a tanító adathalmazban 0,8% halott és 1,1% tarvágás volt, míg a tesztelésben 1% halott és 1,2% tarvágott. Az S-2 alapú osztályozott térképen csak 0,6% és 0,3% volt a halott és a tarvágott, vagyis a terepi igazsághoz képest alacsonyabb értékek, ami azt jelenti, hogy a modell konzervatív és nem ad túl sok téves előrejelzést.

Pontossági értékelést pixel szinten végeztem, amihez létrehoztam egy hibamátrixot mind a tanító, mind a validációs adatkészletekhez, majd kiszámítottam a gyártói (PA), felhasználói (UA) és teljes pontosság (TA) (Congalton & Green, 2019). A teljes pontosság a tanításnál 73% volt, míg a PA 71% és az UA 76%. A validáció teljes pontossága 56% volt, 35% PA, 33% UA mutatókkal. A tanítói pontosság elfogadható, biztosan nem túltanított a modell, de a validációs értékek még közepesek, javítandóak. Ugyanakkor, ha csak a Fritzøe Erdészeti Zrt. közel 350.000 hektáros területére vizsgáljuk a mérőszámokat, akkor a teljes pontosság 85,9%-ra nőtt.

1.táblázat: Az osztályozott kárterkép hibamátrixa
Table 1: Confusion matrix of classification

Osztály	Valódi Pozitív	Valódi Negatív	Hamis Pozitív	Hamis Negatív	Precízió	Szenzitivitás	Specifitás	Negatív Prediktív Érték
Egyéb erdő	2269	20721	1442	13803	0,6114	0,1412	0,9353	0,5998
Erdő	19232	3952	12889	2160	0,5987	0,9009	0,2349	0,6468
Holtfa	76	35315	1543	321	0,0469	0,1914	0,9583	0,9910
Tarvágás	87	37664	797	387	0,0984	0,1835	0,9793	0,9899
Teljes Pontosság	0,567							



4. ábra: Dél-Norvégia osztályozott erdőállapottérképe 2024 nyarán. Láthatók a főként Oslo közelében lévő szűkárak és az erdőgazdálkodók által kezelt, tarvágott területek is
Figure 4: Classified forest damage map of South Norway, in summer 2024. The damage is visible caused by bark beetles north of Oslo and the clearcuts made by forest managers

A módszer hatékonyságát összegezve megállapíthatom, hogy a GEE alkalmas a dél-norvégiai és a szűkárak megfigyelésére, a GEE-alapú térképek rendszeres, szolgáltatásszerű közzétételéhez azonban a szolgáltatás kereskedelmi verziója szükséges. Ezen túlmenően számos problémával találkozottam a számítási kapacitással kapcsolatban, így a nagyméretű adathalmazokat nem lehet sem feltölteni a felhőbe, sem letölteni onnan. A képzési adatok túl nagyok voltak ahhoz, hogy fel lehessen őket tölteni, ezért csökkenteni kellett őket.

ÖSSZEFOGLALÁS

A kutatás során sikeresen létrehoztuk a dél-norvégiai szűkárókat ábrázoló osztályozott térképeket, amelyek 10x10 méteres felbontásban készültek, és négy kategóriát tartalmaztak: egészséges erdő, holt erdő, egyéb erdő, valamint tarvágás. A térképek 2020-ra és 2024-re egyaránt elkészültek a vizsgálati időszakra és területre. A térképek vizuális elemzése során megállapítottuk, hogy bár a legtöbb erdő egészséges, azonban a szűkárók és az emiatti egészségügyi letermelések száma megnőtt az utóbbi években. A legjelentősebb károkat 2020-ban a Siljan területén figyeltük meg, míg 2024-ben a Rødberg környékén (Nore og Uvdal) és az Oslo környéki Maridalen-völgyben. Ha a pixelek osztályonkénti száma alapján vizsgáljuk a helyzetet, az mondható el, hogy S-2 alapú osztályozott térképen 0,6% és 0,3% volt az elpusztul lucos és tarvágás aránya a teljes területhez képest, ami 48840, illetve 24376 ha-os területet jelent. Az is látható, hogy a modell nem ad túl sok téves előrejelzést, hiszen a tanítóadatokban magasabb volt a halott állomány aránya. A modell pontosságát a statisztikai mutatókon túl hibamátrixszal is értékeltük. A tanító adatok teljes pontossága 74% volt, míg a tesztadatoké 57%. Ezek jó eredménynek mondhatóak, de modell fejlesztendő. Az alacsonyabb tesztelési pontosság különösen a holtfa és a tarvágások esetében figyelhető meg, amelyeknél a modell alulteljesített. Ugyanakkor összességében a módszer megfelelő volt a szűkárók megfigyelésére, és a Google Earth Engine jól használható a monitoringhoz, habár az országos szintű, nagy számosságú adatbázisok kezelésében akadályokba ütköztem. A jövőbeni fejlesztésekhez a számítási kapacitás növelése és a térképek publikálásának optimalizálása szükséges.

