

Univerzita Karlova
Přírodovědecká fakulta

Studijní program: Geoinformatika, kartografie a dálkový průzkum Země



Bc. Anna Brázdová

ZMĚNA LAND COVER V ZALEDNĚNÝCH HORSKÝCH OBLASTECH

LAND COVER CHANGE IN GLACIATED MOUNTAIN AREAS

Diplomová práce

Vedoucí práce: Ing. Lukáš Brodský Ph.D.

Praha, 2024

Zadání diplomové práce

Jméno a příjmení: Bc. Anna Brázdová

Studijní program: Geoinformatika, kartografie a dálkový průzkum Země

Název: Změna land cover v zaledněných horských oblastech

Zásady pro vypracování

Cílem diplomové práce je navržení metody detekce plošných změn zalednění, přičemž důraz bude kladen na odlišení reálných změn od nepravých/dočasných změn, jako jsou stíny, změna vlhkosti povrchu nebo suť na ledovci. Dále si práce klade za úkol implementovat tuto metodu pro detekci jak ústupu, tak i postupu zalednění, a následně analyzovat a vizualizovat reálné změny pomocí multitemporální analýzy. Klíčovým úkolem bude zvolit takový model strojového učení, který je schopen odlišit suť pokrývající zalednění od sousedního skalnatého povrchu na základě různých vlastností povrchu.

Dílními cíli práce jsou:

1. Navrhnout metodu detekce změn zalednění s využitím optických multispektrálních dat
2. Vybrat vhodné příznaky ledovců pro odlišení problematických ploch zalednění (suť, stín)
3. Vybrat vhodný model strojového učení k dosažení přesnosti klasifikace stavu $> 95 \%$
4. Analyzovat přínos jednotlivých příznaků pro detekci změn zalednění

Zkoumanou oblastí bude grónský ostrov Disko ležící v Baffinově zálivu. K vyřešení výše stanovených cílů budou sloužit multispektrální optické snímky družic Landsat 5, 7, 8, techniky detekce změn a modely strojového učení.

Seznam odborné literatury:

KHAN, A. A., JAMIL, A., HUSSAIN, D., TAJ, M., JABEEN, G., MALIK, M. K. (2020): Machine-learning algorithms for mapping debris-covered glaciers: The Hunza Basin Case Study. IEEE Access, 8, 12725–12734.

LU, D., MAUSEL, P., BRONDÍZIO, E., MORAN, E. (2004): Change detection techniques. International Journal of Remote Sensing, 25, 12, 2365–2401.

PELLIKKA, P., REES, G. (2010): Remote sensing of glaciers: Techniques for topographic, spatial, and thematic mapping of glaciers. CRC Press, Boca Raton Fla.

ZHANG, J., JIA, L., MENENTI, M., HU, G. (2019): Glacier Facies Mapping Using a Machine-Learning Algorithm: The Parlung Zangbo Basin Case Study. Remote Sensing, 4, 11, 452.

Vedoucí diplomové práce: Ing. Lukáš Brodský, Ph.D.

Konzultant diplomové práce: –

Datum zadání diplomové práce: 14. 6. 2023

Ing. Lukáš Brodský, Ph.D.

Vedoucí diplomové práce

doc. RNDr. Přemysl Štych, Ph.D.

Garant studijního programu

V Praze dne 12. 9. 2023

Prohlášení

Prohlašuji, že jsem závěrečnou práci zpracovala samostatně a že jsem uvedla všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze, 23. 6. 2024

Anna Brázdová

Poděkování

Na tomto místě bych chtěla poděkovat vedoucímu práce Ing. Lukáši Brodskému Ph.D. za ochotný a trpělivý přístup, cenné rady a připomínky v průběhu zpracování diplomové práce. Dále bych chtěla poděkovat svým nejbližším za podporu v průběhu celého studia.

Abstrakt

Cílem diplomové práce je navržení metody detekce plošných změn zalednění, přičemž důraz je kladen na odlišení nepravých změn, jako jsou stíny, změna vlhkosti povrchu nebo suť na ledovci, od změn skutečných (změna třídy krajinného pokryvu). Klíčovou částí je volba vhodných příznaků a modelu strojového učení pro odlišení problematických ploch zalednění (suť, stín) na základě různých vlastností povrchu, a analýza přínosu jednotlivých příznaků pro detekci změn zalednění. Hlavním zdrojem dat jsou multitemporální snímky Landsat zachycující ostrov Disko, který se nachází západně od Grónska. Zkoumáno bylo šest hlavních tříd: zaledněné plochy, zastíněné zaledněné plochy, ledovce pokryté suti, nezaledněné plochy, zastíněné nezaledněné plochy a vodní plochy. Pro odlišení těchto tříd byly kromě spektrálních příznaků použity spektrální indexy, termální pásmo, texturní a topografické příznaky a rychlost povrchového pohybu ledovce. Pro klasifikaci krajinného pokryvu v jednotlivých letech byly vyzkoušeny tři modely strojového učení: *k-Nearest Neighbors*, *Random Forest* a *Gradient Boosted Decision Trees*. Random Forest se ukázal jako vhodný model, protože se dokázal vypořádat s komplexní strukturou dat, a dokázal odlišit problematické třídy s celkovou přesností > 95 %. Pro detekci změn byly zkoumány techniky detekce změn založené na obrazové algebře, techniky založené na klasifikaci a hybridní techniky, přičemž velmi dobrých výsledků bylo dosaženo pomocí postklasifikačního porovnání, a také přímou multitemporální klasifikací změn. K nejdůležitějším příznakům detekce změn patřily spektrální příznaky, spektrální indexy (NDSI, NBR) a termální pásmo. Výsledky ukázaly, že u zaledněných ploch došlo mezi lety 1985–2021 k úbytku o $239,4 \text{ km}^2$, což je zhruba $22,69$ % z celkových zaledněných ploch. V průměru se plocha zalednění zmenšuje o $6,6 \text{ km}^2$ za rok, přičemž v období 2000–2021 došlo k dvojnásobnému úbytku než v letech 1985–2000. Plocha zalednění se mezi lety 1985–2000 zmenšila o $8,9$ % a období 2000–2021 o $18,55$ %.

Klíčová slova: změna krajinného pokryvu, dálkový průzkum Země, detekce změn, strojové učení, ústup ledovců, klimatické změny

Abstract

The aim of this thesis is to propose a method for detecting glacier area changes, with emphasis on distinguishing between false positive changes, such as shadows, surface moisture change, or debris cover on glacier surface, and real changes (transition between land cover classes). The key part is to choose appropriate features and a machine learning model to distinguish problematic glaciation areas (debris, shadow) based on different surface properties and to analyze the contribution of each feature for glaciation change detection. The main data source is Landsat multitemporal imagery capturing Disko Island, located west of Greenland. Six main classes were investigated: glaciated areas, shaded glaciated areas, debris-covered glaciers, unglaciated areas, shaded unglaciated areas and water bodies. In addition to spectral features, spectral indices, thermal band, textural and topographic features, and glacier surface velocity were used to distinguish these classes. Three machine learning models were tested to classify the land cover for each year: *k-Nearest Neighbours*, *Random Forest* and *Gradient Boosted Decision Trees*. Random Forest proved to be a suitable model as it was able to deal with the complex data structure and was able to distinguish problematic classes with >95 % overall accuracy. Image algebra-based, classification-based, and hybrid techniques were investigated for change detection, with very good results achieved using post-classification comparison and direct multi-date classification of changes. The most important features for change detection were spectral features, spectral indices (NDSI, NBR), and thermal band. The results showed a decrease of 239,4 km² in glaciated areas between 1985 and 2021, which is about 22,69 % of the total glaciated areas. On average, the area of glaciers is decreasing by 6,6 km² per year, with twice as much loss between 2000 and 2021 as between 1985 and 2000. Glacier area decreased by 8,9 % between 1985–2000 and 18,55 % between 2000–2021.

Keywords: land cover change, remote sensing, change detection, machine learning, glacier retreat, climate change

Obsah

Seznam obrázků a tabulek	9
Přehled použitých zkratk	10
1 Úvod	11
2 Úvod do problematiky	13
2.1 Ledovce a klimatické změny	13
2.2 Mapování parametrů ledovců s využitím DPZ	16
2.2.1 Mezinárodní aktivity monitorování zaledněných oblastí	21
2.2.2 Příznaky pro ledovce pokryté sutí	22
2.3 Strojové učení v DPZ	23
2.4 Detekce změn	29
3 Data a metodika	40
3.1 Zájmové území	40
3.2 Data	45
3.2.1 Data pro mapování zaledněných ploch	45
3.2.2 Referenční soubory dat	48
3.3 Metodika	48
3.3.1 Předzpracování dat	49
3.3.2 Výběr technik a realizace	50
3.3.3 Hodnocení změn	56
4 Výsledky	58
5 Diskuze	66
6 Závěr	76
Zdroje	77
Přílohy	84

Seznam obrázků a tabulek

Obrázek 1: Odrazivost sněhu a ledu na různých částech spektra.....	18
Obrázek 2: Lokace ostrova Disko	40
Obrázek 3: Schéma pracovního postupu	49
Obrázek 4: Příznakový prostor tříd pro rok 1985	52
Obrázek 5: Zobrazení snímků v syntéze nepravých barev.....	58
Obrázek 6: Chybová matice klasifikace pro rok 2000	59
Obrázek 7: Důležitost příznaků pro klasifikaci stavu (informační zisk).....	59
Obrázek 8: Důležitost příznaků pro klasifikaci stavu (permutační důležitost)	60
Obrázek 9: Binární změnové mapy pro období 1985–2000	60
Obrázek 10: Binární změnové mapy pro období 2000–2021	61
Obrázek 11: Změnové matice pro všechny třídy krajinného pokryvu	61
Obrázek 12: Změnové mapy (postklasifikační porovnání)	62
Obrázek 13: Matice skutečných změn	62
Obrázek 14: Změnové mapy (přímá multitemporální klasifikace změn)	63
Obrázek 15: Důležitost příznaků pro klasifikaci změn (informační zisk)	64
Obrázek 16: Důležitost příznaků pro klasifikaci změn (permutační důležitost).....	64
Obrázek 17: Změnové mapy (transformace obrazu a klasifikace změn).....	65
Obrázek 18: Plošné zastoupení tříd krajinného pokryvu	68
Obrázek 19: Chybová matice změnových tříd pro období 2000–2021	71
Obrázek 20: Změnové mapy pro období 1985–2000.....	72
Obrázek 21: Změnové mapy pro období 2000–2021	73
Obrázek 22: Zastoupení stabilních a změnových ploch	73
Tabulka 1: Použité Landsat snímky.....	46
Tabulka 2: Klasifikační legenda	51
Tabulka 3: Početní zastoupení jednotlivých tříd	51
Tabulka 4: Tabulka možných změn.....	54
Tabulka 5: Přesnost klasifikace krajinného pokryvu.....	58

Přehled použitých zkratk

ANN	<i>artificial neural networks</i> (umělé neuronové sítě)
CNN	<i>convolutional neural networks</i> (konvoluční neuronové sítě)
DT	<i>decision trees</i> (rozhodovací strom)
DPZ	dálkový průzkum Země
GBDT	<i>gradient boosted decision trees</i> (gradientem posílené rozhodovací stromy)
GIS	geografické informační systémy
GLCM	<i>gray level co-occurrence matrix</i> (koincidenční matice stupňů šedi)
GLIMS	Global Land Ice Measurements from Space (Globální měření pevninského ledu z vesmíru)
InSAR	<i>Interferometric SAR</i> (radarová interferometrie)
KNN	<i>k-nearest neighbours</i> (k nejbližších sousedů)
NASA	<i>National Aeronautics and Space Administration</i> (Národní úřad pro letectví a vesmír)
NIR	<i>near infrared band</i> (blízké infračervené pásmo)
NDSI	<i>normalized difference snow index</i> (normalizovaný diferenční sněhový index)
NDWI	<i>normalized difference water index</i> (normalizovaný diferenční vodní index)
OLI	Operational Land Imager
PCA	<i>principal component analysis</i> (analýza hlavních komponent)
RED	<i>red band</i> (červené pásmo)
RF	<i>random forest</i> (náhodný les)
RGI	Randolph Glacier Inventory (Inventář ledovců Randolph)
SAR	<i>synthetic aperture radar</i> (radar se syntetickou aparaturou)
SVM	<i>support vector machine</i> (metoda podpůrných vektorů)
SWIR	<i>shortwave infrared band</i> (krátkovlnné infračervené pásmo)
TIRS	Thermal InfraRed Sensor
USGS	United States Geological Survey (Geologická služba Spojených států amerických)
WGMS	World Glacier Monitoring Service (Světové středisko pro monitorování ledovců)
WGI	World Glacier Inventory (Inventář světových ledovců)

1 Úvod

Detekce změn krajinného pokryvu je důležitá pro výzkum změn globálního klimatu, monitorování životního prostředí a pro mnoho dalších odvětví. Identifikaci rozdílů stavu objektů v průběhu času lze získat přesný odraz změn, ke kterým v určité geografické oblasti dochází. Globální oteplování na celém světě má za následek výrazný úbytek ledovcové pokrývky. Ledovce hrají v globálním i regionálním klimatickém systému velmi důležitou roli, neboť mají zásadní vliv na radiační bilanci povrchu, energetickou bilanci a hydrologické poměry. Díky snímkům dálkového průzkumu Země lze účinně sledovat změny i v zaledněných horských oblastech. Horské ledovce jsou obzvláště dobrými indikátory klimatických změn, protože na tyto změny reagují rychleji než ostatní prvky kryosféry. Kvůli své relativně malé velikosti a nedostatečné stabilitě jsou obzvláště velmi citlivé na výkyvy teplot a srážek. Rozlišení dlouhodobých změn od přirozené proměnlivosti vyžaduje sběr dat na mnoha místech po mnoho let, a jejich následnou pečlivou analýzu. Zjišťování reakcí kryosféry na měnící se klima představuje různé výzvy a vyžaduje dlouhodobé záznamy a frekventovaná pozorování (Zhang a kol. 2019; Alifu a kol. 2020).

