

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

FAKULTA ŽIVOTNÍHO PROSTŘEDÍ

KATEDRA PROSTOROVÝCH VĚD



**KLASIFIKACE SNĚHOVÉ POKRÝVKY OSTROVA
JAMESE ROSSE Z DAT SENTINEL-2**

BAKALÁŘSKÁ PRÁCE

Vedoucí práce: Ing. David Moravec, Ph.D.

Bakalant: Dominika Gulková

2022

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Dominika Gulková

Geografické informační systémy a dálkový průzkum Země v životním prostředí

Název práce

Klasifikace sněhové pokrývky ostrova Jamese Rosse z dat Sentinel-2

Název anglicky

Snow cover classification of James Ross Island from Sentinel-2

Cíle práce

Cílem práce je pomocí satelitní dat analyzovat dynamiku sněhové pokrývky v čase na ostrově James Ross. Budou porovnány trendy s terénním měřením rychlosti a směru větru. Dále bude provedena analýza trendů s ohledem na svažitost a orientaci svahu.

Metodika

V první části práce bude provedena literární rešerše se zaměřením na sníh jako základní faktor ovlivňující mnohé procesy v krajině.

Následně proběhne analýza sněhové pokrývky na ostrově Jamese Rosse. K tomu budou využity satelitní snímky Sentinel 2 z let 2016–2021. Na těchto snímcích bude vhodnou metodou klasifikována sněhová pokrývka. Následná analýza vlivu terénu na sněhovou pokrývku proběhne pomocí digitálního modelu terénu Reference Elevation Model of Antarctica (REMA).

Doporučený rozsah práce

30 stran

Klíčová slova

Sněhová pokrývka, Sentinel-2, Antarktida, Klima

Doporučené zdroje informací

Barnett, Tim P., Jennifer C. Adam, and Dennis P. Lettenmaier. "Potential impacts of a warming climate on water availability in snow-dominated regions." *Nature* 438.7066 (2005): 303-309.

Hrbáček, Filip, Kamil Láska, and Zbyněk Engel. "Effect of snow cover on the active-layer thermal regime—a case study from James Ross Island, Antarctic Peninsula." *Permafrost and Periglacial Processes* 27.3 (2016): 307-315

Shimamura, Y., T. Izumi, and H. Matsuyama. "Evaluation of a useful method to identify snow-covered areas under vegetation—comparisons among a newly proposed snow index, normalized difference snow index, and visible reflectance." *International journal of remote sensing* 27.21 (2006): 4867-4884.

Předběžný termín obhajoby

2021/22 LS – FZP

Vedoucí práce

Ing. David Moravec, Ph.D.

Garantující pracoviště

Katedra prostorových věd

Elektronicky schváleno dne 23. 3. 2022

doc. Ing. Petra Šimová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 23. 3. 2022

prof. RNDr. Vladimír Bejček, CSc.

Děkan

V Praze dne 30. 03. 2022

Čestné prohlášení

Prohlašuji, že jsem bakalářskou práci na téma: *Klasifikace sněhové pokrývky ostrova Jamese Rosse z dat Sentinel-2* vypracovala samostatně a citovala jsem všechny informační zdroje, které jsem v práci použila a které jsem rovněž uvedla na konci práce v seznamu použitých informačních zdrojů.

Jsem si vědoma, že na moji bakalářskou se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů, ve znění pozdějších předpisů, především ustanovení § 35 odst. 3 tohoto zákona, tj. o užití tohoto díla.

Jsem si vědoma, že odevzdáním bakalářské práce souhlasím s jejím zveřejněním podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů, ve znění pozdějších předpisů, a to i bez ohledu na výsledek její obhajoby.

Svým podpisem rovněž prohlašuji, že elektronická verze práce je totožná s verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

V Praze dne: 30. 3. 2022

.....

Dominika Gulková

Poděkování

Ráda bych poděkovala Ing. Davidovi Moravcovi Ph.D. za odborné vedení a cenné rady při psaní této práce. Také děkuji doc. Mgr. Janu Kropáčkovi, Ph.D. za věcné připomínky a vstřícnost při konzultacích a vypracování bakalářské práce.

Abstrakt

Vhodné mapování sněhové pokrývky a automatizace jeho klasifikace je stěžejní pro mnoho vědních oborů.

Bakalářské práce vhodnou metodou vytváří mapy sněhové pokrývky pro optické multispektrální snímky Sentinel-2 a pomocí analýzy terénu pozoruje vliv orientace svahu, sklonitosti svahu a větru na pohybu sněhu v krajině.

V teoretické části je dále popsán základ pro klasifikaci sněhu z optických dat a současné metody mapování sněhové pokrývky pomocí optických senzorů.

V diskuzi jsou rozebrány výsledky, jež podporují vhodnost vybrané metody a je zmíněno možné zlepšení v podobě přesnějších dat.

Klíčová slova:

Antarktida, ostrov Jamese Rosse, Sentinel-2, sněhová pokrývka, klasifikace, klima, klimatická změna, Javascript, Google Earth Engine

Abstract

Appropriate snow cover mapping and automation of its classification is crucial for many scientific disciplines.

The bachelor thesis creates a suitable method for estimating snow cover maps from multispectral optical data acquired from Sentinel-2 and usse terrain analysis to observe the effect of aspect, slope, and wind direction on snow accumulation in nature.

The theoretical part further sets the baseline for snow classification from optical data and current methods of snow cover mapping using optical sensors.

The discussion shows the results that support the suitability of the selected method and mentions possible improvements in the form of more accurate data.

Keywords:

Antarctica, James Ross island, Sentinel-2, snow cover, classification, climate, climate change, Javascript, Google Earth Engine

Obsah

1. Úvod.....	8
2. Cíle práce	9
3. Literární rešerše	10
3.1 Spektrální vlastnosti sněhu.....	10
3.2 Pohyb sněhu v krajině	11
3.3 Metody klasifikace sněhu.....	12
3.3.1 NDSI.....	12
3.3.2 Saito S3 Snow Index.....	13
3.3.3. Combined Snow Index.....	13
3.4 Mapování sněhu.....	14
3.5 Charakteristika zájmového území	16
3.6 Digitální výškový model terénu REMA	18
3.7 ERA5 dataset	19
3.8 Google Earth Engine	19
4. Metodika.....	21
5. Výsledky	25
6. Diskuse.....	30
7. Závěr	31
8. Přehled literatury a použitých zdrojů	32
8.1 Internetové zdroje.....	35
8.2 Zdroje obrázků a tabulek	36
9. Seznam příloh.....	38

1. Úvod

Sníh je jedním z klíčových faktorů, jež ovlivňují, klimatologické, hydrologické či ekologické procesy.

Sněhová pokrývka ovlivňuje energetickou bilanci celé Země. Díky vysokému albedu sněhu se až 90 % krátkovlnného slunečního záření dopadajícího na sněhovou pokrývku odrazí zpět do atmosféry a tím ochlazuje naši planetu. Když pak sníh roztaje, dostává se do dalších důležitých procesů.

Téměř šestina celého obyvatelstva se nachází v povodích řek, které jsou převážně napájeny postupným táním ledovců a cyklickým táním sněhové pokrývky. Jedná se o oblasti nad 45 stupňů severní a jižní šířky (s výjimkou velmi suchých oblastí, například severovýchodní Čína, či oblastí omývaných teplými mořskými proudy jako například provincie Britská Kolumbie v Kanadě nebo Portugalsko a Španělsko). Vysoko položené oblasti, s výjimkou těch velmi blízko rovníku, jsou také závislé na tání sněhu (Pimentel et al., 2017) .

Mapování sněhové pokrývky se v souvislosti s klimatickou změnou věnuje stále více pozornosti. Klimatická změna a s ní vyšší průměrná teplota vzduchu má v horských oblastech za následek posun období tání, respektive období největšího průtoku řek, z pozdního léta do konce zimy, až průběhu jara, což způsobuje nedostatek až úplnou absenci vláh v letních měsících (Carlson et al., 2020).

V neposlední řadě je sníh důležitý z ekologického hlediska. Kvůli nízké tepelné vodivosti sněhu se vrstva sněhové pokrývky chová jako izolant a brání vegetaci a mikroorganismy pod ní před velkými ztrátami tepla a vlhkosti (Pomeroy & Brun, 2011).

Terénní měření sněhové pokrývky již není dostačující, využívá se proto převážně dálkový průzkum Země. S rostoucím radiometrickým rozlišením senzorů se kvalita produktů sněhové pokrývky rapidně zvyšuje, prostorové rozlišení ovšem pořád zhoršuje výsledky těchto globálních datasetů a pro lokální analýzy jsou tyto produkty téměř nepoužitelné.

V této práci se pomocí svého postupu pokusím určit sněhovou pokrývku na menším území a poté provést potřebné analýzy.

