

## **Tvorba aplikácie pre časopriestorovú analýzu zmien krajinej pokrývky a teploty povrchu pomocou družicových dát a algoritmov strojového učenia**

Bc. Anton UHRIN

Školiteľ: Mgr. Katarína Onačillová, PhD.

Adresa: Ústav geografie, PF UPJŠ, Jesenná 5, 080 01 Košice, e-mail: ug@upjs.sk

**Abstract:** *Urbanisation and deforestation are one of the most destructive processes that are significantly altering the natural landscape. Among the most affected areas are tropical rainforests, mainly as a result of logging and the expansion of plantations. In addition, new road networks are being built to connect remote settlements, increasing the quality of life on the one side, but on the other side there is a higher level of urbanisation, to the detriment of the loss of natural forest and other changes in the landscape structure, thus changing the Land Surface Temperature (LST). The aim of this thesis is to develop an application for spatio-temporal analysis of land cover and LST changes using the Google Earth Engine (GEE) platform for the island of Borneo with Landsat satellite data and machine learning algorithms. The proposed application in GEE is customizable and can be used for any area of interest in the world and widely applicable for e.g. land-use planning and sustainable development or climate change monitoring.*

**Keywords:** *land cover classification, Land Surface Temperature, satellite remote sensing, machine learning algorithms, Google Earth Engine*

### **Úvod**

Analýzy využívania zeme a monitoring krajinej pokrývky sú dôležitým nástrojom pre posudzovanie vplyvov zmien týchto štruktúr vzhľadom na možnú environmentálnu a ekologickú degradáciu. Moderné prístupy kombinujú geografické informačné systémy (skr. GIS) a metódy diaľkového prieskumu Zeme (skr. DPZ), ktorými dokážeme identifikovať, analyzovať a vizualizovať časový vývoj krajinej pokrývky. Táto metodika môže byť uplatnená pri územnom plánovaní, tvorbe plánov pre trvalo udržateľný rozvoj regiónov, či na mitigáciu, minimalizáciu alebo úplné odstránenie negatívnych vplyvov krajinných zmien na prirodzené prostredie (Bappa et al. 2022).

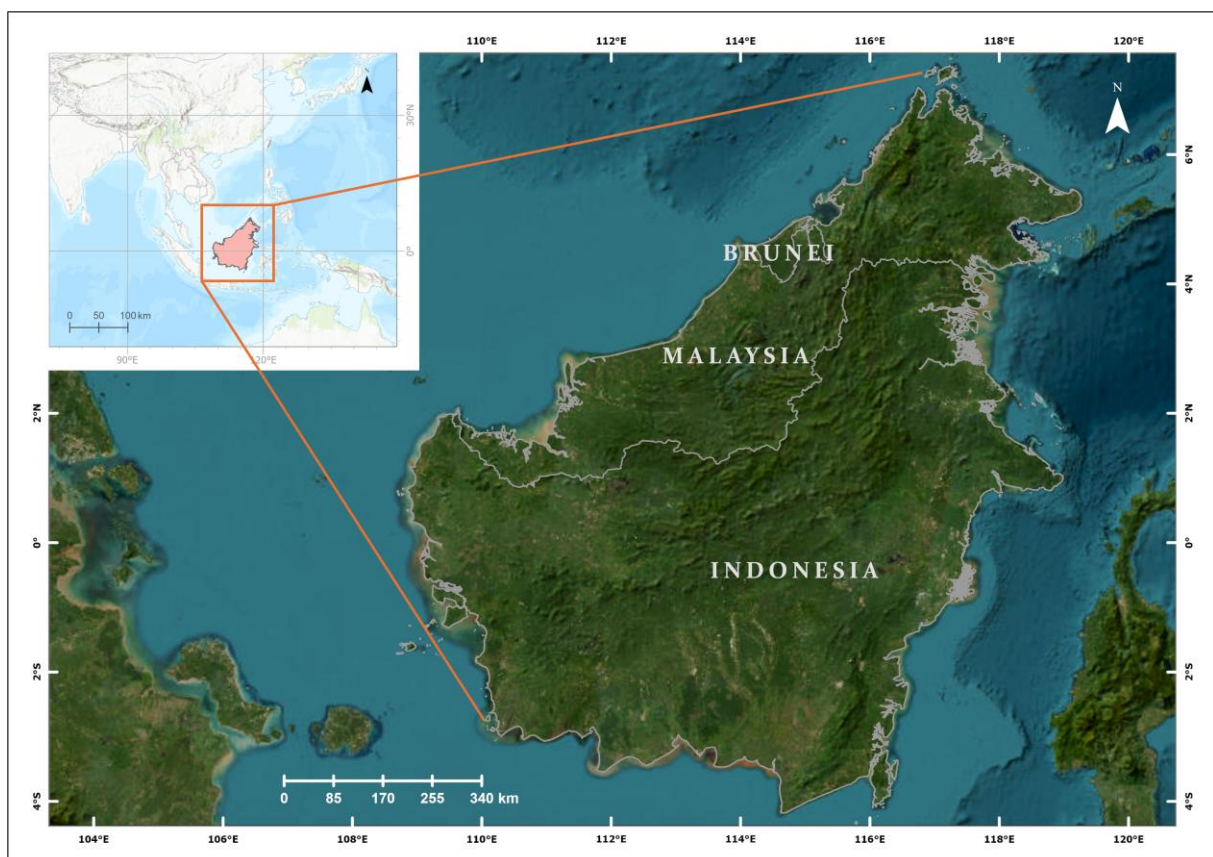
Zmeny charakteristík krajinej pokrývky, akými sú albedo či emisivita, vplývajú aj na regionálny tok tepla, cirkuláciu vzduchu, zrážky, evapotranspiráciu a to zväčša spôsobuje nárast teploty v urbánných prostrediach (skr. z angl. LST). Výraznými faktormi vplývajúcimi na túto dynamiku sú procesy spojené s urbanizáciou a odlesňovaním (Grigoraş a Urişescu 2019). Medzi najviac zasiahnuté oblasti patria pôvodné tropické dažďové pralesy, aké nájdeme aj na ostrove Borneo v juhovýchodnej Ázii. Práve na tomto ostrove bola zaznamenaná najintenzívnejšia ľudská aktivita spojená s kľčovaním lesov pre potreby expanzie plantáží či urbanizácie. Tieto zmeny v krajinej pokrývke začali už v 80. rokoch minulého storočia a do roku 2015 došlo k strate až 50 % pôvodného dažďového lesa (Ocampo-Peñuela et al. 2020).