Hlavním cílem práce je na základě prostudované literatury navrhnout metodu detekce plošných změn zalednění, přičemž důraz je kladen na odlišení skutečných změn od nepravých změn – například stínů, změn vlhkosti povrchu nebo suti na ledovci. Dále pak implementovat tuto metodu pro detekci ústupu i postupu zalednění, a následně analyzovat a vizualizovat reálné změny pomocí změnových map. Klíčovým úkolem je volba modelu strojového učení, který je schopen odlišit suť na ledovci od sousedního skalnatého povrchu na základě různých vlastností povrchu.

Dílními cíli jsou pak:

1. Navržení metody detekce změn zalednění s využitím optických multispektrálních dat
2. Výběr vhodných příznaků ledovců pro odlišení problematických ploch zalednění (suť, stín)
3. Výběr vhodného algoritmu strojového učení k dosažení přesnosti > 95 %
4. Analýza přínosu jednotlivých příznaků pro detekci změn zalednění

K vyřešení výše stanovených cílů je stanovena metodika založená na Open Source technologiích. Zkoumanou oblastí je grónský ostrov Disko ležící v Baffinově zálivu. Primární zdrojem dat jsou snímky Landsat z let 1985, 2000 a 2021.

Přestože existuje mnoho technik detekce změn, které byly zkoumány v mnoha aplikacích životního prostředí (vegetace, mokřady, urbánní oblasti, desertifikace a další), neexistuje mnoho studií, které by se zabývaly použitím různých technik pro zaledněné oblasti. Zároveň většina studií zkoumajících změny krajinného pokryvu využívá postklasifikační porovnání, které však zahrnuje mnoho kroků, a může trpět falešně pozitivními změnami způsobenými chybnou klasifikací (Chughtai, Abbasi, Karas 2021). Při zjišťování změn v zaledněných oblastech je problémem samotné mapování ledovců, protože mnoho ledovců je pokrytých sutí, a je velmi obtížné je na snímcích DPZ odlišit od okolního skalnatého povrchu. Za nejpřesnější metodu mapování ledovců pokrytých sutí je totiž stále považována ruční digitalizace. Studie zkoumající zaledněné oblasti se tedy spíše zaměřovaly na automatizaci mapování ledovců pokrytých sutí než na techniky detekce změn.

Diplomová práce je členěna do 6 kapitol. V úvodu jsou představeny důvody výběru daného tématu, cíle práce a její struktura. V teoretické části je stručně představena problematika reakce ledovců na klimatické změny a možnosti monitorování různých parametrů ledovců s využitím dat dálkového průzkumu Země i mezinárodní mise. Dále jsou představeny modely strojového učení, základní techniky detekce změn a možnosti jejich využití pro zaledněné horské oblasti. Následuje fyzickogeografická a socioekonomická charakteristika území v souvislosti s problematikou klimatických změn. V další části jsou detailně popsána vstupní data potřebná pro odvození spektrálních, teplotních, texturních a topografických vlastností povrchu. Následně je představena metodika pro návrh techniky detekce změn včetně přípravy dat, volba techniky detekce změn a hodnocení změn. V praktické části jsou na základě získaných poznatků vybrány a otestovány různé techniky detekce změn; rozdíl hodnot obrazových dat, postklasifikační porovnání, přímá multitemporální klasifikace změn, transformace obrazu a přímá klasifikace. Tyto techniky jsou naprogramovány pomocí jazyka Python. Výstupem práce jsou změnové mapy skutečných změn a mapy krajinného pokryvu pro roky 1985, 2000 a 2021. Současně jsou analyzovány skutečné a nepravé změny. Následuje diskuse a závěr, kde jsou shrnuty výsledky práce i jejich zhodnocení.

2 Úvod do problematiky

2.1 Ledovce a klimatické změny

Klimatická změna a globální oteplování jsou jevy, které v posledních desetiletích výrazně ovlivňují naši planetu. Jedná se o postupné zvyšování průměrné teploty Země způsobené především rostoucími emisemi skleníkových plynů z lidské činnosti. Tento proces má rozsáhlé dopady na různé ekosystémy a přírodní procesy, přičemž jednou z nejvíce postižených oblastí je kryosféra.

Kryosféra zahrnuje všechny oblasti Země, kde se voda vyskytuje v pevném skupenství, a to buď sezónně nebo celoročně. Složkami kryosféry jsou sněhová pokrývka, sladkovodní a mořský led, zmrzlá půda a ledovce. Kryosféra hraje klíčovou roli v globálním klimatickém systému, protože ovlivňuje energetickou bilanci, cirkulaci vzduchu a oceánů, a také hladinu moří. Kromě toho představuje největší zásobárnu sladké vody na Zemi a reguluje vliv skleníkových plynů (Tedesco 2014).

Kryosféra je nejcitlivější složka životního prostředí ohrožená probíhající klimatickou změnou. Od průmyslové revoluce v polovině 19. století se v důsledku lidské činnosti, jako je spalování fosilních paliv, průmyslové procesy, zemědělství a změny ve využívání půdy se zvyšuje množství oxidu uhličitého a metanu v atmosféře. Plyny zadržující teplo, nazývané také skleníkové plyny, jsou hlavní příčinou oteplování klimatu a ústupu ledovců od počátku 20. století. Ačkoliv je změna klimatu obecně způsobena nárůstem koncentrací skleníkových plynů v atmosféře, tento základní hnací proces je součástí složitých interakcí mezi atmosférou, hydrosférou, biosférou a kryosférou. Skleníkové plyny pohlcují teplo vyzařované zemským povrchem, a kvůli pohlcování tohoto tepla se atmosféra a oceány pomalu ohřívají. Oteplování oceánů a vzduchu pak přispívá ke změnám v kryosféře. Úbytek kryosféry vyvolává zpětné pozitivní vazby, které způsobují další oteplování (Tedesco 2014; NSIDC 2024).

Sníh a led pomáhají regulovat teplotu Země, protože odrážejí značné množství dopadajícího slunečního záření zpět do vesmíru. Sníh a led mají ve srovnání s jinými povrchy vysoké albedo, a jsou důležitým ochlazovacím faktorem v globálním klimatickém systému. S úbytkem sněhové a ledové pokrývky dochází k odkrývání tmavší pevniny a oceánu, které sluneční záření spíše pohlcují, než aby jej odráželi, čímž přispívají k rychlejšímu oteplování, což vede k dalšímu zmenšování ploch pokrytých sněhem a ledem. Mořský led výrazně snižuje přenos tepla mezi oceánem a atmosférou, protože vrstva mořského ledu působí jako izolační vrstva

a udržuje klima chladnější. S úbytkem mořského ledu se teplo v podobě teplé vody dostává z rovníkových oblastí na póly, což vede k oteplování polární atmosféry a dalšímu zmenšování kryosféry v polárních oblastech. Suchozemský permafrost je významnou zásobárnou organického uhlíku a hydrátů plynu a tání permafrostu vede k emisím metanu, který přispívá ke skleníkovému efektu v atmosféře (Tedesco, 2014).

Jedním z nejvýznamnějších příznaků probíhajících klimatických změn je však ústup ledovců. Většina ledovců ustupuje od poloviny 19. století, v posledním století ledovce ustupují rychleji a rychlost ústupu od počátku 21. století překračuje historické zkušenosti a přirozenou proměnlivost ledovců (NSIDC 2024). Ledovce jsou důležitou součástí globální kryosféry a jsou citlivou součástí zpětnovazebních mechanismů klimatického systému, neboť pokrývají rozsáhlé plochy a jejich albedo může přesahovat 90 %. Jejich nízká teplota přispívá ke globálnímu teplotnímu gradientu, který pohání systém atmosférické cirkulace, a jejich velikost a poloha zásadně ovlivňují detaily této cirkulace. Kromě toho, že menší ledovce plní roli indikátoru klimatu, mají také hospodářský význam. Ledovce uchovávají přibližně 69 % světových zásob sladké vody a zásobují mnoho lidí na celém světě. Ledovce jsou také zásobárnou vodní energie, která se využívá zejména v Norsku, na Islandu, ve Spojených státech a v Alpách (Kuhn 2010; NSIDC 2024).

Ledovec je trvalá hustá masa ledu, která se neustále pohybuje pod vlastní vahou. Ledovce se začínají tvořit tam, kde se dlouhodobě ukládá sníh, který se postupem času přeměňuje na led. Každý rok nové vrstvy sněhu pohřbívají a stlačují předchozí vrstvy, čímž sníh rekrystalizuje a tím se pomalu zhutňuje a mění se v led. Ledovce tedy vznikají, když se během běžného roku nahromadí více sněhu, než kolik se ho ztratí, tedy když akumulace převyší ablací. Obecně se akumulace skládá ze sněhových srážek, větrných nánosů a lavin. Sníh padá na akumulační oblasti, obvykle v části ledovce s nejvyšší nadmořskou výškou, čímž se zvyšuje hmotnost ledovce. Jak se sníh hromadí a mění v led, hmotnost ledovce roste a led se začíná deformovat, což způsobuje jeho pohyb. Masa ledu proudí pod vlivem vlastní váhy do oblastí nižších nadmořských výšek, kde se nachází ablační oblast. Ablace je přirozenou a sezónní součástí života ledovce a může být způsobena táním, sublimací, větrnou erozí, nebo ztrátou ledu lavinami či odlamováním ledu do oceánu. Akumulační a ablační zóna jsou od sebe odděleny rovnovážnou čarou, kde je bilance mezi přírůstkem a úbytkem hmoty přesně nulová. Hmotnostní bilance určuje, zda je ledovec stabilní nebo zda se zmenšuje či naopak roste. Dokud ledovec akumuluje stejnou hmotnost sněhu, kterou ztrácí, zůstává v rovnováze, nebo se dokonce zvětšuje. Pokud je však hmotnostní bilance záporná, množství přeneseného ledu

nestačí k vyrovnání tání ledu, plocha ledovce ustupuje a ledovec se zmenšuje. Většina ledovců má zápornou hmotností bilanci a čelo ledovce ustupuje a tím ledovec zmenšuje svou plochu (Kuhn 2010).

Rozložení ledovců je dáno podmínkami prostředí včetně geografického umístění, nadmořské výšky a tvaru reliéfu, teplotou vzduchu, množstvím slunečního záření a ročním úhrnem srážek. Ledovce se vyskytují na místech se specifickými klimatickými a topografickými podmínkami. Vznikají především ve vysokých zeměpisných šířkách a nadmořských výškách s velkými zimními sněhovými srážkami a mírnými teplotami (Alifu a kol. 2020). Obecně existují dvě kategorie ledovců, ledovcové příkrovy (štíty) a horské ledovce. Ledovcový příkrov je ledovcová masa rozkládající se na ploše větší než 50 000 km². V současné době se na Zemi nachází pouze Grónský ledový příkrov a Antarktický ledový příkrov. Horské ledovce vznikají ve vysokohorských oblastech. Jsou zmrzlé masy ledu, které pod vlastní vahou pomalu stékají po svazích hor do údolí (NSIDC, 2024). Ledovec při svém pohybu intenzivně eroduje své podloží a boční stěny údolí, což vede k odlamování okolního horninového materiálu, který vytváří boční morény, pokud se soustřeďuje po bočních stranách ledovce. Pokud se ale úlomky hornin a suťové materiály usazují na povrchu a v čele ledovce, vznikají ledovce pokryté suti. Ledovce pokryté suti představují důležitou součást ledovcových systémů v horském prostředí, neboť přítomnost suti na ledovcovém splazu může ovlivňovat rychlost tání, zvyšovat rychlost ablace v případě tenkého suťového pokryvu, nebo snižovat rychlost ablace při silném suťovém pokryvu. Pokrytí suti také zastírá skutečnou rozlohu ledovců, což ztěžuje přesnou inventarizaci ledovcových ploch a jejich příslušných výkyvů v reakci na klimatické změny a další faktory (Alifu a kol. 2020).

Ledovce a ledovcové příkrovy reagují na globální oteplování s různou intenzitou. Menší ledovce jsou na globální oteplování citlivější, zatímco ledové příkrovy jako Grónsko a Antarktida reagují na probíhající změny pomaleji. Doba reakce ledovců je však ovlivněna místním klimatem. Ledovce nacházející se v mořském mírném a polárním podnebí reagují na změny klimatu rychleji a intenzivněji než ledovce v chladném kontinentálním podnebí. Změny ledovců po celém světě jsou však patrné bez ohledu na jejich měřítko, neboť se jejich rozloha i objem postupně zmenšují (Pellikka, Rees 2010b). Pochopení dynamiky změn a neustálé monitorování ledovců je zásadní nejen pro studium klimatu a hospodaření s vodními zdroji, ale také pro předvídání a předcházení geohazardů spojenými s ledovci. Tání ledovců přispívá ke zvyšování hladiny moří, což ohrožuje pobřežní oblasti a způsobuje erozi. Lokální nebezpečí

také představuje voda uvolněná z ledovce či ledovcové laviny (Pandey, Ramanathan, Venkataraman 2016).

2.2 Mapování parametrů ledovců s využitím DPZ

Existuje řada měřitelných parametrů, které lze použít ke zmapování reakce zaledněného prostředí na klimatické změny. Některá pozorování lze provádět měřeními in-situ v terénu různými glaciologickými, hydrologickými nebo geodetickými metodami, avšak podrobné sledování ledovců je velmi náročný úkol. Ledovce se často nacházejí v odlehlých vysokohorských oblastech, kde bývá extrémní klima, což snižuje nebo dokonce vylučuje jejich celkovou dostupnost. Z těchto důvodů jsou jako prostředek shromažďování údajů zvláště užitečné pozorovací techniky dálkového průzkumu Země (Raup a kol. 2014; Pandey, Ramanathan, Venkataraman 2016).