2. Cíle práce

Cílem práce je pomocí optických multispektrálních dat analyzovat vliv větru na akumulaci sněhové pokrývky v čase na ostrově Jamese Rosse na Antarktidě. Bude provedena analýza trendů výskytu sněhové pokrývky s ohledem na svažitost a orientaci svahu.

V první části práce bude provedena literární rešerše se zaměřením na sníh jako základní faktor ovlivňující mnohé nezbytné procesy v krajině.

Následně proběhne analýza sněhové pokrývky na ostrově Jamese Rosse. K tomu budou využity satelitní snímky Sentinel 2 z let 2016–2021. Na těchto snímcích bude vhodnou metodou klasifikována sněhová pokrývka. Následná analýza vlivu terénu na sněhovou pokrývku proběhne pomocí digitálního modelu terénu Reference Elevation Model of Antarctica (REMA). K porovnání s větrnými daty bude použit dataset ERA5 od společnosti ECMWF.

3. Literární rešerše

3.1 Spektrální vlastnosti sněhu


Optické vlastnosti materiálu ovlivňují způsob, jakým optické záření reaguje při dopadu na jeho povrch. Každý materiál má svoji specifickou spektrální charakteristiku díky stupni odrazu, absorpce a prostupu při různých vlnových délkách přijímaného záření (ESA, ©2014).

Interakce elektromagnetického záření s ledem a médii obsahujícími led (např. sníh či mraky) jsou určeny indexem lomu a absorpčním koeficientem čistého ledu jako funkce vlnové délky (Warren, 2019).

Ve viditelné části spektra (cca 0,4-0,75 μm) led a sníh obecně vykazují velmi vysokou odrazivost. Hodnota albeda čerstvého sněhu činí až 0,9 (90 %), horní vrstvy oblačnosti tvořené ledovými krystalky mají v této části hladinu odrazivosti podobnou. Nižší odrazivost vykazují v blízké infračervené části spektra (vlnová délka cca 0,78-0,9 μm) a velmi nízkou odrazivost v krátkovlnné infračervené části spektra (vlnová délka cca 1,57-1,78 μm). Nízká odrazivost ledu a sněhu v krátkovlnné infračervené části spektra souvisí s jejich mikroskopickým obsahem kapalné vody. Charakteristický odraz se však mění se skutečným složením materiálu (ESA, ©2014).

Spektrální odrazivost a rozptylové charakteristiky sněhu závisí na mnoha různých faktorech jako je velikost a tvar zrna sněhu, obsah kapalné vody, nečistota sněhu, teplota, obsah ledu a konzistenci povrchu pod sněhovou pokrývkou (Sturm et. al, 1995, Hall Dorothy K.and Riggs, 2011, Tait 1998, Dozier et al., 2009, Kelly et al. 2003, Foster et al. 2005).

Závislost spektrální odrazivost sněhu na jeho typu je například vidět na obrázku 1. (Majumdar, 2019)



Obrázek 1: Spektrální křivka odrazivosti různých typů sněhu (Majumdar, 2019)

V závislosti na zvoleném typu senzoru a rozlišení se může interference všech těchto faktorů na získávání parametrů sněhu lišit (Dietz et al., 2012).

Jak již bylo naznačeno, v blízkém infračerveném pásmu sníh většinu záření absorbuje, na rozdíl od mraků. Kombinací pásem viditelného spektra a středního infračerveného spektra se tedy dá sněhová pokrývka mapovat velice efektivně. Jednou z metod klasifikace sněhu je diferenční sněhový index NDSI (HALOUNOVÁ & PAVELKA, 2005).

3.2 Pohyb sněhu v krajině

Časový vývoj sezónní sněhové pokrývky a její prostorová variabilita v prostředí, jako jsou hory či polární oblasti, je silně ovlivněna interakcemi mezi mezní vrstvou atmosféry (tedy částí atmosféry, v níž se projevuje tření vzduchu o zemský povrch) a sněhovou pokrývkou. Není proto překvapením, že jedním z faktorů, který významně ovlivňuje pohyb sněhu v krajině (a tudíž hraje podstatnou roli v rámci praktické části této práce), je vítr (Mott et al., 2018).

Vítr hraje roli v ukládání sněhu ve všech měřítcích, ať už jde o orografické srážky ve velkém měřítku, ovlivnění místa spadu ve středním měřítku, či přefoukávání sněhových částic v měřítku malém (Mott et al., 2018).

Z jeho textu plyne, že na rozlehlých plochách bez vegetace se sníh na rovině moc nevyskytuje a při vátí přes kopec má tendenci se akumulovat na horní návětrné straně a blízko za ní. Mott dále tvrdí, že při sněhové akumulaci lze pozorovat optické vyhlazení topografických zlomů (Mott & Lehning, 2010).

Typy pohybu sněhu způsobených větrem jsou popsány v tabulce 1.

Charakteristiky typů pohybu sněhu			
Typ	Pohyb	Výška pokrývky	Rychlost větru
Plazení (creep)	válení, kutálení	< 1 cm	< 5 m/s
Saltace (saltation)	skákání	1 cm – 10 cm	5 – 10 m/s
Turbulentní difúze (long-term suspension)	tečení (suspenze sněhu a vzduchu)	1 m – 100 m	> 10 m/s


Tabulka 1: Charakteristiky typů pohybu sněhu

Plazení (creep) popisuje kutálení částic, které jsou příliš těžké na to, aby mohly být unášeny větrem.

Saltace představuje přeskokování/"hopsání" částic po povrchu sněhu

Turbulentní difúze (long-term suspension) znamená pohyb (tok) částic v horizontálním směru rychlostí pohybujícího se vzduchu.

Typy pohybu jsou blíže znázorněny na obrázku 1



Obrázek 2: Typy pohybu sněhu

V pár centimetrech nad povrchem sněhu dochází převážně pouze k saltaci. Saltace vzniká erozí sněhu a je příčinou veškerého pohybu sněhových částic. Tyto erodované částičky mají jiné způsoby akumulace jako čerstvě napadený sníh.

3.3 Metody klasifikace sněhu

3.3.1 NDSI

NDSI (Normalized Difference Snow Index) je mezinárodně užívaný poměrový index, který pomocí jednoduchého normalizovaného rozdílu identifikuje sněhové pixely. Index používá zelenou část spektra ve viditelném pásmu a střední infračervené pásmo. První dokumentace použití pásem viditelného a středního infračerveného pásma pro mapování sněhu byly publikovány v půlce sedmdesátých let (Valovcin, 1976), ale s názvem „NDSI“ přišel až Kyle v roce 1995 (Kyle et al., 1978).

Vzorec pro výpočet NDSI je následující:

$$NDSI = \frac{GREEN - SWIR1}{GREEN + SWIR1}$$

kde *GREEN* je hodnota odrazivosti v zeleném pásmu a *SWIR1* je hodnota odrazivosti ve středním infračerveném pásmu.

Pro pásma družic Sentinel-2 je tedy vzorec:

$$NDSI_{Sentinel-2} = \frac{B_{03} - B_{11}}{B_{03} + B_{11}}$$

Výsledkem je binární rastr, jehož hodnoty se pohybují vždy mezi 0 a 1. Pixely s hodnotou NDSI 0,4 a vyšší jsou pravděpodobně pixely sněhu (Dozier & Painter, 2004).

3.3.2 Saito S3 Snow Index

V roce 1999 byl navrhnut tento index, který k výpočtu používá červenou část spektra viditelného pásma, blízké infračervené pásmo (NIR) a střední infračervené pásmo (SWIR1). Díky kombinaci těchto pásem se dají detekovat pixely, které neobsahují jen sníh, ale zároveň například lesní porost (tzv. „mixels“) Pixely, které obsahují zasněžené vrcholky stromů mohou být tedy identifikovány a odstraněny z výpočtů, protože nereprezentují sněhovou pokrývku. (Shimamura et al., 2006).

Vzorec pro Saito S3 Snow Index:

$$S3 = \frac{NIR * (RED - SWIR1)}{(NIR + RED) * (NIR + SWIR1)}$$

, kde *RED* je hodnota odrazivosti v červeném pásmu, *SWIR1* je hodnota odrazivosti ve středním infračerveném pásmu a *NIR* je hodnota odrazivosti v blízkém infračerveném pásmu.

Pro pásma Sentinel-2 je tedy vzorec:

$$S3_{Sentinel-2} = \frac{B_{08} * (B_{04} - B_{11})}{(B_{08} + B_{04}) * (B_{08} + B_{11})}$$

3.3.3. Combined Snow Index

Kombinovaný index sněhu je produkt vytvořený pomocí open-source softwaru Automated Snow Index Tool (ASIT) od společnosti NASA (Barrow et al., 2017).

Využívá kombinaci rovnic NDSI, a Saito S3 indexu, a tudíž si poradí s problémem výše zmíněných „mixels“.