Problematika spojená s analýzou vývoja zmien krajinej pokrývky vo vzťahu ku zmenám LST s využitím GIS a DPZ metód bola skúmaná viacerými autormi (Thakur et al. 2020, Fries et al. 1998, Grigoraş a Urişescu 2019, Choudhury et al. 2019, Ibitoye et al. 2017). V našom článku sa venujeme tvorbe aplikácie v platforme Google Earth Engine, v ktorej na základe algoritmov strojového učenia klasifikujeme satelitné snímky z misií Landsat do tried predstavujúcich dominantné typy krajinej pokrývky. Výsledkom je aj časopriestorová analýza

zmien krajinej pokrývky a zmien LST v 20-ročnom časovom období a komparácia použitých algoritmov strojového učenia – z angl. Support Vector Machine (skr. SVM) a Random Forest (skr. RF). Samotná aplikácia je modifikovateľná podľa potrieb užívateľa a použiteľná napríklad pre potreby územného plánovania a trvalo udržateľného rozvoja.

### Záujmové územie

Borneo je tretím najväčším ostrovom sveta, ktorý sa nachádza v juhovýchodnej časti Ázie. Zaberá plochu približne 744 000 km<sup>2</sup> a z politického hľadiska sa delí na tri samostatné štáty – Indonéziu, Malajziu a najmenšiu časť zaberá Brunej. Malajská časť ostrova je známa pod názvom Východná Malajzia a indonézska časť sa označuje ako Kalimantan. Grafické znázornenie je uvedené na obrázku 1. Celý ostrov patrí do rovníkového pásma, pre ktoré sú typické tropické dažďové pralesy. Práve tie na Borneu patria k najstarším tropickým lesom sveta a k tzv. hotspotom biodiverzity (Moate 2023). Aj napriek tomuto prechádzajú tieto biotopy čoraz viac drastickými zmenami, ktoré spôsobuje človek svojím negatívnym zásahom (Ocampo-Peñuela et al. 2020). Medzi najvýznamnejšie aktivity, spôsobujúce tieto zmeny patria urbanizácia a deforestácia. Môžeme povedať, že deforestácia na Borneu bola jednou z najintenzívnejších na celom svete. Pre porovnanie v Amazonskom pralesi sa na hektár lesa vyťaží 23 kubíkov dreva, zatiaľ čo na Borneu bolo v tomto období vyťažených až 60 – 240 kubíkov dreva na hektár. K výrubu dochádza aj pre potreby výsadby nových plantáží palmy olejnej a kaučukovníka, ktoré majú vysokú produktivitu, a tým aj ekonomickú hodnotu (Butler 2020).



**Obr. 1.** Poloha ostrova Borneo (Zdroj: GADM 2022 a ©ESRI basemap 2024, spracované autorom)

## Platforma Google Earth Engine

Google Earth Engine je online cloudová platforma slúžiaca predovšetkým na analýzy a vizualizácie geopriestorových dát. Je využívaná širokým spektrom užívateľov, od vedcov cez súkromný sektor až po vládne inštitúcie. Platforma je tvorená multibajtovou databázou, výkonnou výpočtovou technikou a riadi ju aplikačné programovacie rozhranie – skratka z ang. API. Zabudovaná databáza GEE obsahuje obrovské množstvo verejne dostupných geopriestorových dát zo satelitného a leteckého skenovania, ako napríklad archív misií Landsat, topografické, klimatické dáta či environmentálne a socio-ekonomické dáta apod. Do platformy je možné vložiť aj vlastné datasey, ktoré je možné analyzovať pomocou 800 rôznych funkcií a algoritmov. Google Earth Engine je čoraz častejšie využívanou platformou vo viacerých vedných disciplínach, a aj preto sa označuje za efektívny nástroj pre rýchle a relatívne jednoduché mapovanie rozvoja miest, mapovanie a identifikáciu rizikových lokalít náchylných na záplavy, analýz časopriestorových zmien, a pod. (Gorelick et al. 2017).