DPZ lze definovat jako umění a vědu získávání informací o objektu, aniž bychom s ním byli v kontaktu. Dálkový průzkum lze provádět ze země, letecky nebo z vesmíru. Družicový dálkový průzkum představuje cenný nástroj pro shromažďování informací o ledovcích, které jsou jinak nepřístupné. Díky technologiím DPZ je možné získávat parametry ledovců včetně polohy, plošného rozsahu, hmotnosti tloušťky a rychlosti pohybu ledu, rozložení supraglaciálních prvků, jako jsou skalní sutě a jezera, rozložení ledovcových zón, mapování sněhové pokrývky a nadmořské výšky rovnovážné linie, povrchovou teplotu ledovce či jeho topografii a změny těchto parametrů v čase. V některých případech poskytují technologie DPZ alternativu práce v terénu, některé vlastnosti ledovců je však obtížné nebo nemožné měřit jinak než dálkovým průzkumem (Pandey, Ramanathan, Venkataraman 2016; Taylor a kol. 2021).

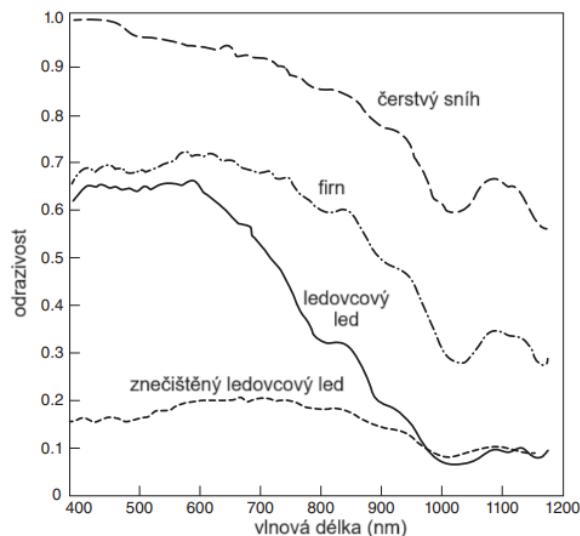
Použití dálkového průzkumu je rovněž náročným úkolem, protože musí překonat různé omezující faktory, jako přesnost geokódování, vliv topografie a atmosférické vlivy. Všechny tyto faktory však lze zohlednit použitím různých dat a technik dálkového průzkumu. Senzory využívané k dálkovému průzkumu Země pracují v různých částech elektromagnetického spektra a využívají ke sběru informací o objektu elektromagnetické záření. Pokud senzor dálkového průzkumu zaznamenává přirozeně se vyskytující záření, nazývá se pasivní. Tento typ senzorů zahrnuje například optické senzory, které měří odražené sluneční záření, nebo termální senzory, které detekují infračervené tepelné záření vyzařované objekty na zemském povrchu. Naopak, pokud senzor dálkového průzkumu vytváří vlastní záření, označuje se jako aktivní. Aktivní senzory jako radar nebo lidar, využívají vlastní zdroj záření a měří množství záření, která se od objektu na Zemi odrazí zpět k senzoru. Na rozdíl od pasivních senzorů

dokážou aktivní senzory získávat informace jak ve dne, tak v noci, což je výhodou v oblastech, kde nastává polární noc. V případě radaru je možné i měření skrz oblačnost, což výrazně zvyšuje jeho využitelnost při různých meteorologických podmínkách. Senzory pracují v různých spektrálních oblastech a hojně se využívají ke studiu ledovců (Pellikka, Rees 2010a; Tedesco 2014b).

Optické multispektrální senzory

Senzory zachycují odrazivé vlastnosti povrchu, které jsou kvantifikovány jejich spektrálními vlastnostmi. V různých částech elektromagnetického spektra mají jednotlivé zemské povrchy typické spektrální chování a rozlišování různých povrchů se tedy opírá o rozdíly ve spektrálním chování (Pellikka, Rees 2010b). Pokud nejsou ledovce pokryté sutí, je identifikace sněhu a ledu od okolních skal na satelitních snímcích možná díky podstatnému rozdílu ve spektrální odrazivosti. Světlý povrch ledovce má vyšší odrazivost ve srovnání s horninami či vegetací, které ho obklopují. Povrch ledovce se většinou skládá ze sněhu, firnu, ledu, vody a suti, přičemž podíl těchto složek na různých ledovcích je velmi proměnlivý, což významně ovlivňuje optické vlastnosti ledovce. Suť na ledovci může mít velmi podobné spektrální vlastnosti jako okolní horniny, stejně tak jako voda obsahující velké množství horninových úlomků (Pellikka, Rees 2010b; Tedesco 2014b; Kääb a kol. 2014).

Vzhledem k tomu, že ledovcový led vzniká z metamorfovaného sněhu, jsou optické vlastnosti povrchu ledovce do značné míry určeny vlastnostmi sněhu. Sníh má velmi vysokou odrazivost ve viditelné oblasti elektromagnetického spektra, zatímco v části blízkého a středního infračervené oblasti má vyšší absorpci. Vzor spektrální odezvy sněhu však závisí na jeho hustotě, velikosti zrn, obsahu kapalné vody a přítomnosti nečistot, jako jsou prach a suti. Odrazivost sněhu je vyšší u čerstvého sněhu, a s rostoucí velikostí zrn klesá. Firn má tedy o 25–30 % nižší odrazivost než sníh. Ledovcový led má vysokou odrazivost v modrém a zeleném pásmu vlnových délek, naopak v červeném pásmu prudce klesá. Odrazivost na různých částech ledovce se může lišit v důsledku přirozeného stárnutí a znečištění. Jak sněhová pokrývka stárne, může se na ní také usazovat prach nebo horninové úlomky, které mohou rovněž snižovat odrazivost. Zatímco odrazivost čerstvé sněhové pokrývky může přesahovat 90 %, u znečištěného sněhu může toto číslo klesnout na 40 % nebo dokonce až na 20 % (Pellikka, Rees 2010b; Tedesco 2014b). Na Obrázku 1 jsou znázorněny křivky spektrální odrazivosti čerstvého sněhu, firnu, ledovcového ledu a znečištěného ledovcového ledu.



Obrázek 1: Odrazivost sněhu a ledu na různých částech spektra, převzato z: Hall a Martinec (1985)

Nejjednodušší a nejběžnější aplikací optického dálkového průzkumu v ledovcovém prostředí je mapování rozlohy ledovců. Vymezení ledovce je snazší na základě syntézy v nepravých barvách, která zvyšuje kontrast snímků. Jednou z nejpoužívanějších metod je vizuální interpretace a manuální vymezení ledovců ze snímků DPZ pořízených na konci ablačního období bez přítomnosti sezónního sněhu. Ruční digitalizace je však závislá na úrovni dovedností, úsudků a zkušenostech uživatele. Další nevýhodou této metody je těžkopádnost a časová náročnost při mapování rozlohy ledovců a při multitemporální analýze změn ve velkých územích. Proto bylo vyvinuto a testováno množství metod pro automatické mapování ledovců, které využívají odlišných spektrálních vlastností sněhu a ledu v různých částech elektromagnetického spektra (Pellikka, Rees 2010b).

Za robustní, přesnou a časově efektivní metodu pro vytyčování ledovců v regionálním měřítku je považována metoda poměru pásem. Poměry pásem pro mapování ledovců jsou založeny na kontrastu v odrazivosti sněhu a ledu ve viditelné a krátkovlnné infračervení části elektromagnetického spektra, díky čemuž silně zvýrazňují zaledněné plochy a snižují zkreslení osvětlení v terénu. K nejčastěji používaným patří poměr červeného a krátkovlnného infračerveného pásma (*RED/SWIR*), případně poměr blízkého infračerveného a krátkovlnného infračerveného pásma (*NIR/SWIR*). Celkově jsou rozdíly mezi těmito dvěma poměry velmi malé, přičemž je upřednostňována první varianta, která má oproti druhé výhodu v tom smyslu, že lépe rozlišuje zastíněný sníh, led a ledovce pokryté tenkou vrstvou sutě (Pellikka, Rees 2010). K mapování obrysů ledovců lze podobně použít normalizovaný rozdílový sněhový index. NDSI byl vyvinut pro mapování sněhu, ale protože ledovcový led je tvořen zhuštěným

sněhem, spektrální charakteristiky jsou podobné. NDSI je normalizovaný rozdíl zeleného a krátkovlnného infračerveného pásma. Obvykle se předpokládá, že sníh je přítomen, pokud NDSI překročí hodnotu 0,4, avšak optimální prahová hodnota se mění v závislosti na ročním období (Raup a kol. 2014).

Pokud nejsou ledovce pokryté sutí, lze pro mapování jejich plošné rozlohy využít metod řízené a neřízené klasifikace. Klasifikace obrazu je proces přiřazování tříd materiálu (vegetace, skály, sníh, voda atd.) ke každému pixelu obrazu. Pro řízenou klasifikaci je potřeba vybrat sadu pixelů, které jsou reprezentativní pro různé materiály na snímku. Rozdíly mezi spektrálními signaturami referenčních dat se následně použijí k přiřazení pixelů v obraze k jedné z těchto kategorií. Metody neřízené klasifikace přiřazují pixely do různých tříd na základě algoritmů pro detekci shluků (Raup 2014). Algoritmy řízené klasifikace často poskytují přesné výsledky pro vysokohorský terén. Mapování ledu pokrytého sutí je však stále obtížné. Algoritmy neřízené klasifikace bývají úspěšné v případě relativně homogenního terénu s malým počtem krajinných prvků, zatímco v případě složitějšího terénu s velkým počtem prvků se často objevují problémy (Kääb a kol. 2014).

Termální senzory

Termální senzory využívají termální infračervené záření k měření tepelného záření vyzařovaného objekty na zemském povrchu. Odrazivost sněhu a ledu v tepelné infračervené oblasti je relativně malá, díky čemu lze rozeznat zaledněné plochy od ostatních povrchů. Termální senzory mohou detekovat rozdíly v povrchové teplotě ledovců v závislosti na jejich tloušťce a přítomnosti vody a zároveň mají potenciál pro mapování ledovců pokrytých sutí (Pellikka, Rees 2010b; Pandey, Ramanathan, Venkataraman 2016).

Mikrovlnné/SAR senzory

Mikrovlnnou část spektra využívají jak aktivní, tak pasivní senzory. Velkou výhodou mikrovlnného záření je jeho schopnost proniknout skrz oblačnost, navíc tyto vlnové délky mohou za vhodných podmínek pronikat i pod povrch. Pasivní mikrovlnné radiometry se využívají k měření tepelného záření, měřený signál má však velký podíl šumu a jeho interpretace je obtížnější. Pasivní mikrovlnné radiometry se využívají pro mapování rozsahu sněhové pokrývky či mořského ledu, dále také pro získání vlastností sněhu, jako je jeho hloubka a vlhkost pro mapování ledovcových zón (Tedesco 2014b).

Typickými představiteli aktivních senzorů využívající mikrovlnné záření jsou radary. Radarový systém vysílá rádiové vlny směrem k Zemi a měří čas, za který se signál vrátí zpět k senzoru poté, co se odrazí od povrchu Země. Na základě tohoto času a změn v jeho frekvenci nebo fázi, je možné získat informace o vzdálenosti, rychlosti, tvaru a povaze objektů, které tyto signály odrážejí. Odrazivé vlastnosti povrchů jsou dány především drsností povrchu, vlhkostními poměry, úhlem dopadu a topografií terénu. Velkou výhodou radaru je nezávislost na světelných podmínkách a jeho schopnost proniknout skrz oblačnost. Většina družicových systémů využívá radar se syntetickou aperturou (Pellikka, Rees 2010b; Taylor a kol. 2021).

V současné době se družicové radary se využívají především k měření nadmořské výšky a k tvorbě výškových produktů. SAR snímky se pak využívají např. k detekci supraglaciálních jezer. Radarové snímky lze využít i pro monitorování povrchových rychlostí ledovce. Ledovce jsou neustále v pohybu a data o jejich pohybu mohou přispět k odlišení ledovců od jiných prvků krajinného pokryvu, zejména pak například ledovců pokrytých sutí od holé zemské půdy. Produkty povrchové rychlosti pohybu ledovců jsou důležité pro určení dlouhodobé reakce ledovce nebo regionu na oteplování klimatu, stejně jako pro posouzení pravděpodobných lokalit, kde mohou vznikat nebezpečí spojená s ledovci. Existují dvě hlavní techniky pro odvození rychlosti povrchového pohybu ledovce. První metodou je sledování prvků na povrchu ledovce v sekvenčních snímcích (optických nebo radarových). S využitím křížové korelace jsou vyhledávány shodné prvky (ledovcové vrcholy, trhliny nebo charakteristický vzor suti a ledu) na obou snímcích, a v mřížce je pro každé místo definován vektor posunu. Druhou metodou je využití radarové interferometrie (InSAR) pro monitorování geometrických posunů ledovce (Raup a kol. 2014; Pandey, Ramanathan, Venkataraman 2016).

Laser

Laserové altimetrie (Lidar) je další aktivní metodou dálkového průzkumu Země. Tato technologie využívá k zobrazování objektů viditelné či blízké infračervené světlo. Funguje tak, že systém vysílá světelné pulsy a detekuje záření odražené od objektů. Laserový systém měří čas, za který se laserové pulsy odrazí zpět. Výsledkem snímání je bodové mračno, ze kterého lze vytvořit digitální výškový model s velmi dobrou výškovou přesností. Laserové skenery jsou velmi vhodné pro měření topografie ledovců, či měření mocnosti ledovce (Pellikka, Rees 2010a; Tedesco 2014b).

Výškové produkty z laserových a radarových výškoměrů lze pak využít pro měření objemových změn a změn hmotnostní bilance ledovců. Objem nebo hmotnost ledovce a jejich

změny lze zkoumat pomocí pozorování plochy ledovce a jeho nadmořské výšky ve dvou různých časech, nebo změnou polohy rovnovážné linie. Rovnovážnou linii nelze zjistit přímo, ale lze ji odvodit z polohy sněhové čáry ze snímků pořízených na konci ablační sezóny. Modelováním rovnovážné linie pak lze mapovat ablační a akumulární zóny ledovce (Kuhn 2010; Raup 2014).