Pro potřeby této práce byl algoritmus upraven, takže NDSI index byl použit i s prahovacími zlepšeními, jaké jsou použity v produktu Snowmap. Pro zpřesnění, byla ještě vytvořena maska mraků a ta byla odečtena.

3.4 Mapování sněhu

Již od 60. let 20. století se k mapování sněhové pokrývky používají převážně družicová data. Terénní měření sice byla důležitá k pochopení chování sněhu a jeho vlastností, vykazují ovšem mnoho problémů. Sníh je velmi variabilní, jak v prostoru, tak v čase, takže terénní měření jsou často nevyhovující o celkovém stavu pokrývky. Sníh se také vyskytuje nejčastěji v nehostinných oblastech, jakými jsou vysoké hory či polární oblasti, což sběr terénních dat značně ztěžuje.

Program **TIROS** (Television Infrared Observation Satellite) byl prvním experimentálním krokem NASA v otázce využití družic pro zkoumání Země. První prioritou programu TIROS byl vývoj meteorologického satelitního informačního systému, což se později ukázalo jako mimořádně úspěšné a TIROS poskytoval první přesné předpovědi počasí na základě družicových dat (NASA, ©2016).

TIROS-1 byla první družice použita k mapování sněhu. Následovalo mnoho dalších družic s rozmanitými senzory a s nimi přišlo i mnoho různých způsobů mapování sněhu. Úkolem TIROS-6 bylo pokračovat v dosavadním výzkumu a vývoji družicového meteorologického informačního systému a mimo jiné také získat vylepšená data pro použití při předpovědi počasí během sezóny hurikánů. Kromě toho však TIROS-6 provedl první satelitní experimenty k detekci sněhové pokrývky z Vesmíru (NASA, ©2016).

MODIS (Moderate Resolution Imaging Spectroradiometer) je zobrazující spektrometr a jedná se o klíčový instrument na družicích Terra a Aqua od společnosti NASA. Terra byla vypuštěna 18. prosince 1999, Aqua o necelé tři roky později, 4. května 2002. Tyto dvě družice nasnímají celý zemský povrch každé 1-2 dny a získávají data ve 36 spektrálních pásmech v rozsahu vlnové délky od 0,4 μm do 14,4 μm s rozlišením 1000 m, 500 m a 250 m, přičemž pásma potřebná k mapování sněhu mají rozlišení 500 m. Šířka záběru činí 2330 km (NASA, ©2022).

Jedním z algoritmů pro sledování sněhové pokrývky je Snowmap. Snowmap byl vytvořen přímo pro MODIS (Hall & Riggs, 1995). Využívá indexu NDSI, kterému byla věnována pozornost již v předchozí kapitole (viz 3.3.1). Výhodou tohoto indexu (jako všech ostatních poměrových indexů) je, že není tolik ovlivněn atmosférou, dá se tedy

použít i na datech bez atmosférické korekce. Snižuje také chybu vzniklou v závislosti na úhlu snímání (Gascoin et al., 2020).

Nevýhodou je, že má velkou chybovost na zalesněných územích. Stromy často zakrývají zasněženou půdu a snižují tedy hodnotu NDSI. V takové situaci je potřeba snížit prahovou hodnotu 0.4. S dalším zpřesněním přišla Hall, když upozorovala, že sníh snižuje hodnoty NDVI. Pokud je tedy hodnota NDVI přibližně 0.1, jedná se o zasněžený pixel, i když je $NDSI < 0.4$.

NDSI také značně nadhodnocuje hodnoty ve tmavém prostředí. Pokud jsou hodnoty odrazivosti malé, tak značně zmenšují jmenovatel rovnice NDSI a vzorec má tendenci označit pixel jako sníh i při malém vzrostu odrazivosti ve viditelném spektru. Toto se dá vyřešit tím, že odrazivost v zeleném pásmu viditelného spektra musí být aspoň 0.1.

Tyto všechny podmínky produkt Snowmap implementuje a na jeho základě jsou vytvářeny denní, osmidenní a měsíční produkty sněhové pokrývky zprostředkované americkým národním datovým centrem pro sníh a led NSIDC (National Snow and Ice Data Center). V perfektních klimatických a ideálních terénních podmínkách má tento algoritmus přesnost 93 %. Průměrně má ovšem přesnost 31 % a 45 % na družici Aqua, respektive Terra (Dietz et al., 2012). Ačkoliv je tento algoritmus pro velkoplošné snímání sněhové pokrývky a tvorbu globálních produktů dosud optimální a nejpoužívanější, s prostorovým rozlišením 500 metrů není vhodný pro aplikaci na menší plochy.

Index NDSI zároveň ztrácí přesnost, pokud je v pixelu méně než 50 % sněhové pokrývky. V těchto případech je vhodné použít subpixelovou klasifikaci (Salomonson & Appel, 2004).

TM (Thematic Mapper) byl multispektrální skenovací radiometr snímající ve viditelné a infračervené oblasti elektromagnetického spektra na palubě satelitů Landsat-4 a 5. Senzory TM poskytovaly téměř nepřetržité pokrytí zemského povrchu od července 1982 až do června 2013 se šířkou záběru 185 km a rozlišením 30 m (ESA, ©2022 b).

Rosenthal a Dozier vytvořili pomocí Thematic Mapperu klasifikační model založený na rozhodovacím stromu obsahujícím velmi mnoho podmínek. Nejdříve se identifikují mrakové pixely. Jen pro tuto analýzu má schéma 21 možných negativních výstupů (terminálních uzlů). Druhé stromové schéma rozdělí hodnoty na sníh, vodu a „ostatní“ povrchy. Následuje regrese, která vytvoří subpixelovou mapu sněhové pokrývky (Rosenthal & Dozier, 1996).

MERIS (Medium Resolution Imaging Spectrometer) byl programovatelný spektrometr na palubě mise Envisat. MERIS se primárně věnoval pozorování barev oceánů, ale dále také studiu atmosféry a povrchu pevniny. Se šířkou záběru 1150 km dokázal nasnímat zemský povrch každé 3 dny v rozlišení 300 m/pixel (ESA, ©2022 a)

Subpixelová maska se z MERISu dá vytvořit pomocí řízené jemné klasifikace. Pomocí interaktivních tréninkových polí je pro každý pixel vytvořena pravděpodobnost, že spadá do typu využití krajiny specifikovaného v tréninkových polích. Výsledkem je mapa pro každou třídu využití, ve které je každému pixelu přiřazena hodnota pravděpodobnosti, že do této třídy spadá. Kombinací těchto jemných map je poté možno dosáhnout subpixelové přesnosti mapy (Pepe et al., 2005).

3.5 Charakteristika zájmového území

Ostrov Jamese Rosse leží v Jižním oceánu u pobřeží Antarktidy a od nejsevernějšího výběžku Antarktického poloostrova je oddělen průlivem prince Gustava. Ostrov byl zmapován v roce 1903 švédskou výpravou vedenou Otto Nordenskjöldem, který jej pojmenoval po britském průzkumníkovi Jamesi Clarku Rossovi, jenž v roce 1842 objevil a zakreslil velké množství míst na východě ostrova (Obrázek 3).




Obrázek 4: Mapa Antarktidy, v horním levém rohu je vidět ostrov Jamese Rosse (British Antarctic Territory, 2022)

Rozloha ostrova činí přibližně 2500 metru čtverečních a je ze 70-80 % pokryt ledovcem. Severní část s rozlohou asi 312 kilometrů čtverečních je odledněná a jedná se o největší odledněnou část Antarktického poloostrova (Kavan et al., 2017).

Na ostrově převládá J až JZ vítr, orografie antarktického poloostrova blokuje vlhké západní větry typické pro antarktickou oblast a přivádí studené bariérové větry směrem z jihu od antarktického kontinentu (Zvěřina et al., 2014).

Na obrázku 3 je záběr ostrova Jamese Rose z legendární mise Rosetta, jež sledovala 67P/Churyumov-Gerasimenko a po 10 letech letu na ní přistála (ESA, ©2022 c).



Obrázek 4 5: Záběr ostrova Jamese Rosse z družice Rosetta, 2007 (ESA, 2022)

V Tabulce X jsou znázorněna naměřená klimatická data z australského léta roku 1997 a 1998 na ostrově King George Island (KGI) (Braun & Hock, 2004) a v letech 2013-2016 na ostrově Jamese Rosse (Ambrožová et al., 2019).