## Vzťah krajinnej pokrývky a povrchovej teploty - LST

Diaľkový prieskum Zeme je kľúčovým nástrojom pre pochopenie priestorových a časových zmien rôznych fyzikálnych vlastností v súvislosti s využívaním pôdy (Miss et al. 2020). Neplánovaná urbanizácia a zmeny vo využívaní pôd vedú k transformáciám prirodzenej krajinnej pokrývky na nepriepustné umelé plochy, ktoré zapríčiňujú nárast povrchovej teploty (Das a Angadi, 2020). Zastavané oblasti sú zväčša teplejšie ako okolitá prírodná krajina, a tým dochádza k lokálnym zmenám LST. To má negatívny vplyv na spoločnosť aj životné prostredie, pretože sa zhoršuje kvalita ovzdušia, zvyšuje spotreba energie, ohrozuje zdravie ľudí a dochádza k strate biodiverzity. Pokroky v oblasti DPZ, a najmä termálneho DPZ, geografických informačných systémov (GIS) a štatistických metód umožňujú výskumníkom lepšie chápať tieto dynamické zmeny, a tým aj navrhovať stratégie pre mitigáciu týchto nepriaznivých vplyvov teploty zemského povrchu (Tran et al. 2017). Existuje mnoho prístupov pre analýzy týchto zmien a medzi najbežnejšie patrí odvádzanie LST pomocou spektrálnych indexov.

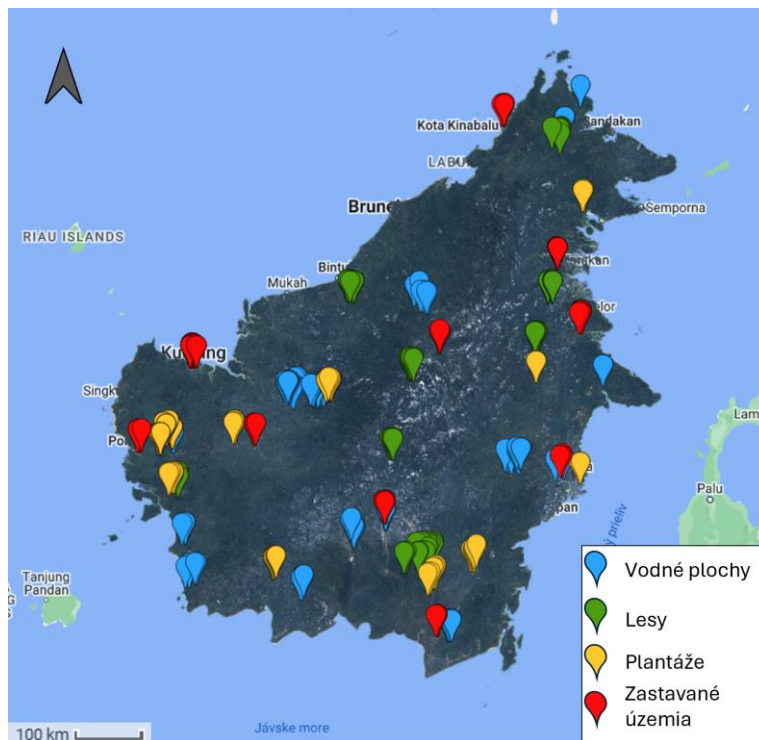
Normalizovaný diferenčný vegetačný index – skr. NDVI, je jedným zo základných spektrálnych indexov diaľkového prieskumu, ktorý sa pre analýzu LST využíva už od 70. rokov. Ide o veličinu, ktorá umožňuje merania úrovne zelenosti a zdravotného stavu vegetácie, pričom využíva kombináciu infračerveného a červeného spektrálneho pásma (Badapalli et al. 2022). Výsledkom rovnice sú hodnoty v rozmedzí od -1 do +1. Negatívne hodnoty predstavujú vodné plochy. Skaly, sneh alebo zastavané plochy nadobúdajú hodnoty blízke hodnote 0. Rastúca hodnota NDVI znamená, že rastie aj hustota vegetačného pokryvu, teda hodnoty od 0,1 – 0,3 predstavujú trávnaté a krovinaté plochy a tropické dažďové pralesy dosahujú hodnoty blízke +1 (Akbar et al. 2019).