2.2.1 Mezinárodní aktivity monitorování zaledněných oblastí

Prvním pokusem o získání přehledu o světových ledovcích bylo sestavení světového soupisu ledovců (World Glacier Inventory) organizací World Glacier Monitoring Service. Cílem WGMS bylo shromáždit co nejvíce informací o světových ledovcích s využitím družicových dat a terénního měření. Tyto bodové informace je však obtížné použít pro hodnocení změn, a proto byla vytvořena databáze Global Land Ice Measurements from Space. Projekt GLIMS je mezinárodní iniciativa pro monitorování světových ledovců pomocí optických dat. Tento projekt zahrnuje více než 200 vědeckých institucí a poskytuje podrobné informace o ledovcích po celém světě v podobě ledovcových obrysů ve vektorovém formátu. Inventarizační data ledovců GLIMS mohou sloužit jako referenční sada pro výstupy analýz dat DPZ, protože jednotlivé ledovce obsahují informace o datu pořízení snímku či technikách použitých pro extrakci ledovců pokrytých sutí. Další důležitou databází je Randolph Glacier Inventory, která poskytuje kompletní sbírku digitálních obrysů světových ledovců s výjimkou ledovcových příkrovů (Paul 2011).

Činnost rozsáhlého monitorování ledovců úzce souvisí s družicovými misemi. Vývoj nových nástrojů, technik DPZ a dostupnost satelitních dat s vysokým rozlišením, přispěl k inventarizaci světových ledovců (Taylor a kol. 2021). Pro studium ledovců lze využít celou řadu satelitů využívajících optické senzory. Patří k nim například mise Landsat či SPOT ale i mnoho dalších. Program Landsat je jedním z nejúspěšnějších a nejdélejších programů, který nepřetržitě pozoruje Zemi, a shromažďuje data již od roku 1972. Skládá se z řady družicových misí, které společně řídí NASA a USGS. Veškerá Landsat data jsou volně dostupná a jsou poskytována dvou kolekcích, které se liší úrovní předzpracování dat (USGS 2023). Série družicových misí Sentinel významně přispívá k monitorování ledovců. Družice Sentinel jsou vybaveny pokročilými senzory, včetně radarových (Sentinel-1) a optických (Sentinel-2, Sentinel-3) přístrojů a poskytují data s vysokým rozlišením, která jsou volně dostupná. K dalším radarovým misím pak patří například RADARSAT-1 a RADARSAT-2 nebo ERS-1 a ERS-2. K misím využívající radarovou interferometrii pro generování digitálních výškových modelů patří například TerraSAR-X či TanDEM-X. Dalšími významnými misemi jsou například

ICESat a ICESat-2 nebo CryoSat-2, které využívají laserové nebo radarové altimetrie pro měření nadmořských výšek ledovců a jejich změn v čase. Měření změn gravitačního pole Země k odvození změn hmotnosti ledovců lze využít misi GRACE (eoPortal 2024).

K významným projektům patří například projekty ArcticDEM a projekt ITS_LIVE. Projekt ArcticDEM se zabývá tvorbou vysoce kvalitních výškových dat v odlehlých lokalitách pro potřeby přesného měření topografických změn. Výškové produkty ArcticDEM jsou výsledkem institucionální spolupráce mezi Národní geoprostorovou zpravodajskou agenturou (National Geospatial-Intelligence Agency) a Národní vědeckou nadací (National Science Foundation) (Porter, 2023). Program Inter-Mission Time Series of Land Ice Velocity and Elevation (ITS_LIVE) je součástí programu NASA Making Earth System Data Records for Use in Research Environments (MEaSUREs) a poskytuje datové soubory povrchových rychlostí pohybu ledovce i změn hmotnostní bilance a nadmořské výšky odvozených z různých družicových misí (Gardner, Fahnestock, Scambos 2023).

2.2.2 Příznaky pro ledovce pokryté sutí

Díky datům dálkového průzkumu Země lze efektivně monitorovat zaledněné oblasti. Získávání přesných informací ze satelitních snímků je však spojeno s řadou problémů a efektivní využití různých metod se liší v závislosti na typu dat a podmínkách prostředí. Faktory ovlivňující přesnost jednotlivých metod ovlivňuje např. vysoká oblačnost v horských i v ostrovních oblastech, proměnlivé sněhové podmínky a spektrální podobnost suti, která se nachází na povrchu ledovce a přilehlého skalního podloží (Alifu a kol. 2020; Zhang a kol. 2019).

Problémům spojených se sezónním sněhem lze předcházet volbou vhodného snímku z konce ablační sezóny. V Grónsku je za vhodnou roční dobu považován konec srpna. Ideální je pak najít takový snímek, který neobsahuje oblačnost, avšak v horských oblastech to může být problematické. V takovém případě je před samotnou analýzou potřeba identifikovat veškerou oblačnost. To lze provést pomocí barevné syntézy v nepravých barvách (SWIR-NIR-RED), kde se pouze oblačnost jeví bíle. Součástí produktů Landsat je pásmo hodnocení kvality oblačnosti podle odrazivosti povrchu a lze jej použít pro vytvoření masky oblačnosti (Paul, Hendriks 2010).

Mnoho ledovců je však pokrytých sutí a je obtížné je automaticky odlišit od okolních skalnatých oblastí kvůli podobným spektrálním charakteristikám. Mapování povrchu ledovců pokrytých sutí tak představuje jeden z nejobtížnějších aspektů mapování ledovců v globálním měřítku (Paul, Hendriks 2010). Přechod od povrchu ledovce pokrytého sutí od zbytku ledovce

či od okolních hornin se neustále mění, což ztěžuje přesné vymezení hranic ledovce pokrytého sutí. Za nepřesnější metodu mapování ledovců pokrytých sutí z multispektrálních dat je všeobecně považováno ruční vytyčování, to je však pro rozsáhlá území časově náročné, proto bylo vynaloženo mnoho úsilí do vývoje sofistikovanějších technik. Tyto snahy využívají určitý stupeň fúze dat, neboť vzhledem ke spektrální podobnosti s okolním terénem nelze části ledovců pokryté sutí mapovat pouze na základě spektrálních vlastností. Pro automatickou klasifikaci ledu pokrytého sutí byly vyvinuty techniky, které kombinují multispektrální data s pomocnými soubory dat, jako jsou topografická a termální data, texturní vlastnosti nebo povrchové rychlosti pohybu ledovce (Alifu a kol. 2020).

Údaje o sklonu z digitálního povrchu terénu se využívají k identifikaci oblastí pokrytých sutí, neboť ledovcové jazyky pokryté sutí mají obvykle nízké sklony. Termální data pak využívají rozdílných tepelných vlastností supraglaciální suti ve srovnání s okolní horninou. Pokud je supraglaciální suť dostatečně tenká, podkladový led ji ve srovnání s okolními horninami ochlazuje, čímž jsou ledovce pokryté sutí odlišitelné od okolního horninového materiálu. Silnější vrstva suti však funguje jako izolační vrstva, která zakrývá chladný povrch ledu (Raup a kol. 2014). Texturní data poskytují informace o prostorových vzorcích a vlastnostech povrchu. Pomocí texturní analýzy lze odhalit rozdíly v drsnosti, uspořádání a struktuře povrchu, které mohou být charakteristické pro oblasti pokryté sutí ve srovnání s hladšími ledovcovými plochami nebo okolním terénem. Rychlosti pohybu ledovce pak pomáhají identifikovat dynamické oblasti ledovce a přispívají k odlišení ledovců pokrytých sutí od okolních skal. Přidáváním dalších příznaků však roste dimenzionalita dat a zvyšuje se komplexita problému (Zhang a kol. 2019).

2.3 Strojové učení v DPZ

V posledním desetiletí bylo vyvinuto mnoho zdokonalených metod automatického vymezení ledovců pokrytých sutí, při nichž se používají techniky strojového učení pro efektivní klasifikaci snímků dálkového průzkumu Země, neboť tyto modely dokáží zpracovávat data vysoké dimenzionality a rozlišit třídy se složitými charakteristikami. Strojové učení je podoblast umělé inteligence, která využívá statistických technik k tomu, aby počítačové systémy získaly schopnost učit se z dat, aniž by byly explicitně naprogramovány. Modely strojového učení umožňují provádět vícerozměrnou, nelineární, neparametrickou analýzu dat, přičemž postupně zlepšují svou výkonnost pomocí souboru trénovacích dat, který zachycuje podstatné vzorce a vztahy v datech, a umožňuje tak generalizaci na nová data. Strojové učení

je tedy vhodné pro řešení takových problémů, u kterých jsou naše teoretické znalosti ještě neúplné, ale pro které máme k dispozici značný počet pozorování a dalších dat (Lary a kol. 2016).

Metody strojového učení nacházejí v oblasti DPZ široké uplatnění nejen při klasifikaci ledovců, ale i v mnoha dalších oblastech, jako je detekce změn krajiny, mapování vegetace, klasifikace půdních typů nebo monitorování městské infrastruktury. Díky schopnosti rozpoznávat složité vzory v datech se strojové učení stalo klíčovým nástrojem při analýze změn krajinného pokryvu a využití krajiny. Algoritmy strojového učení jsou schopny modelovat složité charakteristiky tříd, pracovat s různými typy vstupních proměnných a nevyžadují předpoklady o rozdělení dat. Mnohé studie zjistily, že tyto metody často dosahují vyšší přesnosti než tradiční parametrické metody, jako např. klasifikátor maximální věrohodnosti, zejména při práci s komplexními daty s vysokou dimenzionalitou (Maxwell, Warner, Fang 2018).

Využitím modelů strojového učení pro klasifikaci dat DPZ se věnuje například Maxwell, Warner a Fang (2018). Autoři se s využitím dvou volně dostupných datasetů zaměřují na zhodnocení šesti různých modelů strojového učení: SVM, DT, RF, GBDT, ANN a KNN. Podle autorů totiž není možné vybrat pouze jeden univerzální model strojového učení, který by byl nejlepší pro klasifikaci veškerých dat dálkového průzkumu Země. Pro různá území a různé výzkumné problémy může být vhodný jiný model strojového učení, neboť výsledek bývá zpravidla ovlivněn výběrem různých typů krajinného pokryvu, kvalitou trénovacích dat a počtem proměnných. Autoři proto doporučují nejprve prozkoumat data a jejich příznakový prostor, posoudit překryv jednotlivých tříd a komplexnost problému a vybrat takový model, který je nejvhodnější pro zrovna zkoumané zájmové území, přičemž při výběru modelu je důležité zvážit i jeho výpočetní náročnost. V této studii se modely SVM, RF a GBDT ukázaly být robustní pro komplexní vícedimenzionální prostory a dosahují velmi dobrých výsledků ve srovnání s jinými modely, jako jsou jednoduché rozhodovací stromy nebo KNN. Autoři však zdůrazňují, že pro dosažení nejlepších výsledků klasifikace je důležitá jak optimalizace parametrů klasifikátoru, tak kvalita a velikost trénovacích dat. Pokud optimalizaci parametrů není možné provést, nebo pokud není k dispozici dostatek trénovacích dat, je vhodné zvolit RF, který je k těmto parametrům robustní. Další výhodou RF je, že ve výsledku poskytuje odhad důležitosti jednotlivých proměnných, díky čemuž lze zjistit přínos jednotlivých pásem či jiných parametrů (Maxwell, Warner, Fang 2018).

KNN

Algoritmus KNN je založen na instancích a neprobíhá v něm žádná trénovací fáze. Algoritmus předpovídá třídu na základě blízkosti cílových instancí k trénovacím datům. Příslušnost pixelu ke třídě se vyhodnocuje na základě početního zastoupení pixelů dané třídy v okolí. Před samotnou klasifikací je potřeba zvolit parametr k , který představuje počet nejbližších sousedů, a který značně ovlivňuje výkonnost modelu. Algoritmus pak v příznakovém prostoru vyhledá zkoumanému pixelu k nejbližších pixelů s využitím eukleidovské vzdálenosti a třída cílového pixelu je určena na základě majoritní třídy jeho k nejbližších pixelů (Pacheco a kol. 2021).

Nevýhodou tohoto algoritmu je, že nebere v úvahu vysokou variabilitu tříd a spoléhá na blízkost datových bodů, při špatně zvolené hodnotě k tak může výsledek obsahovat vysoký podíl šumu. Algoritmus může být výpočetně nákladný, zejména u velkých souborů dat nebo u prostorů příznaků s vysokou dimenzí. Nutnost vypočítat vzdálenosti mezi datovými body může vést k prodloužení doby zpracování (UHULAG 2024).

Algoritmy založené na rozhodovacích stromech

Rozhodovací stromy jsou spojitě acyklické neorientované grafy složené z kořenového uzlu (vytvořeného ze všech dat), sady vnitřních uzlů (podmínky pro rozdělení) a sady koncových uzlů (označení přiřazené třídy). Mají strukturu binárních stromů, kořenový uzel a všechny vnitřní uzly mají maximálně dva podřízené uzly. Rozhodovací strom je sestaven z trénovací množiny, která se skládá z objektů (pixelů) popsaných sadou příznaků a označením třídy. Při klasifikaci je pak vstupní množina dat rekurzivně rozdělována na menší dílčí části na základě nejvýznamnějších proměnných tak, aby v těchto podmnožinách převládaly prvky patřící do jedné třídy. Algoritmus rozděluje data na základě jednotlivých příznaků a jejich prahových hodnot s cílem najít takový výraz, který nejlépe rozdělí data do homogenních podmnožin. Hodnota tohoto výrazu závisí na tom, jak dobře jsou třídy separovatelné (James a kol. 2023, s. 337).