Wind direction	Frequency (%)		Air temperature (°C)		Lapse rate (°C 100 m ⁻¹)	
	KGI	JRI	KGI	JRI	KGI	JRI
N	2.3	9.8	0.3	-1.5	0.4	0.6
NE	1.2	7.3	-0.7	-2.9	0.8	0.7
E	12.9	7.1	-2.2	-4.5	0.9	0.6
SE	14.5	5.9	-2.1	-4.6	0.9	0.6
SE	6.8	14.6	-0.9	-5.5	0.8	0.6
SW	27.6	21.0	0.6	-3.2	0.6	0.5
W	20.1	14.7	0.2	-0.3	0.7	0.4
NW	14.7	19.6	1.1	0.8	0.4	0.5

Tabulka 2: Klimatická data z KGI a ostrova Jamese Rosse v letech 1996-1998, re psektive 2013-2016 (Braun a Hock, 2004, Ambrožová et. al. 2019)

Zde jsou vidět převažující jihozápadní až západní větry, které jsou navíc vzhledem k datům z KGI mnohem studenější. To je vysvětlováno právě studenými bariérovými větry (Ambrožová et al., 2019).

Průměrná teplota v severní části ostrova (kde se nachází meteorologické stanice) se pohybuje mezi -6 až -7 °C (Ambrožová et al., 2019).

V severní části ostrova se také nachází česká výzkumná stanice J. G. Mendela (Obrázek č. 5) postavena v letech 2005 a 2006. Stanice byla vybudována Masarykovou univerzitou sídlící v Brně a slavnostně byla otevřena v únoru roku 2007



Obrázek 56: česká polární stanice J.G.Mendela (MUNI, 2022)

3.6 Digitální výškový model terénu REMA

REMA (the Reference Elevation Model of Antarctica) je digitální výškový model antarktického kontinentu dostupný od roku 2019. K vytvoření modelu byly použity snímky ze čtyř komerčních optických satelitů od společnosti DigitalGlobe Inc. – WorldView-1, WorldView-2, WorldView-3 a GeoEye-1. Družice využívají push-broom skener (funkci podélného skenování), díky které mají jednotlivé snímky až submetrové prostorové rozlišení. Navíc, jejich schopnost zaměřovat kamery umožňuje větší překryv snímků, a tedy jednodušší extrakci topografie pomocí fotogrammetrie. Díky vysokému prostorovému i radiometrickému rozlišení kamer jsou tyto snímky vhodné k zjišťování výšky i na površích s nízkým kontrastem, jakými jsou právě sněhová pokrývka nebo akumulární oblasti ledového příkrovu.

Snímky byly koregistrovány pomocí bodových mračen získaných z radaru CryoSat-2 a z laserového altimetrického systému GLAS z mise ICESat. Tímto způsobem bylo možné dosáhnout prostorového rozlišení 8 metrů, což je doposud nejvyšší prostorové rozlišení v této oblasti (předchozí digitální výškový model měl rozlišení ~ 30 metrů) (Howat et al., 2019).

3.7 ERA5 dataset

ERA5 je pátou generací reanalýzy ECMWF (European Centre for Medium-Range Weather Forecasts) pro globální klima a počasí za poslední 4 až 7 desetiletí. Klimatické reanalýzy kombinují minulé pozorování s modely, aby generovaly konzistentní časové řady více klimatických proměnných. Reanalýzy patří mezi nejpoužívanější soubory dat v geofyzikálních vědách a poskytují komplexní popis pozorovaného klimatu a našly široké uplatnění také v atmosférických vědách a v neposlední řadě v operačních meteorologických střediscích (Climate Data Store, ©2022).

Vzhledem k tomu, že se v případě ERA5 jedná o pátou generaci atmosférické reanalýzy, má ECMWF dlouhou historii. Činnosti v oblasti atmosférické reanalýzy byly zahájeny v roce 1979 projektem FGGE, po kterém následovala výroba ERA-15 v polovině 90. let, ERA-40 od roku 2001 do roku 2003 a ERA-Interim v období 2006-2019 (Hersbach et al., 2020) .

ERA5 poskytuje hodinové odhady velkého počtu atmosférických, pozemních a oceánských klimatických proměnných. Data pokrývají Zemi na 30 km mřížce a rozlišují atmosféru pomocí 137 úrovní povrchu až do výšky 80 km. Měsíční aktualizace ERA5 (1979 až do současnosti) se zárukou kvality jsou publikovány do tří měsíců v reálném čase. Předběžné denní aktualizace datové sady jsou uživateli k dispozici do pěti dnů v reálném čase. ERA5 kombinuje obrovské množství historických pozorování do globálních odhadů pomocí pokročilého modelování a systémů asimilace dat. Nahrazuje zmíněnou reanalýzu ERA-Interim (ECMWF, ©2022).

3.8 Google Earth Engine

Google Earth Engine je inovací v práci s geoprostorovými daty. Nabízí volně přístupnou databázi téměř všech veřejně přístupných geodat, obrovský výpočetní výkon, geoprostorové API a interaktivní aplikační server GEE představuje neuvěřitelný pokrok v objemu zpracovaných dat a v rychlosti jejich zpracování.

Katalog dat obsahuje například kompletní archivy Sentinelu 1 a 2, misí Landsat, ale i klimatická data, klimatické modely a předpovědi a mnoho dalších datasetů. Z aktivních misí se denně přidává přibližně 6000 nových scén a scény se přidávají zhruba po 24 hodinách od jejich zpracování.

Nevýhodou je pomalejší stahování dat (exportování dat je funkce na klientské straně), GEE předpokládá, že uživatel bude stahovat až hotové výsledky celých analýz, převážně ve formě tabulek či grafů. Při častější potřebě ověřovat výsledky dílčích analýz se toto ukazuje jako problém.


K datům se uživatel dostává přes klientské knihovny, dostupné pomocí jazyka JavaScript, případně Python (Gorelick et al., 2017).

4. Metodika

K první části postupu byl použit Google Earth Engine. Javascript kód pro analýzu je přiložen na konci práce (Příloha č. 1). Do analýzy vstupovaly snímky z družic Sentinel-2, které měly oblačnost menší než 30 % snímku. Oříznuty byly podle zájmového území.

Poté byla použitá pásma převzorkována na stejné rozlišení, aby se s nimi dalo pracovat. Převzorkování se provádí vždy podle nejhoršího rozlišení vstupních dat. Pokud bychom použili převzorkování podle lepších dat, dosáhli bychom falešné přesnosti.

Pro každý snímek byly pomocí rastrového kalkulátoru spočteny hodnoty NDSI, Saito S3 indexu a maska mraků. Ta byla spočtena použitím modrého pásma pro identifikaci mraků a středního infračerveného pásma (SWIR) pro jejich odlišení od vodních ploch. Pomocí podmínky $(NDSI \geq 0.4) \text{ AND } (Saito S3 = 1) \text{ AND } (maska\ mraků \neq 1)$ byly vytvořeny binární rastry sněhové masky (Obrázek 6).



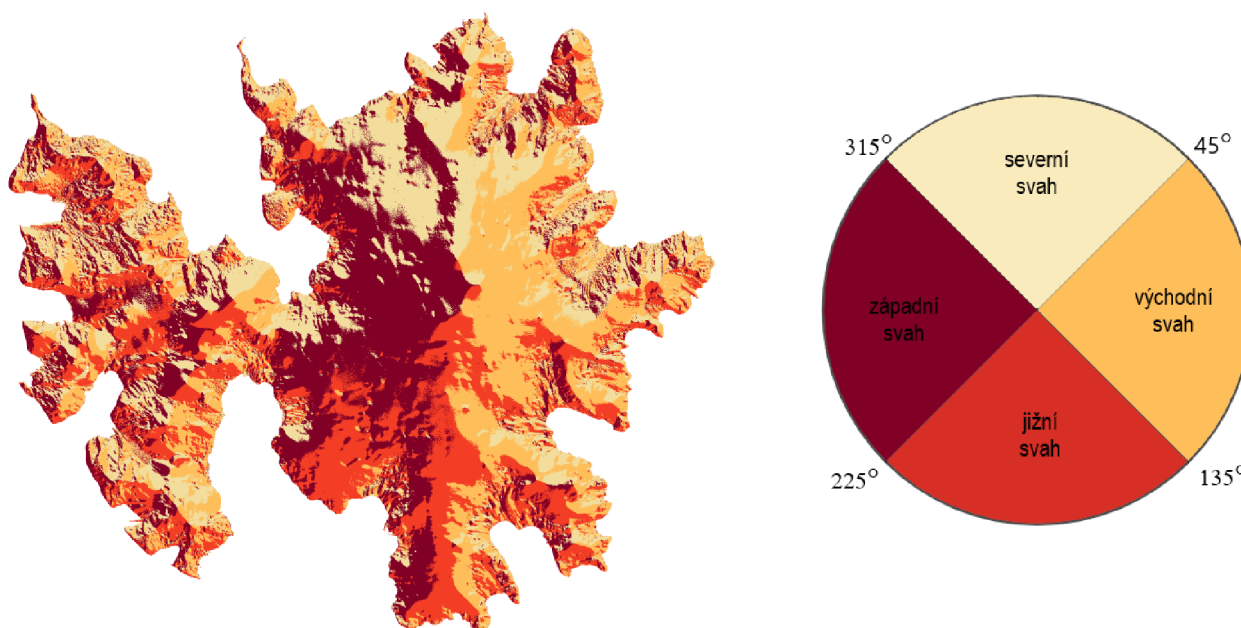
Obrázek 6 7: Workflow metody klasifikace sněhu (autorka)

K dalšímu postupu byl použit software ArcGIS Pro od společnosti ESRI. Čtyři dlaždice datasetu digitálního výškového modelu, jež zasahovaly do zájmového území, byly spojeny do jedné mozaiky a ořezány funkcí *Clip*. Poté byly použity nástroje *Aspect* a *Slope*, kterými byly vytvořeny rastry orientace svahu, respektive jeho sklonitosti.