## Metódy a dáta

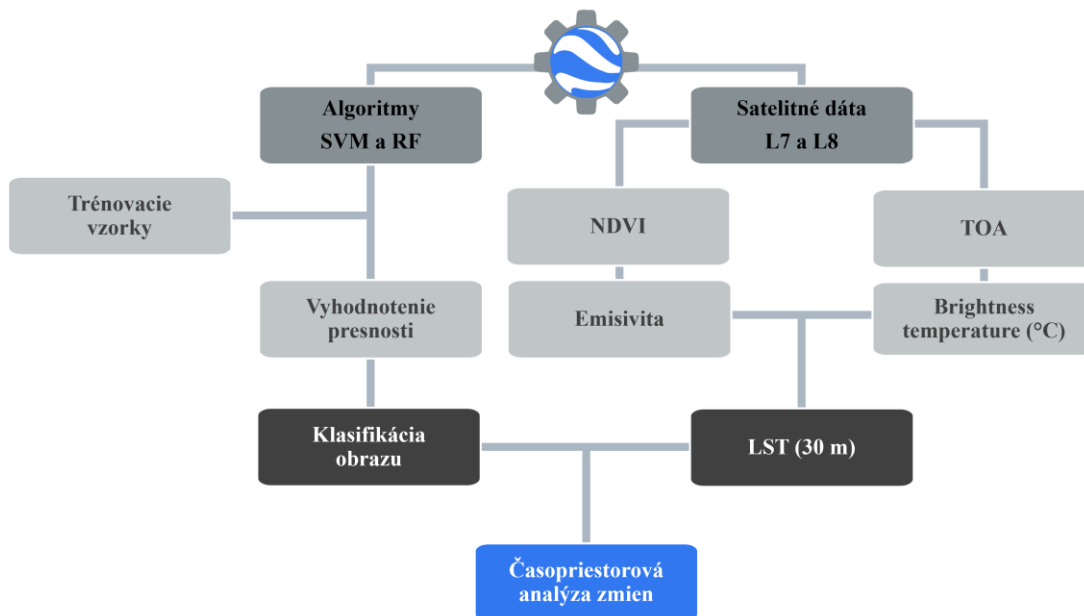
Navrhovaná aplikácia bola implementovaná v prostredí GEE. Celé územie ostrova Borneo bolo zvolené pre demonštráciu efektívneho využitia tejto platformy na analýzu veľkoobjemových satelitných scén aj pre samotnú klasifikáciu obrazu. Prvým krokom bola príprava vstupných dát z dvoch misií Landsat 5 (skr. L5) a Landsat 8 (skr. L8), z ktorých sme vytvorili farebnú kompozíciu v pravých farbách prostredníctvom algoritmu „*ee.Algorithms.Landsat.simpleComposite*“, ktorý je zabudovaný priamo v platforme. Tento algoritmus využíva surové dáta z misií Landsat, na ktoré aplikuje štandardné kalibrácie TOA (z angl. Top Of Atmosphere) pre minimalizáciu atmosférických chýb a taktiež ma v sebe implementovaný algoritmus pre filtrovanie najmenej oblačných scén v záujmovom území (GEE 2024). V tomto prípade sme využívali defaultné nastavenie oblačnosti na hodnotu 10 %.

V druhom kroku sme aplikovali 2 modely pre semi-automatickú klasifikáciu vstupného obrazu, pričom sme testovali 2 rôzne algoritmy strojového učenia – SVM a RF. Keďže ide o semi-automatickú metódu, bolo potrebné vytvoriť dataset tréningových plôch, tzv. vzoriek, ktoré sme využívali pre natréningovanie modelov. Celkovo boli na testovanie vytvorené 4 triedy, predstavujúce dominantné typy krajinej pokrývky – vodné plochy, lesy, plantáže a zastavané územia. Každá trieda obsahovala 100 tréningových vzoriek a ich rozmiestnenie je znázornené na obrázku 2. Testovanie prebiehalo pre celé územie ostrova, pričom sme vyhodnocovali presnosť modelov pomocou chybových matic a údajov o celkovej presnosti, ktoré sme generovali priamo v GEE.

V treťom kroku sme vybrali algoritmus s vyššou presnosťou a použili ho pre klasifikáciu vybranej lokality na základe bezoblačných satelitných scén, ktoré sú predpokladom pre dosiahnutie najvyššej správnosti klasifikácie obrazu. Pre ňu sme odvádzali aj LST, kde sme si vypočítali normalizovaný diferenčný vegetačný index NDVI využitím kombinácie dvoch spektrálnych pásiem, a to blízkeho infračerveného a červeného. Následne sme odvádzali parametre (emisivitu) pre výpočet povrchovej teploty. Na záver sme štatisticky analyzovali časopriestorové zmeny v krajinej pokrývke aj v hodnotách LST pre dve časové obdobia – roky 2001 a 2021. Postup práce je graficky znázornený na vývojovom diagrame na obrázku 3.



**Obr. 2.** Rozmiestnenie tréningových vzoriek, predstavujúcich dominantné triedy krajinej pokrývky na ostrove Borneo (Zdroj: GEE 2024, spracované autorom)




**Obr. 3.** Schéma metodiky použitej v tejto práci (spracované autorom)

## Výsledky a diskusia

### 1. Vyhodnotenie správnosti klasifikácie pomocou algoritmov strojového učenia SVM a RF

Naším prvým cieľom bola tvorba aplikácie v platforme GEE pre semi-automatickú klasifikáciu družicových dát, na ktorej sme v prvom kroku skúmali efektivitu platformy pre spracovanie týchto veľkoobjemových družicových dát. Územie ostrova Borneo sme klasifikovali pomocou dvoch algoritmov strojového učenia – SVM a RF, pričom sme sa snažili presnosť oboch modelov čo najviac maximalizovať. Výsledky klasifikácie sú znázornené na obrázku 4. Z vizuálneho hľadiska vidíme rozdiely medzi SVM a RF algoritmami, a to hlavne pri triede zastavaných plôch (červená farba).