Při sestavování klasifikačních stromů se k hodnocení kvality zvoleného rozdělení obvykle používá buď Giniho index nebo entropie. Giniho index měří míru nehomogenity ve vytvořených uzlech, zatímco entropie vyjadřuje míru nejistoty v datech vzhledem k rozdělení tříd. Rozhodovací proces zahrnuje vyhodnocení všech možných rozdělení a výběr takového rozdělení, které vede největšímu snížení entropie nebo Giniho indexu, což se nazývá informační zisk. Tento postup se rekurzivně opakuje pro každou podmnožinu, dokud se úspěšně nerozdělí data do všech listů, nebo dokud není splněno pravidlo pro zastavení růstu stromu.

Jedním z pravidel zastavení je například čistota uzlu, tedy pokud všechny prvky v uzlu náleží do stejné třídy, uzel se považuje za čistý a další dělení se neprovádí. Další pravidlo zastavení je hloubka stromu, což je délka cesty od kořene k cílovému uzlu, dále pak minimální počet prvků v koncovém uzlu nebo minimální počet prvků potřebný k rozdělení uzlu (Friedl, Brodley 1997; James a kol. 2023, s. 339).

Výstupem algoritmu je výstup podobný binárnímu stromu, který je snadné interpretovat. Rozhodovací stromy jsou neparametrické a nevyžadují předpoklady týkající se rozdělení vstupních dat. Kromě toho zvládají nelineární vztahy mezi prvky a třídami. Další jejich výhodou je pak výpočetní efektivita a schopnost pracovat s menším množstvím trénovacích dat. Rozhodovací stromy mají však tendenci trpět vysokou variabilitou. To znamená, že pokud by trénovací data byla náhodně rozdělena na dvě podmnožiny, a na každou z nich by byl aplikován rozhodovací strom, výsledky mohou být zcela odlišné. Zároveň, pokud nejsou rozhodovací stromy prořezány, mohou být náchylné k přetrénování. Tyto nevýhody lze potlačit použitím ansámblových metod (Alifu a kol. 2020; James a kol. 2023, s. 342).

Ansámblové metody kombinují predikce několika jednoduchých modelů s cílem získat jediný výkonný model k dosažení přesnější a stabilnější předpovědi. Rozhodovací stromy jsou kombinovány a jejich předpovědi jsou agregovány s cílem určit nejčastější výsledek. Nejznámějšími ansámblovými metodami jsou *bagging*, známý také jako bootstrapová agregace, a *boosting* (James a kol. 2023, s. 343). *Bagging* snižuje variabilitu tím, že z původní trénovací množiny jsou opakovaně náhodně odebírány vzorky, čímž vznikne několik trénovacích množin, na kterých jsou modely nezávisle na sobě natrénovány a jejich předpovědi zkombinovány. Výsledná předpověď je určena nejčastěji se vyskytující třídou v rámci většinového hlasování napříč všemi předpověďmi. *Bagging* obvykle vede ke zvýšení přesnosti oproti predikci pomocí jediného stromu. Nevýhodou je, že bootstrapové množiny jsou pro každý strom vybírány zcela náhodně, a jednotlivé vzorky mohou být vybrány více než jednou, což způsobuje, že jednotlivé stromy mají tendenci si být navzájem dosti podobné (James a kol. 2023; Gislason, Benediktsson, Sveinsson 2006).

Vylepšením metody *bagging* je RF. V RF jsou stromy opět natrénovány nezávisle na náhodně vybraných podmnožinách trénovacích dat. Při každém zvažovaném rozdělení se však využívají pouze náhodně vybranou podmnožinu vstupních proměnných, což zajišťuje, že výsledné stromy jsou vůči sobě nekorelované. Tento klíčový rozdíl odlišuje jednoduché rozhodovací stromy od RF. Zatímco samotné stromy zvažují všechny proměnné při dělení, náhodné lesy vybírají pouze jejich podmnožinu. Při klasifikaci je prvek zařazen do té třídy, která měla během

klasifikace nejvyšší četnost napříč jednotlivými rozhodovacími stromy (James a kol. 2023, s. 346).

RF má dva hlavní hyperparametry, které je potřeba nastavit před trénováním. Počet rozhodovacích stromů a maximální počet uvažovaných proměnných použitých k rozdělování dat. Obecně platí, že počet stromů má na klasifikační přesnost malý vliv, neboť při navyšování nedochází k přetrénování modelu. Příliš velký počet však může zpomalovat proces výpočtu. Maximální počet uvažovaných proměnných při každém rozdělení pomáhá zajistit rozmanitost mezi stromy v ansámblu a jeho hodnota většinou odpovídá odmocnině celkového počtu vstupních proměnných (Belgiu, Drągų 2016).

Model RF se v DPZ při klasifikaci krajinného pokryvu využívá velmi často, a to díky přesnosti klasifikaci a své schopnosti pracovat s velmi komplexními datasey (Belgiu, Drągų 2016). Tato metoda je méně citlivá na šum nebo přeučení a dokáže odhadnout důležitost jednotlivých proměnných na základě celkového poklesu nečistoty, které daná proměnná přináší (Belgiu, Drągų 2016).

Boosting funguje podobným způsobem jako *bagging*, avšak s tím rozdílem, že stromy jsou trénovány postupně, přičemž každý nový strom je natrénován na základě informací z předchozích stromů. *Boosting* využívá tzv. učení s posilováním, kdy se nesprávně klasifikovaným vzorkům postupně zvyšuje váha (James a kol. 2023, s. 348). GBDT jsou kombinací rozhodovacích stromů a metody gradientního sestupu. Tento algoritmus vytváří stromy postupně a každý nový strom je optimalizován tak, aby korigoval chyby předchozích stromů s cílem zlepšit celkovou přesnost modelu. Zaměřuje se na případy v souboru dat, které byly předchozími stromy chybně klasifikovány, nebo které měly vysokou reziduální chybu. Gradientní sestup se využívá k minimalizaci ztrátové funkce, kdy každý nový strom je přizpůsoben zápornému gradientu této funkce. Výstupem z GBDT je vážený průměr výstupů všech rozhodovacích stromů. Algoritmus GBDT vyžaduje definici tří hyperparametrů – rychlost učení, počet stromů a velikost podvorku (Alifu a kol. 2020).

Boosting snižuje jak variabilitu, tak předpojatost klasifikace, a je velmi přesnou metodou. Má však své nevýhody: je časově náročný, a pokud není trénování včas zastaveno, vede k přeučení (James a kol. 2023, s. 348; Gislason, Benediktsson, Sveinsson 2006).

SVM

Metoda podpůrných vektorů funguje na principu hledání optimální nadroviny, která maximalizuje separaci dvou různých tříd v datovém prostoru. Cílem je minimalizovat chybu klasifikace a zároveň se maximalizovat vzdálenost mezi nadrovinou a nejbližšími datovými body, které jsou označovány jako podpůrné vektory. U nelineárních dat SVM využívá kernelové funkce k transformaci dat do vyšší dimenze, kde je možné nalézt vhodnou nadrovinu pro separaci tříd (Maxwell, Warner, Fang 2018).

ANN

Umělé neuronové sítě se skládají z vrstev neuronů, které jsou vzájemně propojené a přenášejí mezi sebou informace pomocí váhových koeficientů. Proces učení zahrnuje úpravu těchto váhových koeficientů na základě vstupních dat a očekávaných výstupů, což síti umožňuje naučit se rozpoznávat složité vzorce a vztahy v datech. Základními komponentami, které ovlivňují schopnost sítě učit se jsou vrstvy a aktivační funkce. Každá vstupní proměnná je reprezentována jedním neuronem a každá výstupní třída má svůj vlastní neuron. Kromě těchto vrstev obsahuje ANN jednu nebo více skrytých vrstev. Aktivační funkce určují, zda neuron bude aktivován a přidávají nelinearitu do modelu (Maxwell, Warner, Fang 2018).

Metoda podpůrných vektorů a umělé neuronové sítě mají několik nevýhod, které mohou ovlivnit jejich efektivitu, a proto jsou v současné době často nahrazovány konvolučními neuronovými sítěmi. Obě metody se stávají výpočetně náročnými v případě velkých datových sad a jejich výkon záleží na správném ladění hyperparametrů (Maxwell, Warner, Fang 2018). Na druhou stranu, CNN jsou schopny automaticky se učit složité prostorové vzorce, efektivněji zpracovávat velké soubory dat a poskytovat přesnější a podrobnější výsledky klasifikace díky tomu, že efektivně zachycují komplexní prostorové struktury (Chen a kol. 2023).

Strojové učení pro klasifikaci ledovců pokrytých sutí

Použitím modelů strojového učení pro klasifikaci ledovců pokrytých sutí se zabývají například Zhang a kol. (2019) a Khan a kol. (2020). Obě studie využívají data Landsat a zaměřují se na použití modelů strojového učení a využití různých příznaků k dosažení co nejlepší přesnosti při odlišení ledovců pokrytých sutí od jiných typů povrchu. Kromě spektrálních příznaků využívají spektrální indexy a texturní vlastnosti vygenerované z optických dat maticí GLCM, dále poté

teplotu zemského povrchu a topografické vlastnosti (např. nadmořská výška, sklonitost terénu) odvozené z dat digitálního výškového modelu.

Khan a kol. (2020) se zaměřují na srovnání výkonnosti různých modelů strojového učení (RF, SVM, ANN), zatímco Zhang a kol. (2019) se zaměřují na klasifikaci pomocí algoritmu RF a zaměřují se spíše na vyhodnocení důležitosti jednotlivých příznaků. Ačkoliv všechny tři modely ve studii Khana a kol. (2020) poskytli velmi dobré výsledky, RF dosáhl nejvyššího F1 skóre pro všechny tři typy povrchů ve srovnání se SVM a ANN. Vhodnost RF pro klasifikaci potvrzují i výsledky Zhang a kol. (2019), které ukázaly že RF dokáže velmi dobře odlišit různé povrchy s vysokou celkovou přesností. Kromě toho RF poskytuje informace o důležitosti jednotlivých proměnných, přičemž nejdůležitějšími se ukázaly být teplota povrchu, nadmořská výška a NDWI.

V současné době neexistuje žádná zcela jedinečná klasifikační metodika, která by umožňovala konzistentně mapovat zaledněné terény. Co dobře funguje v jednom regionu nebo při použití určité datové sady, nemusí mít stejný úspěch v jiné části kryosféry či při použití jiného zdroje dat.

2.4 Detekce změn

Mapování a monitorování krajinného pokryvu je z jednou hlavních aplikací dat DPZ a hraje zásadní roli pro odhadování změn krajinného pokryvu. Krajinný pokryv (*land cover*) představuje biofyzikální pokrytí zemského povrchu jako je např. vegetace, vodní plochy, lidská infrastruktura atd. Dálkový průzkum Země a digitální zpracování obrazu umožňují pozorování, identifikaci, mapování a hodnocení půdního pokryvu v různých prostorových, časových a tematických měřících. Identifikace typů krajinného pokryvu poskytuje základní informace pro tvorbu dalších tematických map (Chughtai, Abbasi, Karas 2021).

Díky technologiím DPZ lze monitorovat a analyzovat změny krajinného pokryvu jak na regionální, tak globální úrovni. Monitorování zemského pokryvu ve velkém měřítku je důležité, protože změny zemského pokryvu ovlivňují biofyzikální a biogeochemické vlastnosti zemského povrchu. Změny v krajinném pokryvu navíc ovlivňují klima prostřednictvím změn ve složení oxidu uhličitého a dalších skleníkových plynů v atmosféře. K monitorování změn se využívají především multitemporální satelitní snímky, které mají význam pro dlouhodobá pozorování Země za účelem výzkumu změny klimatu (Chughtai, Abbasi, Karas 2021).

Pro identifikaci změn objektů v krajině pomocí dat DPZ je základním předpokladem, že změny v chování objektů nebo jejich vlastnostech je možné zachytit snímacím zařízením. Multitemporální analýza spektrálních, výškových nebo prostorových změn je možná v případě, že všechny tyto materiálové nebo topografické změny mohou být prostorově, spektrálně nebo radiometricky rozlišeny. Při analýze změn je však nezbytné odlišit nepravé změny od skutečných. Skutečnými změnami se rozumí přeměna určité třídy krajinného pokryvu na jinou, zatímco nepravé změny indikují dočasné změny ve stavu tříd krajinného pokryvu (změna vlhkosti, změna fenologické fáze, změna osvětlení apod.) (Kääb a kol. 2014).

Data dálkového průzkumu Země se běžně používají ke zjišťování rozsahu změn, ke kterým dochází v určité geografické oblasti v průběhu času. Pro zjišťování a analýzu změn se využívají techniky detekce změn, které jsou zásadním nástrojem DPZ. Díky rozvoji technologií DPZ a zpřístupnění družicových snímků je v současnosti k dispozici velké množství dat s vysokým spektrálním, prostorovým a časovým rozlišením, což podporuje rozvoj technik detekce změn. Techniku detekce změn lze popsat jako soubor základních operací aplikovaných na analytické jednotky dvou nebo více souborů dat DPZ zachycující určitou lokalitu v různých obdobích (Lu a kol. 2004).

Cíle detekce změn DPZ zahrnují identifikaci geografické lokalizace změn, určení typu změn, kvantifikace změn a posouzení přesností výsledků techniky detekce změn (Hussain a kol. 2013). Klíčovou úlohou technik detekce změn je identifikace významných změn, ke kterým v dané lokalitě ve sledovaném období došlo. Na základě těchto změn je pak možné vytvořit změnovou mapu, ve které lze jasně odlišit oblasti, kde došlo ke změnám od těch, které zůstaly stabilní. Jedním z náročných úkolů je oddělit významné změny od nevýznamných. Významnost změn se liší podle konkrétní aplikace, což vyžaduje pečlivý výběr vhodné techniky detekce změn (Lu a kol. 2004).

Různé techniky detekce změn se běžně používají pro monitorování stavu životního prostředí, jako jsou například dopady přírodních katastrof, urbanizace a suburbanizace, vegetační změny, desertifikace, odlesňování či dopady klimatických změn. Tyto změny krajinného pokryvu a využití půdy, vyvolané lidskou činností a přírodními jevy, způsobily mnoho problémů v oblasti klimatických změn, přírodních rizik a globálního oteplování. Včasná a přesná identifikace těchto změn poskytuje proto základ pro pochopení vztahů a interakcí mezi člověkem a přírodními jevy (Kumar, Arya 2021).