Orientace svahu popisuje orientaci svahu vzhledem k světovým stranám a je vyjádřena ve stupních v rozsahu 0°–360°. Pro potřeby analýzy byl rastr převeden ze spojitého na diskretní pomocí nástroje *Int* a poté překlasifikován do čtyř tříd pomocí nástroje *Reclass by Table* (Tabulka č. 3, Obrázek 7).

hodnoty orientace svahu	nová hodnota rastru	popis hodnoty
315°-360°	1	severní svah
0°-45°	1	severní svah
45°-135°	2	východní svah
135°-225°	3	jižní svah
225°-315°	4	západní svah

Tabulka 3: Reklasifikační tabulka orientace svahu

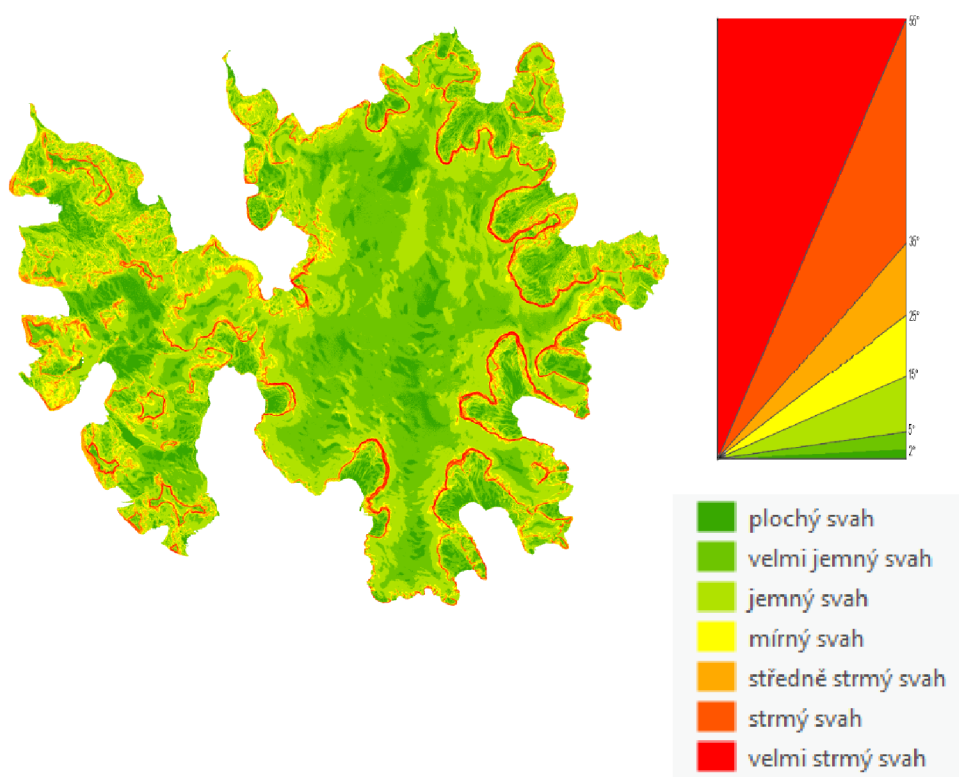


Obrázek 78: Mapa orientace svahu a její legenda (autorka)

Sklon svahu vyjadřuje úhel tečné roviny v bodě k rovině rovnoběžné, je vyjádřen hodnotami od 0°–90°. Tento rastr byl také převeden na diskretní rastr a poté překlasifikován: Byla použita klasifikace sklonu, kterou vytvořil He (Tabulka č. 4, Obrázek č. 8) (He et al., 2020).

hodnoty sklonu svahu	nová hodnota rastru	popis hodnoty
0°-2°	1	plochý svah
2°-5°	2	velmi jemný svah
5°-15°	3	jemný svah
15°-25°	4	mírný svah
25°-35°	5	středně strmý svah
35°-55°	6	strmý svah
55°-90°	7	velmi strmý svah

Tabulka 4 Reklasifikační tabulka sklonu svahu



Obrázek 89: Mapa sklonu svahu a její legenda (autorka)

Oba rastry byly poté převedeny na do vektoru pomocí nástroje *Raster to Polygon*.

Vektory orientace a sklonu svahu byly poté použity jako zónové vektory v nástroji *Zonal Statistics as Table*. Výsledkem byly tabulka pro každý rastr obsahující počet pixelů sněhu v každé zóně.

Bylo vypočteno, jaký podíl má každá jednotlivá zóna na zasněžených pixelech a poté byly tyto hodnoty zprůměrovány.

Jedním z cílů bylo porovnat trendy pokryvu s terénními měřeními. K tomu byla použita meteorologická data ERA5 od společnosti EUCWF, konkrétně směr a rychlost větru. Data jsou dostupná ve formátu GRIB (Gridded Binary), který zaznamenává klimatické hodnoty v mřížce s časovým rozměrem. Data o větru jsou zaznamenány pomocí dvou vektorů, vektor u a vektor v . Data jsou spočtena pro každou hodinu. K analýze byla použita data zprůměrovaná na měsíce od roku 2016 do konce roku 2021. Do softwaru ArcGIS Pro byly hodnoty vloženy jako multidimenzionální rastr a poté převedeny na formát NetCDF. Poté byl spočten směr větru ze směrových vektorů u a v .


$$\text{směr větru} = \text{atan}^2(v, u)$$

Z těchto dat byl vytvořen průměrný směr větru za celou dobu měření.

Ačkoliv byl výsledkem rastr se 72 hodnotami, byly všechny hodnoty téměř identické, s hodnotou kolem 45° , tedy jihozápadní vítr.

5. Výsledky


Analyzováno bylo 73 snímků z družice Sentinel-2. Snímky byly sice vybírány s ohledem na oblačnost, nicméně v jedné části ostrova se téměř vždy vyskytovala (asi v 80 % snímků), tato část tedy byla z analýzy vyřiznuta, aby nevytvářela nepřesné hodnoty. Na obrázku 9 je vidět vzhled sněhové masky z 19. 12. 2018.



Obrázek 9 10: Sněhová maska z prosince 2018 (autorka)


Zastoupení jednotlivých orientací svahů na ostrově je téměř rovnoměrné, jak je vidět na obrázku 10 na obrázku 11 je vidět zastoupení jednotlivých typů svahu na rozloze zasněžených pixelů, zde je vidět, že sníh se na jižních a západních svazích držel více než na severních a východních.

Podíl typů svahu na celkové rozloze ostrova



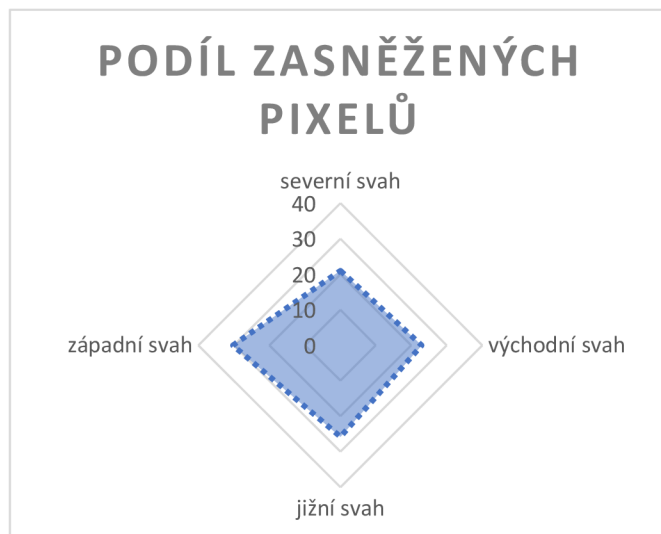
Obrázek 10: Podíl typu svahu na celkové rozloze ostrova (autorka)

Podíl zasněžených pixelů




Obrázek 11 Podíl typu svahu na zasněžených pixelech (autorka)

Na obrázku 12 je paprskový graf podílu zasněžených pixelů ilustrující převahu jižních a jihozápadních svahů.