**Obr. 4.** Klasifikácia krajiny pokrývky na ostrove Borneo použitím algoritmov SVM a RF (Zdroj: GEE 2024, spracované autorom)

Okrem vizuálnej komparácie sme vygenerovali v prostredí GEE aj metriky pre hodnotenie správnosti klasifikácií, a to pomocou chybových matíc, z ktorých sme odvodili celkovú presnosť klasifikácií, ktoré sú zaznamenané v tabuľke 1. Tieto hodnoty poukazujú na to, že SVM model pracoval pre dané územie s menšou spoľahlivosťou pre klasifikáciu krajinej pokrývky – jeho presnosť bola len okolo 68 %. Naopak, využitím klasifikátora RF bola výsledná presnosť klasifikácie vyššia, 88 %. Dosiachnutie takýchto hodnôt výslednej správnosti klasifikácie môžeme interpretovať aj výskytom malej oblačnosti na vstupných scénach, ktorej prítomnosť na tak rozsiahlom území a v takom podnebí, v akom leží ostrov Borneo, ťažko odstrániť či maskovať. Ďalším faktorom vplývajúcim na presnosť sú aj rozličné rádiometrické vlastnosti snímok, ktoré boli do jednej kompozície zmozaikované za dlhšie časové obdobie (v oboch prípadoch 2-ročné). Práve z tohto dôvodu sme v ďalšej časti našej práce pristúpili ku klasifikácii už len pre menšie územie v rámci ostrova Borneo a už len pomocou algoritmu RF, ktorý vykázal lepšie výsledky klasifikácie v porovnaní s algoritmom SVM a jeho správnosť klasifikácie bola pomerne vysoká.