V průběhu let byla vyvinuta celá řada metod a technik pro analýzu dat DPZ a novější metody jsou stále ve vývoji. Vzhledem k velkému množství navrhovaných technik se je různí výzkumníci pokusili rozdělit do různých kategorií, aby téma zjednodušili a systematizovali. Přehled jednotlivých technik poskytují například autoři Lu a kol. (2004), Husssin a kol. (2013), Tewskubury a kol. (2015), Salah a kol. (2020), Chugtai, Abbasi a Karas (2021) či Kumar a Arya (2021). K historicky nejznámějším technikám patří například techniky založené na vizuálním porovnání, techniky založené na obrazové algebře, techniky založené na transformaci nebo klasifikaci obrazu.

Vizuální porovnání obrazu

Obecně je vizuální interpretace počátečním krokem před výběrem vhodné metody detekce změn. Na základě vizuálního porovnání lze získat představu o prostorovém rozložení prvků a jejich struktuře v zájmové oblasti. Hrubý odhad změn lze provést buď vizuálním porovnáním dvou multispektrálních snímků, či pomocí barevných syntéz multitemporálních snímků. Tento přístup vyžaduje plné využití znalostí a dovedností analytika, a neposkytuje kvantitativní informace o změnách (Lu a kol 2004; Kumar, Arya 2021).

Metody založené na obrazové algebře

K určení rozsahu změny se v technikách založených na obrazové algebře používají algebraické výrazy. Patří k nim například rozdíl hodnot obrazových dat, výpočet poměru nebo analýza změnového vektoru, regrese obrazu a další (Kääb a kol. 2014).

Výpočet rozdílu hodnot obrazových dat je nejčastěji používanou metodou. Tato technika spočívá v odečtení obrazu jednoho časového období od jiného. Tyto operace poskytují obraz zobrazující rozdíly v odrazivosti mezi dvěma snímky, které by měly odrážet změny v území. Výsledné hodnoty pixelů blíží se nule označují nezměněné oblasti, zatímco kladné či záporné hodnoty označují oblasti změn. Tato metoda může fungovat pouze v případech, kdy existuje velký a konzistentní rozdíl mezi hodnotami pixelů odpovídajících zájmovým prvkům, a kdy neexistují jiné změny ve stavu povrchu jedné třídy krajinného pokryvu (nepravé změny). Kromě multispektrálních snímků, lze využít například i výškové či texturní produkty, indexy atd. (Lu a kol. 2004; Kumar, Arya 2021).

Další metodou je analýza změnového vektoru. Pro každou třídu reprezentovanou pixely se zkoumaná data analyzují pomocí dvou spektrálních pásem, která se proti sobě vykreslí. Vektor změn pak spojuje výsledné body v příznakovém prostoru těchto pásem. Pokud nedošlo

k žádným změnám mezi dvěma měřeními, graf má rozptýl blízky diagonále. Pokud body leží mimo diagonálu, typ změn je charakterizován směrem vektoru a jeho úhlem vůči počátečnímu směru. Identifikace významných změn pak vyžaduje stanovení prahové hodnoty (Lu a kol. 2004; Kumar, Arya 2021).

Metody založené na obrazové algebře se snadno implementují, je však obtížné zvolit správnou prahovou hodnotu, na základě, které je možné identifikovat změněné oblasti. Problémem prahování je, že kromě skutečných změn krajinného pokryvu, mohou rozdíly obsahovat také vnější vlivy způsobené úhly slunce, atmosférickými podmínkami či vlhkostí půdy. Volba prahové hodnoty je závislá na konkrétní scéně a schopnostech analytika (Käab a kol. 2014; Kumar, Arya 2021).

Metody založené na transformaci obrazu

Nejnámější technikou založenou na transformaci obrazu je PCA. Metoda PCA se při detekci změn používá již mnoho let díky své jednoduchosti a schopnosti rozšířit informace o změnách. Metoda PCA využívá kovarianční nebo korelační matici k transformaci dat na nekorelované komponenty. Vlastní vektory výsledné matice jsou seřazeny sestupně, přičemž první hlavní komponenta představuje maximální variabilitu v datech. Tím je zajištěno, že výsledné proměnné jsou nekorelované a zachycují co nejvíce klíčových informací z původních dat (Lu a kol. 2004).

Existují dvě hlavní metody využití PCA pro detekci změn. První je kombinace dvou snímků do jednoho souboru, a následná aplikace PCA a analýza odvozených komponent pro získání informací o změnách. Druhou možností je aplikace PCA samostatně na každý snímek a porovnání rozdílů mezi scénami. Výběr počtu komponent pro zobrazení změn a volba vhodného prahu může být složitá, pokud se v oblasti nachází různé typy změn (Kumar, Arya 2021).

Dalšími metodami jsou pak transformace Tasseled Cap, Gram-Schmidtova transformace a Chí-kvadrátová transformace. Jednou z velkých výhod těchto metod je snížení redundance dat a zdůraznění rozdílných informací v odvozených složkách. Tyto techniky však neposkytují podrobné matice změn. Další nevýhodou je obtížná interpretace a označování tříd v transformovaných snímcích (Lu a kol. 2004; Kumar, Arya 2021).

Metody založené na klasifikaci

Metody založené na klasifikaci zahrnují například postklasifikační porovnání nebo přímou multitemporální klasifikaci změn. Využitím technik založených na klasifikaci lze dosáhnout lepších výsledků, avšak tyto výsledky jsou ovlivněny výběrem, kvalitou, přesností a úplností trénovacích dat. Velkou výhodou těchto technik je, že nejsou tolik ovlivněny vnějšími faktory jako jsou např. atmosférické podmínky (Kääb a kol. 2014; Kumar, Arya 2021).

Velmi oblíbenou a široce používanou metodou je postklasifikační porovnání. Dva snímky pořízené v různém čase jsou nezávisle na sobě klasifikovány a poté porovnány. Změny mezi oběma daty lze vizualizovat pomocí matice změn, která pro obě data udává počet pixelů v každé třídě, a proto by pro každou klasifikaci měly být vytvořené stejné tematické třídy. Tato metoda poskytuje kompletní podrobné informace o změnách „z-na“ pro každou třídu. Výsledná přesnost této techniky se odvíjí od kvality vstupních dat, tedy od přesnosti klasifikace (Lu a kol. 2004).

Namísto porovnání výsledků po klasifikaci lze změny zjišťovat také slučováním multitemporálních dat. Jednotlivá pásma multitemporálních dat lze spojit do jednoho nového vícevrstvého datového souboru, který se klasifikuje. V rámci klasifikačního postupu je definován soubor trénovacích dat, jehož třídy představují stabilní plochy a jednotlivé kategorie změn. Klasifikací se pak získá soupis stabilních oblastí a oblastí, kde došlo ke změně. Pro binární detekci změn pak lze připravit soubor trénovacích dat označujících pouze změněné a nezměněné oblasti. Výhodou tohoto přístupu je potřeba pouze jedné klasifikace, avšak odvození trénovacího souboru může být náročné a vyžaduje dobrou znalost studované oblasti. (Kääb a kol. 2014, Kumar, Arya 2021).

Proces výběru klasifikátoru je rovněž nezbytným pro přesnou identifikaci změn, neboť přístupy založené na klasifikaci jsou závislé na výkonu klasifikátoru. Pro klasifikaci lze využít různé algoritmy, od řízené klasifikace po neřízenou. K nejčastěji používaným patří například klasifikátor maximální věrohodnosti, SVM, DT, RF či ANN. V posledních letech se pro klasifikaci stále častěji využívají techniky hlubokého učení, například CNN (Kumar, Arya 2021).

Hybridní metody

Hybridní techniky detekce změn představují kombinaci dvou nebo více výše zmíněných technik. Jedná se například o metodu binární masky, kdy jsou změněné pixely označeny na

základě rozdílu hodnot obrazových dat, a následně jsou tyto pixely klasifikovány pomocí řízené klasifikace. Podobně lze nejprve multitemporální soubor transformovat pomocí analýzy hlavních komponent a použít jej pro přímou klasifikaci změn. Pro detekci změn lze například využít geografické informační systémy pro kombinaci dat z různých zdrojů či senzorů (Lu a kol. 2004).

Pokročilé metody

Pokročilé metody často zahrnují převádění hodnot odrazivosti na fyzikální parametry. Jedná se například o analýzu spektrální směsi, Li-Strahlerův model odrazivosti či model biofyzikálních parametrů (Kumar, Arya 2021).

V posledních letech se do popředí výzkumu při vývoji nových metod detekce změn dostala integrovaná technologie umělé inteligence, zejména modely strojového a hlubokého učení. Různé techniky detekce změn mají své přednosti a žádný konkrétní přístup není optimální a použitelný pro všechny případy. Výkonnost metody detekce změn závisí na schopnosti adekvátně se vypořádat s výchozí statistickou situací, ale také zohlednit variabilitu v jednom měřítku (např. sezónním), a zároveň umět interpretovat změny v jiném měřítku např. směrovém. V praxi se proto často porovnávají různé techniky s cílem najít nejlepší výsledek detekce změn pro konkrétní aplikaci (Kumar, Arya 2021).

Při výběru techniky detekce změn je potřeba zvážit několik aspektů řešeného problému a to:

1) použitá vstupní data

- letecké snímky, optické multispektrální snímky, data SAR, odvozená data (digitální výškové modely, spektrální indexy, texturní vlastnosti), vektorová data, bodová mračna či různé kombinace dat z různých zdrojů

2) časové rozlišení

- bi-temporální nebo multi-temporální

3) prostorová mapovací jednotka

- pixelové a subpixelové metody, metody založené na objektech (segmentace obrazu) nebo na specifických rysech (spektrální indexy, temporální, texturní vlastnosti)

4) způsob detekce změn

- binární změny (tj. změna vs. žádná změna) nebo získání podrobných informací o změnách (směrové změny – „z-na“)

- 5) typ změn které mají být zohledněny
 - monitorování dlouhodobých trendů či sezónních výkyvů, technické změny vs. změny třídy krajinného pokryvu
- 6) pořadí operací
 - předklasifikační porovnání, přímá klasifikace, postklasifikační porovnání

Hodnocení změn

Hodnocení změn zahrnuje všechny operace, které se na získané mapy změn aplikují za účelem jejich vyhodnocení. Tato fáze zahrnuje jak interpretaci změn, tak posouzení přesnosti. Interpretaci změn lze provést na základě změnové mapy, ze které lze vypočítat plošné zastoupení změn. Hodnocení přesnosti může být výsledkem kvalitativního posouzení (např. srovnání se situací v terénu) nebo kvantitativního posouzení, jehož cílem je porovnání výsledků s validačními daty a kvantifikace rozdílu mezi nimi (Chugtai, Abbasi, Karas 2021).

Metody hodnocení přesnosti se používají k ověření přesnosti technik založených na klasifikaci. Výsledek se odvíjí především od velikosti a kvality trénovacích a validačních dat a od zvoleného klasifikačního algoritmu, dále pak i od schématu výběru vzorků a prostorové autokorelace (Olofsson a kol. 2014).

Nejběžnější technikou je chybová matice založená na porovnání výsledků klasifikace s validačními daty nebo daty naměřenými v terénu. Jedná se o čtvercovou matici, která obsahuje tolik řádků a sloupců, kolik tříd obsahuje legenda posuzované klasifikace. Řádky chybové matice představují přiřazené třídy klasifikací a sloupce třídy odpovídající validačním datům. Na hlavní diagonále chybové matice se nachází správně klasifikované vzorky, zatímco mimo diagonálu se nachází chyby z opomenutí nebo z nesprávného zařazení. Chyby z opomenutí korespondují s hodnotami ve sloupcích mimo hlavní diagonálu – jedná se o pixely, které jsou ve skutečnosti danou třídou, avšak v klasifikaci byly zařazeny do tříd jiných. Chyby z nesprávného zařazení korespondují s hodnotami v řádcích mimo hlavní diagonálu – je to počet pixelů, které byly nesprávně zařazeny do dané třídy, ale ve skutečnosti patří do jiné třídy. Chyby mohou být důsledkem procesu mapování změn, ale i důsledkem předpojatosti analytika a použitých dat (Olofsson a kol. 2014; Chugtai, Abbasi, Karas 2021).

Z matice chyb lze odvodit různé metriky pro hodnocení kvality techniky detekce změn. Celková přesnost udává podíl správně klasifikovaných vzorků z celkového počtu vzorků v souboru dat a poskytuje odhad celkové kvality klasifikace. Celková přesnost však nebere v potaz četnosti jednotlivých tříd. Pokud datový soubor obsahuje třídy s nerovnoměrným

počtem, může model zvýhodňovat třídu s větším počtem vzorků na úkor třídy s menším počtem vzorků, a v takovém případě může být vysoká celková přesnost matoucí. K posouzení kvality se proto používají další dvě metriky: zpracovatelská a uživatelská přesnost (Oloffson a kol. 2014, Chugtai, Abbasi, Karas 2021).

Uživatelská přesnost udává pravděpodobnost, s jakou pixel zařazený do dané třídy tuto třídu skutečně reprezentuje. Zpracovatelská přesnost vyjadřuje pravděpodobnost, s jakou bude pixel zařazený do té třídy, kterou skutečně reprezentuje. Zpracovatelskou a uživatelskou přesnost lze vypočítat pro každou třídu zvlášť anebo je zprůměrovat napříč všemi třídami pomocí F1 skóre (Maxwell, Warner, Guillén 2021).