Obrázek 12: Paprskový graf podílu typu svahu na zasněžených pixelech (autorka)


Na obrázku 13 je ukázka masky sněhové pokrývky z prosince 2018 vytvořené v této práci. Znázorněn je severní cíp ostrova. Z obrázku je patrné, že se sníh převážně udržuje na vršku návětrné strany a těsně za ní na straně závětrné, jak popisoval Mott, je zde vidět i zhlazení terénu (zakrytím sněhovou pokrývkou) (Mott et al., 2018).



Obrázek 13: Maska sněhové pokrývky z prosince 2018 (autorka)


Na obrázcích 14 a 15 jsou grafy podílu typů svahu na celkové rozloze ostrova, respektive na jeho zasněžené části. Zde takový rozdíl mezi normálním rozložením a rozložením zasněžené části není patrný, důležité je ale, že ačkoliv roviny zastupují na celém ostrově až 20 % povrchu, zasněžené části zastupují jen 10 %. Toto potvrzuje vysoký vliv větru na přesouvání sněhové pokrývky. Největší podíl zasněžených pixelů je mezi 2 až 15 stupni, což odpovídá předpokládanému rozdělení.

Podíl typů svahu na celkové rozloze ostrova



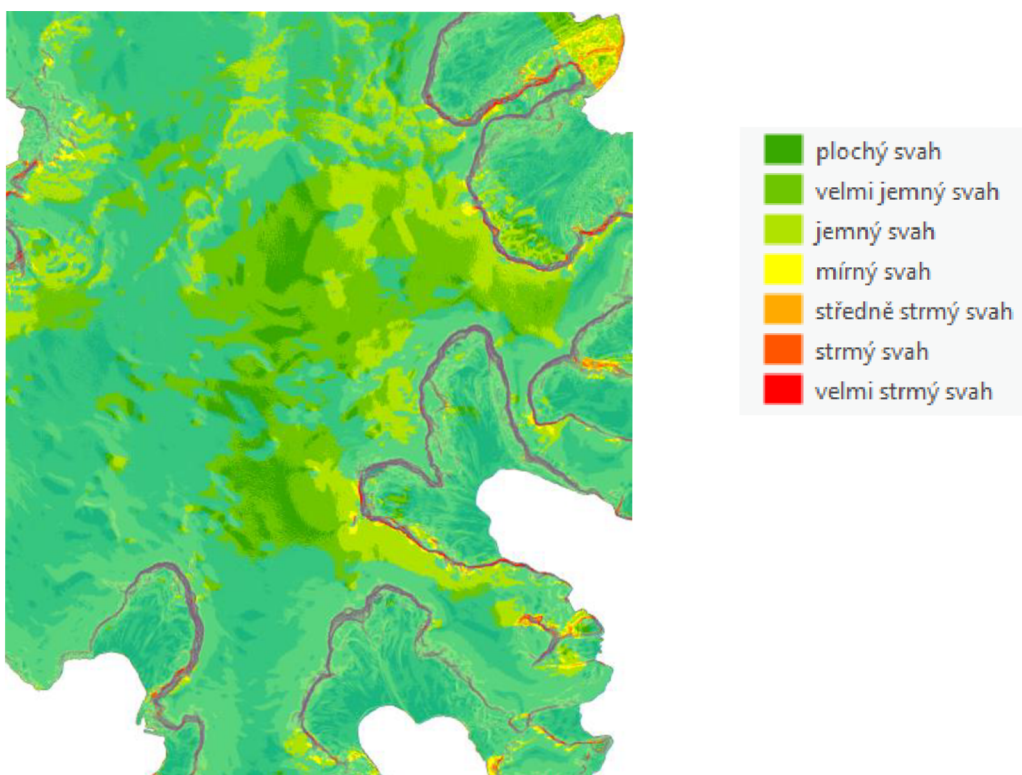
Obrázek 14: Podíl typu svahu na celkové rozloze ostrova (autorka)

Podíl zasněžených pixelů




Obrázek 15: Podíl typu svahu na zasněžených pixelech (autorka)

Na obrázku 16 je vidět Clearwater Mesa – vulkanická náhorní planina, která se nachází ve středu ostrova. Modře je označena sněhová maska z prosince 2018, zde je patrné, že na plošinách se sníh příliš dlouho neudrží.



Obrázek 16: Mapa náhorní planiny Clearwater Mesa a její legenda (autorka)



Obrázek 17: Mapa průměrného směru větru na ostrově Jamese Rosse (autorka)

Data extrahována z datasetu ERA5 od ECMWF nedosáhla požadovaných výsledků. Ačkoliv je klimatický model, který je k tvorbě datasetu použit, již několikátou generací tohoto modelu a pro většinu míst je jako zdroj dat dostačující, pořád jde částečně o interpolaci z dostupných dat, která je nejpřesnější v obydlených oblastech. Ani jednu z těchto podmínek bohužel ostrov Jamese Rosse v polární oblasti nesplňuje, a proto nemělo s daty smysl pokračovat do hlubších analýz. Neznamená to ovšem, že by nebyla správná, jen nedosahují potřebného rozlišení. V této průměrné hodnotě 20 stupňů tedy potvrzují terénní měření od *Ambrožové* (2019) a jsou využita k podpoření teze, jak je vidět na obrázku 17.

6. Diskuse

Výsledky byly převážně uspokojivé, tezi by však více potvrdila kvalitnější data, než jsou odhady datasetu ERA5. Za ideální data by mohla být považována data terénního měření, která by jednak mohla potvrdit vliv větru na dynamiku sněhové pokrývky na ostrově, ale také zjistit podrobnější informace o způsobu vlivu větru.

V analýze závislosti na terénu by bylo možné rozšířit směry orientace ze čtyř základních na osm (S, SV, V, JV, J, JZ, Z a SZ), což by poskytovalo větší přesnost analýzy.

Byly popsány různé metody mapování sněhové pokrývky i s jejich možnostmi či nedostatky. Nejpřesnějších výsledků dosahuje subpixelová metoda pomocí rozhodovacích stromů. Tato metoda, jak již bylo zmíněno, je ovšem na výpočet velmi komplikovaná a hodí se spíše pro malé oblasti. Další metodou, kterou by bylo možno v případě kvalitnějších a rozmanitějších dat použít, je také již zmíněná metoda, metoda jemné klasifikace. Obě tyto metody však již na začátku práce byly vyhodnoceny jako nevyhovující vzhledem k nedostupnosti kvalitních terénních dat, ale také z důvodu komplikovaných výpočtů. V případě použití jedné ze zmíněných metod by se dalo očekávat dosažení poněkud odlišných, do jisté míry pravděpodobně kvalitnějších výsledků, oproti výsledkům, kterých bylo dosaženo pomocí použití vlastní úpravy nejpoužívanějšího algoritmu Snowmap.

Metoda přesto dosáhla uspokojivých výsledků, které však byly ohodnoceny pouze vizuální validací. Bylo by možné zjistit opravdovou přesnost této metody a případně upravit zdrojový skript k veřejnému sdílení.

7. Závěr

Tato bakalářská práce se v teoretické části zabývala popisem mapování sněhové pokrývky. Byly popsány důležité spektrální vlastnosti sněhu umožňující samotné mapování, popis pohybu sněhu v krajině a také byly popsány nejspolehlivější současné postupy k získání mapy sněhové pokrývky s pomocí optických senzorů.

V praktické části bylo cílem vytvořit vhodný postup k automatickému rozpoznávání sněhové pokrývky ve vysokém rozlišení a tohoto postupu poté využít k ověření závislosti pokryvu sněhové pokrývky na větru a terénu.

Data z EMCWF byla sice nedostačující k větší analýze v závislosti na hodnotách, vyjadřovaly ale stejný výsledek jako terénní měření od *Ambrožové*, tedy převážný směr od jihozápadu. (Ambrožová et al., 2019).

Samotnou analýzou masek v závislosti na terénu bylo zjištěno, že se sníh drží převážně na jižních až jihozápadních svazích a na velmi jemných až jemných svazích. Na plošinách se sníh vyskytoval výrazně méně. To podporuje tezi, že je pokryv sněhové pokrývky na ostrově Jamese Rosse vysoce ovlivněn větrem.

Práce by mohla být vhodně rozšířena podrobnějším měřením větru pro validaci závislosti.

Z pohledu výběru metody mapování sněhu se vybraný postup osvědčil a jako automatizující skript v Google Earth Engine může být po validaci s terénními daty použit pro další výzkumné projekty.