KÖSZÖNETNYILVÁNÍTÁS

Köszönöm Dr. Svein Solberg-nek, Dr. Marius Hauglin-nak, Dr. Aksel Granhus-nek, Dr. Bjørn Håvard Evjen-nek, Dr. Torstein Kvamme-nek (Norvég Bioökonómiai Intézet) a norvégiai szakmai tanácsokat, Dr. Borovics Attilának és Dr. Illés Gábornak (SOE ERTI) pedig a kutatás támogatását.

Jelen publikáció a TKP2021-NKTA-43 azonosítószámú projekt keretében a Kulturális és Innovációs Minisztérium Nemzeti Kutatási Fejlesztési és Innovációs Alapból nyújtott támogatásával, a TKP2021-NKTA pályázati program finanszírozásában valósult meg.

A kutatás a Kulturális és Innovációs Minisztérium, Nemzeti Kutatási Fejlesztési és Innovációs Alapból nyújtott támogatásával, az Egyetemi Kutatói Ösztöndíj Program keretében valósult meg.

A 2024-2.1.1-EKÖP-2024-00007 számú projekt a Kulturális és Innovációs Minisztérium Nemzeti Kutatási Fejlesztési és Innovációs Alapból nyújtott támogatásával, az EKÖP-24-4-II pályázati projekt finanszírozásában valósult meg.

IRODALOMJEGYZÉK

- Astrup R., Rahlf J., Bjørkelo K., Debella-Gilo M., Gjertsen A.K. & Breidenbach J. 2019: Forest information at multiple scales: development, evaluation and application of the Norwegian forest resources map SR16. *Scandinavian Journal of Forest Research* 34(6): 484–496.
- Brassard B.W. & Vanasse A. 2023: The effectiveness of Sentinel-2 imagery for detecting and quantifying bark beetle damage in Norwegian spruce forests. *Forests* 14(6): 1104.
- Congalton R. & Green K. 2019: *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, Third Edition. 10.1201/9780429052729. pp 17.
- European Space Agency (ESA) 2024a: Sentinel-2. https://www.esa.int/Enabling_Support/Operations/Sentinel-2_operations (Utolsó letöltés: 2024.12.16.)