F1 skóre je vyvážená metrika, která zohledňuje spolehlivost a úplnost klasifikace. K výpočtu lze využít makroprůměrování nebo vážené průměrování. Makroprůměrování zachází s každou třídou stejně a využívá se v případě nevyváženého datového souboru. Četnost tříd se nebere v úvahu, a všem jsou rovnoměrně přiřazeny stejné váhy. Pro každou třídu se se nejprve spočtou správně klasifikované vzorky, chyby z nesprávného zařazení a chyb z opomenutí, a následně se vypočítá aritmetický průměr zpracovatelské a uživatelské přesnosti. Makroprůměrování se používá v případech, kdy jsou všechny třídy stejně důležité a chceme zjistit, jak dobře si klasifikátor vede v průměru napříč nimi. Vážené průměrování zohledňuje vyváženost tříd, kdy každé třídě je přiřazena váha na základě jejího zastoupení v celém datasetu. Následně se pak vypočte vážený průměr F1 skóre. Tento přístup je vhodný v případě nevyváženého datasetu, kdy třídám s velkým počtem vzorků chceme přiřadit větší důležitost (Maxwell, Warner, Guillén 2021).

Detekce změn v zaledněných horských oblastech

V zaledněných oblastech techniky detekce změn slouží ke zjišťování, zda ledovec ustoupil, a pokud ano, tak o kolik, zda se jeho plocha na konci hydrologického roku výrazně liší od stavu před deseti lety, jak se změnila plocha ledovců pokrytých sutí, zda v oblasti vznikla supraglaciální jezera nebo jak se změnila poloha rovnovážné linie. Kromě toho lze techniky detekce změn využít ke sledování změn výšky ledovce nebo k odhadu změn hmotnostní bilance. Ke zjišťování změn v zaledněných oblastech je možné využít několik přístupů, od jednoduchého porovnání až po metody strojového či hlubokého učení (Kääb a kol. 2014).

V zaledněných oblastech slouží techniky detekce změn k určování, zda ledovec ustoupil a o kolik, nebo zda se jeho plocha na konci hydrologického roku výrazně liší od stavu před deseti lety. Tyto techniky umožňují také sledovat změny v rozloze ledovců pokrytých sutí

a zjišťovat, zda v těchto oblastech vznikají supraglaciální jezera. Kromě toho lze detekční metody využít ke sledování změn výšky ledovce nebo k odhadu změn hmotnostní bilance. Pro sledování změn v zaledněných oblastech existuje několik přístupů, od jednoduchého porovnání po metody strojového či hlubokého učení (Kääb a kol. 2014).

Metodami pro detekci plošných změn ledovců se zabývají například Pellikka a Rees (2010), kteří popisují různé způsoby kvalitativního a kvantitativního hodnocení a vizualizaci plošných změn. Autoři uvádějí dvě hlavní metody, a to animaci multitemporálních snímků pro vizuální porovnání, a překrytí ledovcových map pro vizualizaci a výpočet plošných změn. Pro rychlou a účinnou analýzu změn lze použít multitemporální snímky a syntézu v nepravých barvách. Vizuální porovnání multitemporálních snímků vyžaduje pouze relativní porovnání nad několika kontrolními body a pomocí animace lze jasně sledovat změny. Pro kvantitativnější posouzení plošných změn lze vytvořit obrysy ledovců. Na základě těchto zákresů lze zjistit rozlohu ledovce tak že se počet pixelů pokrývajících ledovec vynásobí prostorovým rozlišením pixelu. Změny plochy potom lze zjistit odečtením rozlohy ledovce v jednom roce od rozlohy ledovce v jiném roce. Tyto změny pak lze vizualizovat překrytím jednotlivých map při použití technik GIS. Z obrysů ledovce pak lze pozorovat vývoj hranic ledovce v čase.

Ruční, poloautomatické či automatické zakreslování obrysů ledovce patří k nejpoužívanějším metodám pro zjišťování plošných změn ledovců v horských oblastech. Ve studiích ji využívají například Burns a Nolin (2014) a Masiokas a kol. (2020) pro zjišťování plošných změn ledovců v Andách a Schmidt a Nüsser (2017) a Rashid a kol. (2021) v Himalájích. Zákresy obrysů různých ledovců jsou také dostupné v GLIMS nebo RGI. Obrysy ledovců však neposkytují úplné informace o změnách, ke kterým ve sledované oblasti dochází. Pro pochopení dynamiky změn, ke kterým v zaledněných oblastech dochází, je důležité porozumět procesům, které se při změnách dějí. Například, jak se v čase mění výška sněhová linie, jak se v čase mění plocha ledovce pokrytá sutí, nebo jak se mění hydrologické poměry v oblasti. Změnové mapy jsou tak účinným nástrojem pro monitorování změn v zaledněných horských oblastech, neboť zahrnují všechny typy povrchů v okolí ledovců.

Technikami detekce se změn zabývají Kääb a kol. (2014), kteří uvádí několik možností, jak využít multitemporální datové soubory DPZ pro zjišťování změn krajinného pokryvu v zaledněných oblastech. Multitemporální topografické soubory lze využít pro monitorování výškových změn či posunů v terénu, což přispívá k pochopení a modelování dynamiky ledovců. Pro detekci plošných změn se pak používají optická multispektrální data, kdy detekce spočívá v překrývání snímků z různých dat. Kääb a kol (2014) potom uvádí šest různých

technik detekce změn pro detekci zaledněných oblastí (post klasifikační porovnání, přímá multitemporální klasifikace změn, multitemporální analýza hlavních komponent, multitemporální barevné syntézy, algebraické výrazy, analýza změnového vektoru a analýza změnové osy), vysvětlují jejich základní principy a hodnotí jejich výhody a nevýhody a konkrétní možnosti využití. Autoři se však nevěnují konkrétnímu použití ani hodnocení přesnosti.

Pro detekci změn krajinného pokryvu v zaledněných oblastech se využívají především techniky založené na klasifikaci, konkrétně postklasifikační porovnání s tím, že důraz je kladen na volbu vhodného klasifikátoru nebo na jednotku analýzy. Raza a kol. (2012) se zaměřují na porovnání pixelové a objektové klasifikace pro detekci změn v zaledněných horských oblastech v Himalájích s využitím snímků Landsat. Autoři kromě hodnot odrazivosti použili jako pomocná data NDSI a NDVI a jejich výsledky ukazují, že objektová klasifikace je efektivnější a časově méně náročná. K podobným závěrům došli i Nijhawan, Garg a Thakur (2016), kteří se zaměřili na porovnání klasifikačních technik pro detekci změn ledovců v Himalájích pomocí multispektrálních snímků. Autoři vyzkoušeli sub-pixelovou klasifikaci, řízenou klasifikaci na základě indexů a objektovou klasifikaci, přičemž objektová klasifikace se v porovnání s ostatními dvěma přístupy ukázala jako nejefektivnější. Obě studie se však zaměřují především na porovnání různých klasifikačních přístupů na základě různých jednotek analýzy, a pro detekci změn používají výhradně postklasifikační porovnání. Nutno také podotknout že v obou sledovaných oblastech se nachází ledovce bez suťové pokrývky.

Detekci změn ledovců pokrytých suti z multispektrálních optických dat se zabývají Ambinakudige a Intsiful (2022), kteří využívají různých algoritmů strojového učení pro klasifikaci ledovců pokrytých suti v Kolumbii. Autoři pracují se sedmi typy krajinného pokryvu, a to sníh, led, suť, voda, skalnatý povrch, vegetace a stín, přičemž pro dobrou odlišitelnost těchto tříd využívají kromě spektrální odrazivosti povrchu také spektrálních indexů (NDVI a NDSI). Autoři nejprve natrénovali a otestovali algoritmy SVM, RF a MLC na snímku z roku 2020. Všechny tři algoritmy klasifikovaly snímek s přesností více než 99 %, přičemž klasifikátor SVM dosáhl vyšší přesnosti pro zaledněné oblastech pokryté suti, proto byl použit pro klasifikaci snímků z ostatních let. Detekci změn autoři potom provádějí na základě postklasifikačního porovnání.

Sood a kol. (2020) využívají pro detekci změn sněhové/ledové pokrývky změn v Himalájích analýzu změnových vektorů. Autoři se zaměřují především na identifikace přechodových zón, které zahrnují smíšené pixely, k čemuž využívají subpixelové klasifikace založené na lineárním

spektrálním mísení. Cílem autorů je identifikovat rozsah a směr změn mezi dvěma multitemporálními snímky s využitím analýzy vektorů změn na subpixelové úrovni. Kromě optických senzorů Landsat využívají i termální pásmo a digitální výškový model ASTER. Výstupem detekce změn na základě analýzy změnového vektoru jsou mapy rozsahu změn, zobrazující oblasti, kde došlo ke změnám a změnové mapy zobrazující směr změn.

Žádné studie se však nezaměřují na porovnání různých technik detekce změn pro zaledněné oblasti, jako např. Berberoglu a Akin (2009), kteří se zaměřují na posouzení účinnosti čtyř různých technik při detekci změn krajinného pokryvu ve středomořském prostředí, nebo Deng a kol. (2008) a Kamh a kol. (2011), kteří porovnávají různé techniky detekce změn pro urbánní oblasti.

3 Data a metodika

3.1 Zájmové území

Ostrov Disko, známý také pod názvem *Qeqertarsuaq* se nachází západně od Grónska v Baffinově zálivu. Jedná se o největší Grónský ostrov o rozloze 8 575 km².



Obrázek 2: Lokace ostrova Disko

Krajina je tvořena převážně vysokými náhorními plošinami (typicky 800–1 200 m n. m.) s kuželovitými vrcholky pokryté ledovcovou pokrývkou, hlubokými údolími ve tvaru písmene U a fjordy. Nejhornatější je severní a severovýchodní část ostrova, přičemž nejvyšší vrchol ostrova leží ve výšce 1 905 m n. m. V současné době je až 20 % plochy ostrova zaledněno. Centrální část ostrova pokrývají dva hlavní ledovce, Sermersuaq (Storbræen) a Bræpasset, celkem se však na ostrově nachází přes 1 000 ledovců, ledovcových čepic a firnových polí o přibližné rozloze 1 610 km². Nezaledněnou krajinu charakterizují třetihorní čedičové plošiny. Svahy údolí se vyznačují příkrými skalními stěnami s nahromaděnou sutí na jejich úpatí. Kvůli vysoké míře zvětrávání čedičových hornin na ostrově dochází k intenzivní tvorbě sutí, a proto se jak na povrchu, tak uvnitř samotných ledovců akumulují úlomky hornin. Ledovcové morény jsou proto tvořeny převážně materiálem připomínajícím štěrk. Vzhledem k intenzivní produkci sutí jsou v oblasti časté také skalní ledovce, které se vyskytují jak ve vnitrozemí, tak na východním pobřeží ostrova. Skalní ledovce jsou horninové úlomky tmelené ledem, pomalu se svažující údolími. Podle jejich tvaru je lze rozdělit na lalokovité a jazykovité skalní ledovce,

příčemž lalokovité skalní ledovce se nachází spíše podél strmých stěn údolí, kdežto jazykovité skalní ledovce se nachází spíše v údolních kotlinách (Humlum, 1982, 1977, 1988, 1998).

Západní a jihozápadní část ostrova se vyznačuje polárním podnebím s oceánským vlivem a jeho klima je ovlivňováno chladným a suchým polárním vzduchem, zatímco ve střední a severovýchodní části ostrova panuje spíše kontinentální klima. Průměrná roční teplota vzduchu za období 1991–2011 byla $-3,0\text{ °C}$ v okolí města Godhavn. Nejchladnějším měsícem byl březen ($-14,0\text{ °C}$) a nejteplejším červenec ($7,9\text{ °C}$) (Hollesen a kol. 2015).

Průměrný roční úhrn srážek je 400 mm, z čehož přibližně 60–70 % jsou srážky sněhové. V okolí města Godhavn je trvalá sněhová pokrývka registrována od konce září do konce května a dosahuje v průměru 16 cm. Převládající vítr je východní a severovýchodní, s výjimkou období od května do srpna, kdy převládají jihozápadní a západní větry. Kvůli proudění vlhkého mořského vzduchu z jihozápadu Davisova průlivu spadne nejvíce srážek od června do prosince. Průměrná rychlost větru u hladiny moře dosahuje maximálních hodnot na podzim a začátkem zimy, minimálních hodnot v únoru až dubnu. Slunce je pod obzorem od konce listopadu do poloviny ledna a od poloviny května konce července nastává období půlnočního slunce (Hollesen a kol. 2015).

Na ostrově Disko se nenachází žádná velká jezera, pouze několik málo řek, u kterých se nachází významné nížinné oblasti s mokřady. Zdrojem vody je přímý odtok z dešťových srážek a každoročního tání sněhu, podzemní vody v čedičových podložích, odtávání ledovců a dlouholeté sněhové pokrývky. V ústí mnoha velkých údolí se nacházejí solné bažiny (Christiansen, 1995).

V pobřežních oblastech se vyskytuje nesouvislý permafrost, zatímco ve vnitrozemí je permafrost souvislý, s čímž souvisí i četnost skalních ledovců a výskyt otevřeného systému hydrolakolitů, které jsou geomorfologickými ukazateli přítomnosti rozsáhlého permafrostu. Mocnost permafrostu na ostrově Disko je odhadována na zhruba 100–200 m (Christiansen, Humlum 2000).

Charakteristickým rysem ostrova Disko je množství termálních pramenů. Nejteplejší pramen má teplotu okolo 18 °C . Několik pramenů obsahuje radioaktivní vody nebo vody bohaté na minerály, zatímco většina je téměř čistá. Teplo z pramenů vytváří dobré podmínky pro floru i faunu, která je zde poměrně pestrá. Na arktické poměry má ostrov velmi vysokou biodiverzitu včetně několika vzácných druhů. Mimořádnou biologickou rozmanitost lze přičíst různým geologickým a půdním podmínkám, výskytu termálních pramenů a tomu, že se v území

nacházejí jak oceánské, tak kontinentální oblasti (Hjartarson, Armannsson 2010). Vegetace v nízké nadmořské výšce je tvořena mechovými vřesovišti nebo vřesovišti se zelenými zakrslými křovinami a malými rašeliništi. Dominantními dřevinami jsou vrba sívá (*Salix glauca*), vrba arktická (*Salix arctica*) nebo kasiope čtyřhranná (*Cassiope tetragona*). Nejbohatším typem vegetace jsou bylinné stráně, které se nacházejí na jižně orientovaných svazích a lze na nich najít například běloprstku bělavou (*Leucorchis albida*), vemeník severní (*Plantanthera hyperborea*) nebo bradáček srdčitý (*Listera cordata*). Ve vyšších nadmořských výškách se vyskytují vrchoviště. Pouze na několika místech se vyskytují druhově chudá sněhová výležiška (Callaghan, Christiensen, Jantze 2011).