8. Přehled literatury a použitých zdrojů

- Ambrožová, K., Láska, K., Hrbáček, F., Kavan, J., & Ondruch, J. (2019). Air temperature and lapse rate variation in the ice-free and glaciated areas of northern James Ross Island, Antarctic Peninsula, during 2013–2016. *International Journal of Climatology*, 39(2), 643–657. <https://doi.org/10.1002/joc.5832>
- Barrow, C., Dutta, S., Gonsoroski, E., & Lynn, T. (2017). *Automated Snow Index Tool (ASIT)*. Langley Research Center. <https://software.nasa.gov/software/LAR-19128-1#:~:text=Then the area of snow,percentage of the whole area.>
- Braun, M., & Hock, R. (2004). Spatially distributed surface energy balance and ablation modelling on the ice cap of King George Island (Antarctica). *Global and Planetary Change*, 42(1–4), 45–58. <https://doi.org/10.1016/j.gloplacha.2003.11.010>
- Carlson, B. Z., Hébert, M., Reeth, C. van, Bison, M., Laigle, I., & Delestrade, A. (2020). Monitoring the seasonal hydrology of alpine wetlands in response to snow cover dynamics and summer climate: A novel approach with Sentinel-2. *Remote Sensing*, 12(12). <https://doi.org/10.3390/rs12121959>
- Dietz, A. J., Kuenzer, C., Gessner, U., & Dech, S. (2012). Remote sensing of snow - a review of available methods. *International Journal of Remote Sensing*, 33(13), 4094–4134. <https://doi.org/10.1080/01431161.2011.640964>
- Dozier, J., Green, R. O., Nolin, A. W., & Painter, T. H. (2009). Interpretation of snow properties from imaging spectrometry. *Remote Sensing of Environment*, 113(SUPPL. 1), S25–S37. <https://doi.org/10.1016/j.rse.2007.07.029>
- Dozier, J., & Painter, T. H. (2004). Multispectral and hyperspectral remote sensing of alpine snow properties. *Annual Review of Earth and Planetary Sciences*, 32(March 2004), 465–494. <https://doi.org/10.1146/annurev.earth.32.101802.120404>
- Gascoin, S., Dumont, Z. B., Deschamps-Berger, C., Marti, F., Salgues, G., López-Moreno, J. I., Revuelto, J., Michon, T., Schattan, P., & Hagolle, O. (2020). Estimating fractional snow cover in open terrain from Sentinel-2 using the normalized difference snow index. *Remote Sensing*, 12(18). <https://doi.org/10.3390/RS12182904>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hall, D. K., & Riggs, G. A. (1995). Mapping global snow cover using Moderate Resolution Imaging Spectroradiometer (MODIS) data. *Report GD-30: Monitoring an Evolving Cryosphere - Summary of the NSIDC Special Session at the American Geophysical Union Fall Meeting 2001*, 4257(95), 13–17.

- Hall Dorothy K. and Riggs, G. A. (2011). Normalized-Difference Snow Index (NDSI). In P. and H. U. K. Singh Vijay P. and Singh (Ed.), *Encyclopedia of Snow, Ice and Glaciers* (pp. 779–780). Springer Netherlands. https://doi.org/10.1007/978-90-481-2642-2_376
- HALOUNOVÁ, L., & PAVELKA, K. (2005). *HALOUNOVÁ, Lena a Karel PAVELKA. Dálkový průzkum Země* (1st ed.). Vydavatelství ČVUT, . ISBN 80-01-03124-1.
- He, W., Ye, C., Sun, J., Xiong, J., Wang, J., & Zhou, T. (2020). Dynamics and drivers of the alpine timberline on Gongga Mountain of Tibetan Plateau- Adopted from the Otsu method on Google Earth engine. *Remote Sensing*, 12(16). <https://doi.org/10.3390/RS12162651>
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., ... Thépaut, J. N. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), 1999–2049. <https://doi.org/10.1002/qj.3803>
- Howat, I. M., Porter, C., Smith, B. E., Noh, M. J., & Morin, P. (2019). The reference elevation model of antarctica. *Cryosphere*, 13(2), 665–674. <https://doi.org/10.5194/tc-13-665-2019>
- Kavan, J., Ondruch, J., Nývlt, D., Hrbáček, F., Carrivick, J. L., & Láska, K. (2017). Seasonal hydrological and suspended sediment transport dynamics in proglacial streams, James Ross Island, Antarctica. *Geografiska Annaler, Series A: Physical Geography*, 99(1), 38–55. <https://doi.org/10.1080/04353676.2016.1257914>
- Kyle, H. L., Curran, R. J., Barnes, W. L., & Escoe, D. (1978). Third Conference on Atmospheric Radiation of the American Meteorological Society, June 28–30, 1978, University of California, Davis, Calif. *Bulletin of the American Meteorological Society*, 59(4), 461–498. <http://www.jstor.org/stable/26218161>
- Majumdar, S. (2019). *Snow Depth and Swe Estimation Using and Interferometric*. May. <https://doi.org/10.13140/RG.2.2.29137.99682>
- Mott, R., & Lehning, M. (2010). Meteorological modeling of very high-resolution wind fields and snow deposition for mountains. *Journal of Hydrometeorology*, 11(4), 934–949. <https://doi.org/10.1175/2010JHM1216.1>
- Mott, R., Vionnet, V., & Grünwald, T. (2018). The Seasonal Snow Cover Dynamics: Review on Wind-Driven Coupling Processes. In *Frontiers in Earth Science* (Vol. 6). Frontiers Media S.A. <https://doi.org/10.3389/feart.2018.00197>
- Pepe, M., Brivio, P. A., Rampini, A., Rota Nodari, F., & Boschetti, M. (2005). Snow cover monitoring in Alpine regions using ENVISAT optical data. *International Journal of Remote Sensing*, 26(21), 4661–4667. <https://doi.org/10.1080/01431160500206635>
- Pimentel, R., Herrero, J., & Polo, M. J. (2017). Quantifying snow cover distribution in semiarid regions combining satellite and terrestrial imagery. *Remote Sensing*, 9(10), 1–17. <https://doi.org/10.3390/rs9100995>

- Pomeroy, J. W., & Brun, E. (2011). Physical properties of snow. *Encyclopedia of Earth Sciences Series, Part 3*(January 2001), 859–863. https://doi.org/10.1007/978-90-481-2642-2_422
- Rosenthal, W., & Dozier, J. (1996). Automated mapping of montane snow cover at subpixel resolution from the Landsat Thematic Mapper. *Water Resources Research*, *32*(1), 115–130. <https://doi.org/10.1029/95WR02718>
- Salomonson, V. v., & Appel, I. (2004). Estimating fractional snow cover from MODIS using the normalized difference snow index. *Remote Sensing of Environment*, *89*(3), 351–360. <https://doi.org/10.1016/j.rse.2003.10.016>
- Shimamura, Y., Izumi, T., & Matsuyama, H. (2006). Evaluation of a useful method to identify snow-covered areas under vegetation - Comparisons among a newly proposed snow index, normalized difference snow index, and visible reflectance. *International Journal of Remote Sensing*, *27*(21), 4867–4884. <https://doi.org/10.1080/01431160600639693>
- Valovcin, F. R. (1976). Snow/Cloud Discrimination. In *Air Force Surveys in Geophysics* (Issue 394).
- Warren, S. G. (2019). Optical properties of ice and snow. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, *377*(2146). <https://doi.org/10.1098/rsta.2018.0161>
- Zvěřina, O., Láska, K., Červenka, R., Kuta, J., Coufalík, P., & Komárek, J. (2014). Analysis of mercury and other heavy metals accumulated in lichen *Usnea antarctica* from James Ross Island, Antarctica. *Environmental Monitoring and Assessment*, *186*(12), 9089–9100. <https://doi.org/10.1007/s10661-014-4068-z>

8.1 Internetové zdroje

Climate Data Store, ©2022: ERA5 hourly data on single levels from 1979 to present (online) [cit.2022.03.30], dostupné z <<https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=overview>>.

ECMWF, ©2022: ERA5 (online) [cit.2022.03.03], dostupné z <<https://www.ecmwf.int/en/forecasts/datasets/reanalysis-datasets/era5>>.

ESA, ©2014: Optical properties of ice and snow (online) [cit.2022.03.30], dostupné z <https://www.esa.int/SPECIALS/Eduspace_Global_EN/SEMPJ7TWLUG_0.html>.

ESA, ©2022 a): MERIS Overview (online) [cit.2022.03.30], dostupné z <<https://earth.esa.int/eogateway/instruments/meris/description>>.

ESA, ©2022 b): Thematic Mapper (TM) (online) [cit.2022.03.30], dostupné z <<https://earth.esa.int/eogateway/instruments/thematic-mapper-tm->>.

(ESA, ©2022 c): Rosetta (online [cit. 2022.03.30] dostupné z <https://sci.esa.int/web/rosetta/-/41768-graham-land?fbclid=IwAR1haGd82DJLDDg4YFuHICDt_vrLfIKq1PbWxwxmBpd2Lm02DsEtHaH36Yk>

NASA, ©2022: MODIS (online) [cit.2022.03.30], dostupné z <<https://science.nasa.gov/missions/tiros>>.

NASA, ©2016: TIROS (online) [cit.2022.03.30], dostupné z <<https://science.nasa.gov/missions/tiros>>.