- European Space Agency (ESA) 2024b: Sentinel-2C delivers stunning first images. https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2/Sentinel-2C_delivers_stunning_first_images (Utolsó letöltés: 2024.12.16.)
- Friedman J. H. 2001: Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 1189–1232.
- Gao B.C. 1996: NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment* 58: 257–266.
- Gohli J., Krokene P., Flo Heggem E. S. & Økland B. 2024: Climatic and management-related drivers of endemic European spruce bark beetle populations in boreal forests. *Journal of Applied Ecology* 61: 809–820. <https://doi.org/10.1111/1365-2664.14606>
- Gorelick N., Hancher M., Dixon M., Ilyushchenko S. & Thau D. 2017: Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment* 202: 18–27.
- Gustafsson M. & Nilsson M. 2023: Assessing bark beetle infestation in Swedish forests using multi-temporal Sentinel-2 imagery and machine learning. *International Journal of Remote Sensing* 44(6): 1885–1901.
- Günther F. & Böttcher H. 2023: Application of satellite-based remote sensing for monitoring bark beetle infestations in German forests. *Forest Ecosystems* 10(1): 20.
- Hallas T., Netherer S., Pennerstorfer J., Karel S., Schadauer T., Löw M. et al. 2024: The Bark Beetle Dashboard - towards a holistic risk assessment of *Ips typographus*. IUFRO World Congress 2024. <https://doi.org/10.13140/RG.2.2.11420.09603>
- Hauglin M., Rahlf J., Schumacher J., Astrup R. & Breidenbach J. 2021: Large scale mapping of forest attributes using heterogeneous sets of airborne laser scanning and National Forest Inventory data. *Forest Ecosystems* 8(1): 65.
- Hedberg S. & Lundin L. 2023: Evaluating remote sensing methods for bark beetle damage detection in Swedish forests. *Forestry* 96(4): 589–602.
- Hedin J. & Olsson H. 2023: Monitoring bark beetle infestations in Swedish forests using Sentinel-2 and Landsat data. *Forestry: An International Journal of Forest Research* 96(2): 237–248.
- Hernández J.C. & Ståhl G. 2022: Mapping forest pests and diseases using remote sensing: A review and case study of Norway spruce bark beetles. *Forest Ecology and Management* 505: 119927.
- Hollaas M. & Wagner W. 2021: Monitoring of forest health and bark beetle infestation in Norway using UAV and satellite remote sensing data. *International Journal of Applied Earth Observation and Geoinformation* 98: 102327.
- Jansen L. & Müller R. 2022: Evaluating remote sensing techniques for bark beetle infestation monitoring in German forests. *Forest Management and Planning* 28(4): 112–126.
- Jokinen S. & Lappalainen H. 2022: Remote sensing and Sentinel-2 imagery for monitoring bark beetle impacts in Finnish mixed forests. *Forestry Science* 68(3): 281–295.
- Kaslimi M., Voulodimos A., Daskalopoulos I., Doulamis N. & Doulamis A. 2023: A Vision Transformer Model for Convolution-Free Multilabel Classification of Satellite Imagery in Deforestation Monitoring. *IEEE Transactions on Neural Networks and Learning Systems* 34(7): 3299–3307. <https://doi.org/10.1109/TNNLS.2022.3144791>
- Kilden skogportalen (NIBIO) 2024: <https://kilden.nibio.no/?topic=skogportal> (Utolsó letöltés: 2024.12.16.)
- Kovács B. & Tóth J. 2023: Remote sensing applications for monitoring bark beetle infestations in Hungarian forests. *Acta Silvica Hungarica* 19(1): 45–58.
- Lindner M. & Maroschek M. 2022: Assessing forest resilience and bark beetle impacts in Norway: Insights from remote sensing and climate data. *Remote Sensing of Environment* 267: 112759.
- Miková H. & Zima J. 2022: Integration of remote sensing and field data for detecting bark beetle outbreaks in Czech forests. *European Journal of Forest Research* 141(6): 1069–1082.
- Molnár T. & Király G. 2023: Sentinel-2 satellite-based analysis of bark beetle damage in Sopron Mountain, Hungary. *Land-scape & Environment* 17(1): 33–40. <https://doi.org/10.21120/LE/17/1/3>
- Németh J. & Csányi M. 2022: Monitoring bark beetle damage in Hungarian coniferous forests using Sentinel-2 imagery and machine learning. *Hungarian Geographical Bulletin* 71(4): 352–366.
- Pölonen I. & Vanhatalo K. 2023: Assessing bark beetle damage in Finnish coniferous forests using Sentinel-2 data and spectral indices. *European Journal of Forest Research* 142(2): 267–281.
- Rouse J.W., Haas R.H., Scheel J.A. & Deering D.W. 1974: Monitoring Vegetation Systems in the Great Plains with ERTS. In *Proceedings of the 3rd Earth Resource Technology Satellite (ERTS) Symposium* 1: 48–62.
- Scharvogel D., Brandmeier M. & Weis, M. 2020: A Deep Learning Approach for Calamity Assessment Using Sentinel-2 Data. *Forests*. <https://doi.org/10.3390/F11121239>
- Škerlep M. & Novák P. 2023: Detection and monitoring of bark beetle infestations in Czech forests using Sentinel-2 imagery. *Journal of Forestry Research* 34(2): 315–328.

Érkezett: 2025.01.14.

Közlésre elfogadva: 2025.04.26.