**Tab. 1.** Metriky presnosti klasifikácií pomocou modelov SVM a RF

	SVM	RF
Celková presnosť	68,6 %	88,4 %

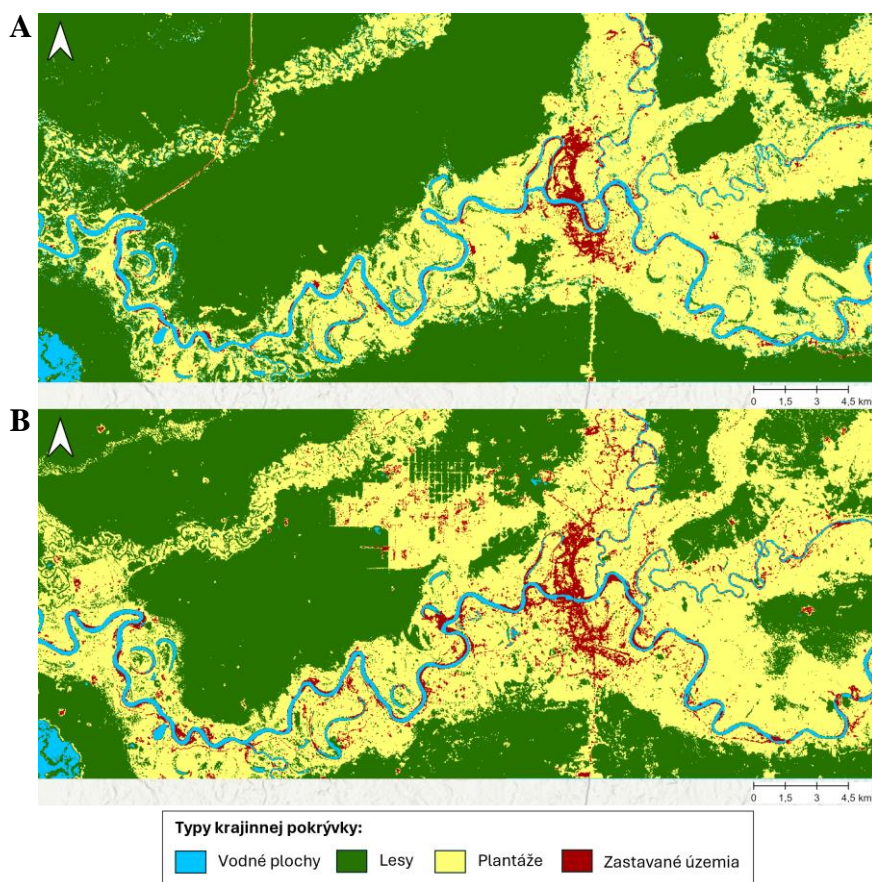
Zdroj: GEE, 2024; spracované autorom

## 2. Časopriestorová analýza zmien krajinej pokrývky a LST v rokoch 2001 a 2021

Lokalitu sme vybrali na základe dostupných bezoblačných snímok, ktoré sme filtrovali podľa časového obdobia a podľa vizuálnych zmien v krajinej pokrývke. Ako reprezentatívne územie sme vybrali oblasť mesta Putussibau v regióne Kapuas Hulu, pre ktoré sme našli vhodné snímky. Satelitné snímky použité pre klasifikáciu sú uvedené na obrázku 5. Model RF sme vytrénovali pomocou 167 tréningových vzoriek – 46 pre vodné plochy, 40 pre zastavené územia a plantáže a 41 bodov pre lesy. V tomto prípade sme porovnávali výslednú presnosť klasifikácie medzi rokmi 2001 a 2021, ktorá je graficky znázornená na obrázku 6. Aj tu sme vyhodnotili výslednú presnosť algoritmu RF. Pre rok 2021 bola dosiahnutá presnosť 91 % a pre rok 2001 až 97 %. Okrem toho sme vyhodnocovali aj časopriestorovú analýzu zmien krajinej pokrývky vzhľadom na zmenu LST.



**Obr. 5.** Satelitné snímky z roku 2001 a 2021 pre lokalitu Putussibau použité pre klasifikáciu obrazu (spracované autorom)



**Obr. 6.** Klasifikácia lokality modelom RF pre rok 2001 (A) a pre rok 2021 (B) (spracované autorom)

Štatistickou metódou sme vypočítali plochy jednotlivých kategórií krajinej pokrývky pre oba roky a ich hodnoty zapísali do tabuľky 2. Zistili sme, že v roku 2001 bolo na záujmovom území približne 1 233 km<sup>2</sup> lesov, plantáže zaberali plochu 245 km<sup>2</sup> a zastavené územia necelých 30 km<sup>2</sup>. Tieto hodnoty sa za 20 rokov výrazne zmenili, pričom došlo k expanzii plantáží a zastavaných území o približne 67 km<sup>2</sup>, a to na úkor dažďových pralesov, pri ktorých došlo k strate necelých 300 km<sup>2</sup>. Rozlohu vodných plôch v tomto prípade neuvádzame, nakoľko ide o oblasť dažďových pralesov, kde sa výška a plocha vodnej hladiny mení výrazne v priebehu roka. Pri tejto štatistike je ale potrebné uviesť, že ide o údaje vypočítané pomocou modelu s 30 m priestorovým rozlíšením a nie sú postavené na empirických dátach, teda je tu vyššia pravdepodobnosť chýb.

**Tab. 2.** Plošná výmera vybraných kategórií krajinej pokrývky v rokoch 2001 a 2021

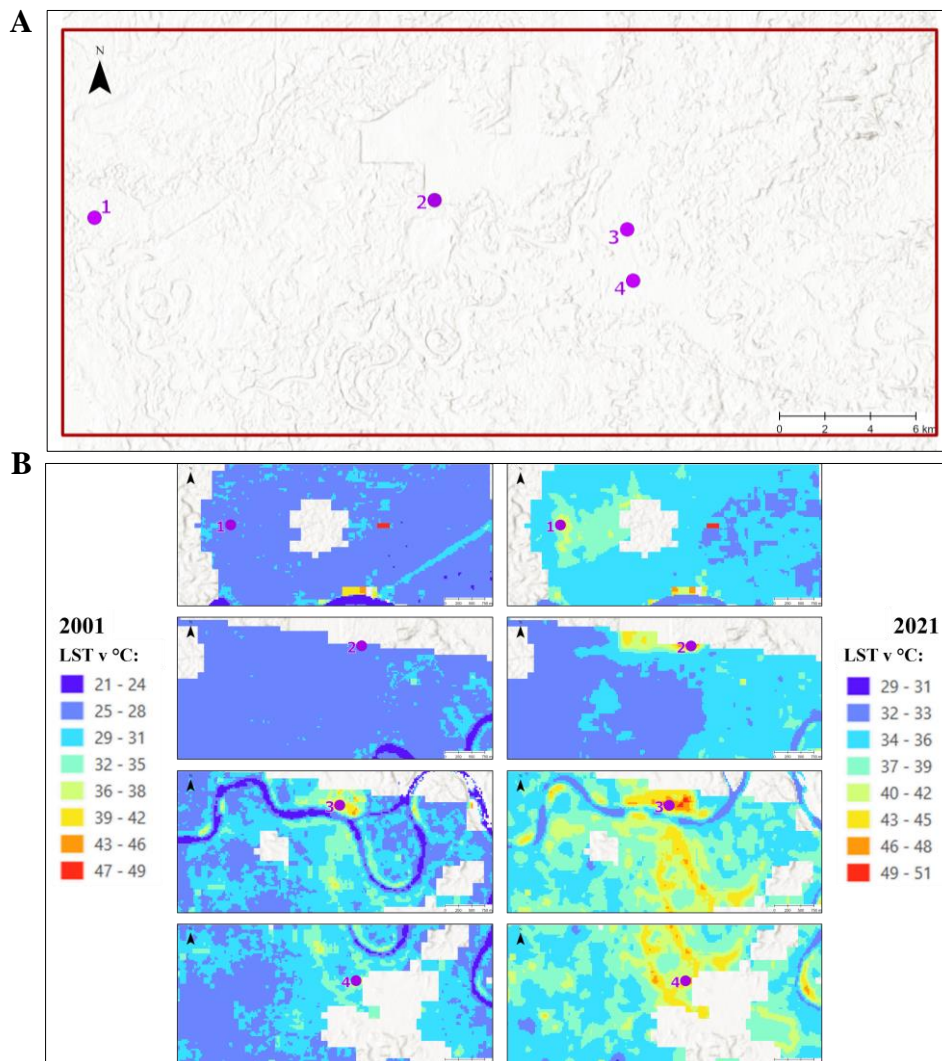
Kategória	2001 (km <sup>2</sup> )	2021 (km <sup>2</sup> )	Rozdiel (km <sup>2</sup> )
Lesy	1233,60	953,57	- 280,03
Plantáže	244,59	311,68	+ 67,09
Zastavané územie	26,63	93,14	+ 66,51