ECMWF, ©2022: ERA5 (online) [cit.2022.03.03], dostupné z <<https://www.ecmwf.int/en/forecasts/datasets/reanalysis-datasets/era5>>.

8.2 Zdroje obrázků a tabulek

Obrázek 1: Spektrální křivka odrazivosti různých druhů sněhu (Majumdar, S. (2019). *Snow Depth and Swe Estimation Using and Interferometric. May*.
<https://doi.org/10.13140/RG.2.2.29137.99682>)

Obrázek 2: Typy pohybu sněhu (Giudice, A. Lo, Nuca, R., Preziosi, L., & Coste, N. (2019). Wind-blown particulate transport: A review of computational fluid dynamics models. *Mathematics In Engineering*, 1(3), 508–547.
<https://doi.org/10.3934/mine.2019.3.508>)

Obrázek 3: Mapa Antarktidy (British Antarctic Territory) (online)[cit. 2022.03.26], dostupné z < <https://britishantarcticterritory.org.uk/sir-james-clark-ross/?fbclid=IwAR3KNkHqdCyrlooNNVbNkBGf5mb967PhhFYKwco8W2w7GeUvKVTKCQxUPPc> >

Obrázek 4: Záběr ostrova Jamese Rosse z družice Rosetta, 2007 (ESA, ©2022 c): Rosetta (online [cit. 2022.03.30] dostupné z <https://sci.esa.int/web/rosetta/-/41768-graham-land?fbclid=IwAR1haGd82DJLDDg4YFuHICDt_vrLflKq1PbWxwxmBpd2Lm02DsEtHaH36Yk>

Obrázek 5: Česká polární stanice J.G.Mendela (Masarykova univerzita v Brně) (online) [cit 2022.03.30] dostupné z: <<https://www.tested-in-antarctica.com>>

Obrázek 6 Workflow metody klasifikace sněhu (tato práce)

Obrázek 7 Mapa orientace svahu a její legenda (tato práce)

Obrázek 8 Mapa sklonu svahu a její legenda (tato práce)

Obrázek 9 Sněhová maska z prosince 2018 (tato práce)

Obrázek 10 Podíl typu svahu na celkové rozloze ostrova (autorka)

Obrázek 11: Podíl typu svahu na zasněžených pixelech (autorka)

Obrázek 12: Paprskový graf podílu typu svahu na zasněžených pixelech (autorka)

Obrázek 13: Maska sněhové pokrývky z prosince 2018 (autorka)

Obrázek 14: Podíl typu svahu na celkové rozloze ostrova (autorka)

Obrázek 15: Podíl typu svahu na zasněžených pixelech (autorka)

Obrázek 16: Mapa náhorní planiny CLearwater Mesa a její legenda (autorka)

Obrázek 17 Mapa průměrného směru větru na ostrově Jamese Rosse (autorka)

Tabulka 1: Charakteristiky typů pohybu sněhu (autorka)

Tabulka 2: Klimatická data z KGI a ostrova Jamese Rosse v letech 1996-1998, respektive 2013-2016 (Ambrožová, K., Láska, K., Hrbáček, F., Kavan, J., & Ondruch, J. (2019). Air temperature and lapse rate variation in the ice-free and glaciated areas of northern James Ross Island, Antarctic Peninsula, during 2013–2016. *International Journal of Climatology*, 39(2), 643–657.

<https://doi.org/10.1002/joc.5832>

Braun, M., & Hock, R. (2004). Spatially distributed surface energy balance and ablation modelling on the ice cap of King George Island (Antarctica). *Global and Planetary Change*, 42(1–4), 45–58.

<https://doi.org/10.1016/j.gloplacha.2003.11.010>

Tabulka 3: Reklasifikační tabulka orientace svahu (autorka)

Tabulka 4: Reklasifikační tabulka sklonu svahu (autorka)

9. Seznam příloh

Příloha 1: Javascriptový skript pro dílčí analýzu v Google Earth Engine

Příloha 1: Javascriptový skript pro dílčí analýzu v Google Earth Engine

```
/*© 2022 Dominika Gulková <domee98@gmail.com> */

/*import from assets GEE*/
var geometry =
  /* color: #d63000 */
  /* shown: false */
  /* displayProperties: [
    {
      "type": "rectangle"
    }
  ] */
  ee.Geometry.Polygon(
    [[[ -58.729003248215946, -63.762950731632614],
      [-58.729003248215946, -64.45610661042129],
      [-56.927245435715946, -64.45610661042129],
      [-56.927245435715946, -63.762950731632614]]], null, false),
    table = ee.FeatureCollection("projects/ee-domcis/assets/islandboi"),
    elevation = ee.Image("users/Domcis/DEM1");

/*set sensor and bands*/
var STD_Names = ['blue', 'green', 'red', 'nir', 'swir1', 'swir2'];
var sensor = 'COPERNICUS/S2';
var sensorBands = ['B2', 'B3', 'B4', 'B8A', 'B11', 'B12'];

/*datum (yyyy-mm-dd)*/
var startDate = '2016-02-01';
var endDate = '2021-12-31';

/*polygon study area*/
var studyArea = table;

/* minimal elevation for analysis */
var elevBounds = 0;

/*band names*/
var blue = sensorBands[0];
var green = sensorBands[1];
var red = sensorBands[2];
var nir = sensorBands[3];
var swir1 = sensorBands[4];
var swir2 = sensorBands[5];
```



```

/* import sentinel2 and cloudFilter */
var satellite = ee.ImageCollection(sensor).filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 30));

/* spatial filter */
var spatialFiltered = satellite.filterBounds(studyArea);

/* filter by date */
var withBands = spatialFiltered.filterDate(startDate, endDate);

/*mosaic tiles for the same date*/
function mosaicByDate(withBands){
  var imlist = withBands.toList(withBands.size());
  print(imlist);

  var unique_dates = imlist.map(function(im){
    return ee.Image(im).date().format("YYYY-MM-dd");
  }).distinct();
  print(unique_dates);
  var mosaic_imlist = unique_dates.map(function(d){
    d = ee.Date(d);
    //print(d)
    var im = withBands
      .filterDate(d, d.advance(1, "day"))
      .mosaic();
    //print(im)
    return im.set(
      "system:time_start", d.millis(),
      "system:id", d.format("YYYY-MM-dd"));
  });

  return ee.ImageCollection(mosaic_imlist);
}

var ic_m = mosaicByDate(withBands);
print(ic_m);

/*elevationData*/
var addElev = function(image) {
  return image.addBands(elevation.select('elevation'));
};
var withBands = ic_m.map(addElev);

/*****

```

Cloud Mapping

```

*****/

/* Cloud Mapping: Blue for identifying clouds, SWIR1 for differentiating clouds from snow */
var addSClouds = function(image) {
    var cloudy =
    ((image.select(swir1).divide(10000)).gte(0.12)).and((image.select(blue).divide(10000)).gte(0.2))
    .rename('Cloud_Index');
    return image.addBands(cloudy);
};

/*****
        Saito S3 Index
*****/

/* Saito 1999 S3 Index */
var addSentS3 = function(image) {
    var snow3 = (((image.select(nir)).divide(10000))
    .multiply(((image.select(red)).divide(10000)).subtract((image.select(swir1)).divide(10000))))
    .divide((((image.select(nir)).divide(10000)).add((image.select(red)).divide(10000))))
    .multiply(((image.select(nir)).divide(10000)).add((image.select(swir1)).divide(10000))))
    .rename('S3index');
    return image.addBands(snow3);
};

/*****
        Calling the appropriate Formulae
*****/

var withBands = (sensorBands == S2_Bands) ? withBands.map(addSClouds) :
withBands.map(addClouds) ;
var withBands = (sensorBands == S2_Bands) ? withBands.map(addSentS3) :
withBands.map(addS3index) ;

/*****
        NDSI
*****/

/* Normalized Difference Snow Index*/
var addNDSI = function(image) {
    var ndsi = image.normalizedDifference([green, swir1]).rename('NDSI');
    return image.addBands(ndsi);
};
var withBands = withBands.map(addNDSI);

/*****
        Combined Snow Index
*****/

```

```

*****/

/* If both assign snow to a pixel (and Cloud_Index does not indicate clouds) then assign snow */

var addCSI = function(image) {
  var combSnowIndex = (image.select('NDSI').gte(0.05).and(image.select('S3index').gte(0.01))
    .and(image.select('Cloud_Index').eq(0))
    .and(image.select('elevation').gte(elevBounds))
    ).rename('CSI');
  return image.addBands(combSnowIndex);
};
var withBands = withBands.map(addCSI);

/*selectCsiBand*/
var indexy = withBands.select ('CSI');
/*download whole ImageCollection*/
var batch = require('users/fitoprincipe/geetools:batch');
batch.Download.ImageCollection.toDrive(indexy, "CSI", {scale: 10});

```