Zdroj: GEE, 2024; spracované autorom

Naším posledným cieľom bolo analyzovať zmenu LST z hľadiska zmeny krajinej pokrývky. V tomto prípade raster odvodený LST obsahuje určité dátové medzery, ktoré sú výsledkom odfiltrovaných oblastí s výskytom oblačnosti, ktoré by mohli skresľovať výsledky analýzy a výslednej LST. Mapy pre roky 2001 a 2021 sú zobrazené na obrázku 7. Môžeme tu vidieť rozdiely v minimálnej a maximálnej LST. Zatiaľ čo v roku 2001 boli minimálne hodnoty LST okolo 21 °C, do roku 2021 vzrástli o 8 °C. Maximálna hodnota taktiež zaznamenala nárast zo 49 °C v roku 2001 na necelých 52 °C v roku 2021. Príčinou je práve zmena krajinej pokrývky, hlavne v oblastiach, kde expandovalo zastavané územie a plantáže na úkor pôvodného tropického lesa.

Aj napriek takýmto chybám sme sa snažili aspoň na odvodených časti územia porovnať vývoj LST. V softvéri ArcGis Pro 3.0.0 sme identifikovali 4 oblasti s výraznou zmenou a označili ich ako lokality 1 – 4. Následne sme každej lokalite priradili prislúchajúcu hodnotu pixela, predstavujúcu hodnotu LST a zapísali ju do tabuľky 3. Vidíme, že teplota povrchu vzrástla pre každú identifikovanú lokalitu. Najväčší nárast LST sme zaznamenali pre lokality 1 a 2, a to o 20 °C pre lokalitu 1 a o 16 °C v lokalite 2. Ak oblasti porovnáme s našou semi-automatickou klasifikáciou obe tieto zmeny v lokalitách korelujú s novou výstavbou. V lokalite 1 máme pre rok 2021 oblasť klasifikovanú ako zastavané územie, ale v roku 2001 boli v tejto oblasti poľnohospodárske oblasti a zalesnené územia. Podobne je to aj v lokalite 2, kde sa pôvodne nachádzali rozsiahle tropické lesy, ale tie boli do roku 2021 pretvorené na územia plantáží. Pre lokalitu 2 je z tejto oblasti možné identifikovať len najjužnejšiu časť týchto plantáží, avšak LST výrazne vzrástla aj tu. Lokality 3 a 4 predstavujú zastavané územie mesta, kde LST stúpila o 5 °C a 13 °C. Tu môžeme vyvodiť záver, že práve v urbánných oblastiach boli vyššie LST už aj pred 20 rokmi a nárast bol menej náhly, ako v predošlých lokalitách, kde došlo k zmene prirodzenej krajinej pokrývky najmä na umelú.





**Obr. 7.** Lokalizácia lokalít, kde došlo k výrazným zmenám povrchovej teploty (A) a odvodená LST pre roky 2001 a 2021 (B) (Zdroj: GEE a ArcGis Pro 2024, spracované autorom)

**Tab. 3.** Teplota povrchu pre vybrané oblasti

Bod	LST pixela pre 2001 (°C)	LST pixela pre 2021 (°C)
1	26,7	42,7
2	28,1	48,4
3	42,9	48,6
4	32,9	46,6

Zdroj: ArcGis Pro, 2024; spracované autorom

## Záver

V tejto práci sme sa zamerali na časopriestorovú analýzu zmien krajinnej pokrývky a LST prostredníctvom vytvorenej aplikácie v platforme GEE. Aplikácia je funkčná, modifikovateľná a široko aplikovateľná. Naším záujmovým územím bol tretí najväčší ostrov sveta - Borneo, na ktorom sme aplikovali semi-automatickú klasifikáciu družicových dát pomocou algoritmov strojového učenia Support Vector Machine a Random Forest. Po spresňovaní oboch modelov prostredníctvom 100 trénovacích vzoriek pre každú kategóriu krajinnej pokrývky bolo zistené, že klasifikátor RF pracuje s vyššou mierou spoľahlivosti, a to 88 %, v porovnaní so 68 % správnosťou s využitím klasifikátora SVM. Následne bol preto už len klasifikátor RF využitý pri klasifikácii menšieho územia, pre ktoré sme analyzovali vývoj krajinnej pokrývky a LST pre roky 2001 a 2021 s vyššou presnosťou. Pre rok 2021 to bola správnosť klasifikácie na 92 % a pre rok 2001 až 97 %. Tieto vysoké presnosti klasifikácie pripisujeme faktu, že klasifikácia prebiehala na relatívne malom území, kde nedochádzalo k chybám spôsobenými vysokou oblačnosťou či rádiometrickými skresleniami. Tým sme aj dokázali, že na Borneu dochádza k vysokým stratám prirodzených lesov, za sledované obdobie až o cca 30 000 ha, v dôsledku expanzie ľudskej aktivity. Porovnanie LST hodnôt sledovaných rokov a lokalít poukázalo na to, že najvyššie zmeny v hodnotách LST súvisia práve s premenou prirodzenej krajiny na umelú. Ďalšie smerovanie tohto výskumu má za cieľ modelovať LST ucelene, s minimalizáciou vplyvu oblačnosti na vyhodnocovanie LST. Na základe našich analýz a výsledkov môžeme tiež vyvodit' záver, že GEE je efektívny nástroj pre spracovanie, vizualizovanie a časopriestorové analyzovanie veľkoobjemových dát, akými sú aj družicové dáta, v globálnej, až regionálnej mierke.

## Pod'akovanie

Touto cestou by som sa chcel poďakovať mojej školiteľke, Mgr. Kataríne Onačillovej, PhD., za odborné rady, usmerňovanie a za pomoc pri písaní tohto príspevku.

## Literatúra

- Bappa, S. A., Malaker, T., Mia, M. R., Islam, M. D. 2022. Spatio-temporal variation of land use and land cover changes and their impact on land surface temperature: A case of Kutupalong Refugee Camp, Bangladesh. *Heliyon*, 8(9), e10449. <https://doi.org/10.1016/j.heliyon.2022.e10449>
- Butler, R. A., 2020: Borneo. Mongabay. <https://rainforests.mongabay.com/borneo/>
- Choudhury, D., Das, K., Das, A. 2019. Assessment of land use land cover changes and its impact on variations of land surface temperature in Asansol-Durgapur Development Region. *The Egyptian Journal of Remote Sensing and Space Sciences*, 22(2), 203–218. <https://doi.org/10.1016/j.ejrs.2018.05.004>
- Fries, R., Hansen, M. C., Townshend, J. R. G., Sohlberg, R. 1998. Global land cover classifications at 8 km spatial resolution: The use of training data derived from Landsat imagery in decision tree classifiers. *International Journal of Remote Sensing (Print)*, 19(16), 3141–3168. <https://doi.org/10.1080/014311698214235>
- GEE. 2024, Reference - ee.Algorithms.Landsat.simpleComposite. <https://developers.google.com/earth-engine/apidocs/ee-algorithms-landsat-simplecomposite>
- Grigoraş, G., Urişescu, B. 2019. Land Use/Land Cover changes dynamics and their effects on Surface Urban Heat Island in Bucharest, Romania. *International Journal of Applied Earth Observation and Geoinformation*, 80, 115–126. <https://doi.org/10.1016/j.jag.2019.03.009>
- Ibitoye, M. O., Aderibigbe, O., Adegboyega, S. A., Adebola, A. O. 2017. Spatio-temporal analysis of land surface temperature variations in the rapidly developing Akure and its environs,

- southwestern Nigeria using Landsat data. *Ethiopian Journal of Environmental Studies and Management*, 10(3), 389. <https://doi.org/10.4314/ejesm.v10i3.9>
- Moate, M. 2023: What Causes Deforestation in Borneo and How Do We Stop It? Earth.Org. [https://earth.org/deforestation-in-borneo/?fbclid=IwAR0HyA1kQp1wraZE\\_sNe\\_F7Y5ckIHB92D3VymD-V5SKRwnWcis-FDUDLk5gM](https://earth.org/deforestation-in-borneo/?fbclid=IwAR0HyA1kQp1wraZE_sNe_F7Y5ckIHB92D3VymD-V5SKRwnWcis-FDUDLk5gM)
- Ocampo-Peñuela, N., Garcia-Ulloa, J., Kornecki, I., Philipson, C. D., Ghazoul, J. 2020. Impacts of four decades of forest loss on vertebrate functional habitat on Borneo. *Frontiers in Forests and Global Change*, 3. <https://doi.org/10.3389/ffgc.2020.00053>
- Rao, P., Tassinari, P., Torreggiani, D. 2023. Exploring the land-use urban heat island nexus under climate change conditions using machine learning approach: A spatio-temporal analysis of remotely sensed data. *Heliyon*, 9(8), e18423. <https://doi.org/10.1016/j.heliyon.2023.e18423>
- Thakur, S., Maity, D., Mondal, I., Basumatary, G., Ghosh, P., Das, P., De, T. K. 2020. Assessment of changes in land use, land cover, and land surface temperature in the mangrove forest of Sundarbans, northeast coast of India. *Environment, Development and Sustainability*, 23(2), 1917–1943. <https://doi.org/10.1007/s10668-020-00656-7>