Počet druhů ptáků hnízdících ve vnitrozemí je na ostrově Disko poměrně nízký. Z hlediska ochrany přírody patří k nejvýznamnějším druhům suchozemských ptáků husa běločelá (*Anser albifrons*). Podél pobřeží se nacházejí četné hnízdní kolonie mořských ptáků. Většina kolonií je poměrně malá, čítající desítky až stovky ptáků. Na jednom místě často hnízdí více druhů, jako například buňák lední (*Fulmarus glacialis*), kormorán velký (*Phalacrocorax carbo*), kajka mořská (*Somateria mollissima*), racek šedý (*Larus hyperboreus*), racek polární (*Larus glaucooides*) a další (Wegeberg, Boertmann 2016, s. 51).

Fauna suchozemských savců ostrova Disko je podobná západnímu Grónsku, neboť se zde vyskytují převážně druhy jako liška polární (*Alopex lagopus*), zajíc polární (*Lepus arcticus*) a sob polární (*Rangifer tarandus*). Mezi mořské savce vyskytující se ve vodách poblíž ostrova Disko patří mrož lední (*Odobenus rosmarus*), čtyři druhy tuleňů a také několik druhů velryb. Od jara do podzimu se kolem ostrova vyskytuje plejtvák myšok (*Balaenoptera physalus*), plejtvák malý (*Balaenoptera acutorostrata*), keporkak (*Megaptera novaeangliae*) nebo velryba grónská (*Balaena mysticetus*) (Wegeberg, Boertmann 2016, s. 54).

Na jižním pobřeží ostrova se nachází přístav Qeqertarsuaq známý také pod názvem Godhavn. Jedná se o nejvíce osídlenou oblast na ostrově a k roku 2023 zde žije 845 obyvatel, z nichž většinu tvoří Kalaallit (grónští Inuité) (Statistics Greenland 2023, s. 5). Převládajícím jazykem místních Inuitů je západogrónský dialekt *kalaalisut* (grónský jazyk Inuitů), druhým jazykem většiny obyvatel je dánština (Caulfield 1993).

Hospodářství na ostrově Disko je založeno na rybolovu, lovu, zpracování mořských plodů, roste ale i význam cestovního ruchu. Lidé žijící ve městě Godhavn využívají k lovu a rybolovu pevninu, moře a mořský led (Ramage a kol. 2022). Komerční rybolov představuje nejdůležitější vývozní odvětví. V hlubších mořských vodách rybolov zahrnuje krevetku severní (*Oandalus*

borealis) a platýse černého (*Reinhardtius hippoglossoides*). V pobřežních vodách se loví okouni (*Sebastes*), platýs obecný (*Hippoglossus hippoglossus*), žralok malohlavý (*Somniosus microcephalus*), hlavoun severní (*Macrourus berglax*). Ve sladkých vodách se vyskytují pouze dva druhy ryb, a to siven severní (*Salvelinus alpinus*) a koljuška tříostná (*Gasterosteus aculeatus*) (Wegeberg, Boertmann 2016).

V blízkosti města se nachází Arktická stanice, kterou od roku 1906 provozuje Kodaňská univerzita a která zajišťuje rozsáhlý přírodovědný výzkum na ostrově (Hjartarson, Armannsson 2010). Na základě dat z Arktické stanice lze na ostrově monitorovat dopady klimatických změn. Změny klimatu jsou dominantní hybnou silou mnoha environmentálních, ekonomických a společenských změn na ostrově Disko i v celé Arktidě. Dopadům změny klimatu na arktické ekosystémy je věnována stále větší pozornost, neboť globální oteplování je v arktických oblastech čím dál tím výraznější. Variabilita klimatu se za posledních 20 let výrazně zvýšila, klíčové ukazatele jako je teplota, srážky, povětrnostní jevy, sněhová pokrývka, tloušťka a rozsah mořského ledu a tání permafrostu, ukazují, že v Arktidě dochází k rychlým a rozsáhlým změnám (AMAP, 2021).

Teplota vzduchu v Arktidě roste až třikrát rychleji než celosvětový průměr, což potvrzují i teplotní trendy na ostrově Disko, které naznačují celkový nárůst teploty o 0,2 °C za rok, s vyšším nárůstem v zimě (0,4 °C za rok) ve srovnání s létem a podzimem (0,1 °C za rok). Při porovnání dat z let 1991–2000 a 2002–2011 bylo zjištěno i významné prodloužení délky vegetačního období, neboť došlo k úbytku průměrné počtu dní s teplotami trvale pod bodem mrazu. S tím souvisí i zkrácení doby trvalé sněhové pokrývky, což má dopad na stabilitu půd v krajině. Teploty půdy v zimě v posledních letech více souvisejí s teplotami vzduchu, což je důsledek klesající výšky sněhu. Při porovnání dat z let 1991–2000 a 2002–2011 je rovněž zřejmé, že zimní a jarní teploty půdy se výrazně oteplily navzdory menšímu množství sněhu (Holleisen a kol. 2015). Od počátku 20. století také došlo na ostrově Disko ke zvýšení intenzity a nárůstu ročních srážek přibližně o 20 %, a k častějším a extrémnějším povětrnostními podmínkám (Yde, Knudsen 2007).

V okolí ostrova Disko se za období 1991–2011 pokrytí mořským ledem snížilo přibližně o 50 %, přičemž se mořský led v průběhu sezóny tvoří později a mizí dříve (Holleisen a kol. 2015). Zmenšení rozlohy mořského ledu se projevilo výraznými změnami v dostupnosti tuleňů grónských a v migraci populací kachen divokých (Goldhar, Ford 2010).

Oteplování přispívá k destabilizaci permafrostu a k ústupu ledovců. Území ovlivněné degradovaným permafrostem se označuje jako termokrast – tající vrstva vytváří jezírka, mokřady, pukliny a trhliny, které se erozí zvětšují. Půda se stává měkčí, což zvyšuje náchylnost k erozi, a velké plochy půdy se tak mohou sesouvat dolů. Infrastruktura (budovy, silnice, potrubí atd.) umístěná v takových oblastech se stává nestabilní, je narušena nebo poškozena, propadá se do země nebo je jednoduše zničena (Ramage a kol. 2022).

Kromě teploty jsou dalšími faktory ovlivňující ústup ledovců změny zimních srážek, sněhové pokrývky a změny povětrnostních podmínek. Ledovce na ostrově Disko ustupují již od počátku 20. století. Mezi lety 1953 a 2005 došlo u 70 % ledovců k ústupu. Nejcitlivější na změny klimatu jsou ledovce s ablačními plochami obrácenými směrem na jih až severozápad, pokrývající plochu nad 5 km² a mající nadmořskou výšku pod 800 m. Tyto ledovce jsou zranitelnější vůči slunečnímu záření, povětrnostním podmínkám, vyšším letním teplotám vzduchu a většímu počtu dnů s teplotami nad nulou. Ústup ledovců způsobuje zvyšování hladiny moří, pobřežní erozi, ledovcové záplavy a laviny v horských oblastech, a narušuje základních zásoby sladké vody (Yde, Knudsen 2007).

Klimatické změny mají dopad na všechny složky kryosféry včetně permafrostu, což má následné důsledky pro obyvatele a ekosystémy v celé Arktidě (Ramage a kol. 2022). Obyvatelstvo ostrova Disko je obzvláště citlivé na proměnlivost a změny klimatu. Mnoho obyvatel totiž žije tradičním způsobem života, a pro zajištění potravin a příjmů domácností jsou pro ně důležité činnosti jako je lov a rybolov, sběr a sklizeň, stejně tak umění a řemesla. Mnoho obyvatel je tedy závislých místních potravinách a na samozásobitelství v rámci izolované komunity. Tání permafrostu, zmenšování rozlohy mořského ledu, vysoká proměnlivost počasí a nedostatek živočišných zdrojů ohrožuje bezpečnost, zdraví a životní pohodu místních obyvatel, neboť způsobuje zranitelnost potravinového systému, poškozuje infrastrukturu a způsobuje ekonomické dopady v mnoha odvětvích. To ovlivňuje způsob života na ostrově, dopravu, komerční rybolov a arktické ekosystémy tak procházejí zásadními změnami ve své struktuře a fungování (Goldhar, Ford 2010).

3.2 Data

3.2.1 Data pro mapování zaledněných ploch

Multispektrální optická data Landsat

Z optických senzorů se stala řada Landsat hlavním zdrojem dat pro mapování ledovců a hodnocení jejich změn. Snímky Landsat poskytují velmi dobré spektrální, prostorové i časové rozlišení, a jsou tedy vhodným zdrojem pro mapování změn. Data Landsat byla pro tuto diplomovou práci zvolena kvůli velmi dobré prostorové kvalitě a bezkonkurenční dlouhodobé kontinuitě dat, pomocí které je možné zachytit trendy, vzorce a dlouhodobé změny v chování ledovců v reakci na měnící se klimatické podmínky. Díky dostupnosti dat v různých spektrálních pásmech je možné odlišit zaledněný povrch od ostatních povrchů. Velkou výhodou dat Landsat je právě termální infračervené pásmo, neboť povrchové teploty hrají důležitou roli při odlišování ledovce pokrytého sutí od sutin na zemském povrchu nebo stínu na ledovci od sněhu na zemském povrchu.

Veškerá data Landsat jsou navíc volně dostupná na stránkách USGS EarthExplorer, kde jsou poskytována ve dvou kolekcích, které se liší úrovní předzpracování dat. Kolekce 2 (*Collection 2*) disponuje vylepšenými radiometrickými a atmosférickými korekcemi, lepší konzistencí dat, lepším maskováním oblačnosti a vyšší geometrickou přesností ve srovnání s Kolekcí 1 (*Collection 1*). Kolekce 2 obsahuje data úrovně 1 a 2, produkty na úrovni 1 jsou založené na škálovaných digitálních číslech, zatímco produkty úrovně 2 jsou založené na povrchové odrazivosti a povrchové teplotě, a jsou připravena k dalšímu zpracování, neboť nevyžadují žádné další korekce (USGS 2023).

Pro přesnou detekci změn je zásadní výběr správných dvojic snímků, neboť detekce změn je ovlivněna prostorovým, spektrálním a časovým omezením, stejně tak jako radiometrickým rozlišením, atmosférickými podmínkami, osvětlením, vlhkostními podmínkami půdy nebo šumem. Je vhodné proto vybírat snímky pořízené každoročně ve stejný den nebo v jeho blízkosti, protože snižují počet chyb způsobených sezónními změnami, minimalizují rozdíly v osvětlení, úhlech pohledu a atmosférických podmínkách (Hussain a kol 2013).

Původním záměrem bylo vytvořit časovou řadu po sobě jdoucích snímků s odstupem každých 10 let. Výběr vhodných snímků však komplikovala vysoká oblačnost i sezónní sníh. Pro 90. léta nebyl dostupný žádný snímek, který by pokrýval kompletní území ostrova Disko bez oblačnosti. Mezi lety 2003–2013 nebylo možné najít snímek bez chyb senzoru způsobených

vadou skeneru družice Landsat 7, což limituje jejich využití pro analýzu a následnou klasifikaci, a proto byly z výběru vynechány. Nakonec byly použity snímky ze září 1985, srpna 2000 a srpna 2021 viz. Tabulka 1.

Datum	ID snímku
03.09.1985	LT05_L2SP_011011_19850903_20200918_02_T1
26.08.2000	LE07_L2SP_012011_20000826_20200918_02_T1
21.08.2021	LC08_L2SP_011011_20210821_20210827_02_T1

Tabulka 1: Použité Landsat snímky

Hodnoty spektrální odrazivosti byly získány přímo z dostupných dat Landsat 5 TM, Landsat 7 ETM a Landsat 8 OLI, konkrétně pro zelené, modré, červené, blízké infračervené, krátkovlnné infračervené pásmo I a II.

Spektrální indexy

Pro účely této práce byly odvozeny tři spektrální indexy – normalizovaný diferenční sněhový index, normalizovaný vodní index a nový poměr pásem navržený autory Alifu a kol. (2015).

NDSI využívá kontrastních spektrálních vlastností sněhu v zeleném pásmu a krátkovlnném infračerveném pásmu a používá se k detekci sněhové pokrývky. Jeho vzorec je následující:

$$NDSI = (GREEN - SWIR)/(GREEN + SWIR)$$

NDWI využívá absorpční vlastnosti vody blízké infračervené části spektra a její silné odrážejí světlo v zelené části spektra. NDWI se používá ke zvýraznění vodních ploch a k potlačení ostatních prvků zemského povrchu, a počítá se následovně:

$$NDWI = (GREEN - NIR)/(GREEN + NIR)$$

Nový poměr pásem využívá tepelné a spektrální vlastnosti ledovců pokrytých sutí a slouží k lepšímu odlišování ledovců pokrytých sutí od okolního terénu. Tato technika integruje tepelné infračervené (TIR), blízké infračervené (NIR) a krátkovlnné infračervené (SWIR) pásmo ve specifickém poměru:

$$NBR = TIR / \left(\frac{NIR}{SWIR} \right)$$

Spektrální indexy byly vypočteny v QGISU s využitím funkce *raster calculator*.

Texturní míry

Texturní míry slouží k rozlišení drsnosti, hrubosti/hladkosti a pravidelnosti zemského povrchu. Texturní příznaky jsou založeny na místních prostorových závislostech odstínů šedi a lze je pomocí Haralickovo funkcí odvodit z koincidenční matice stupňů šedi, která obsahuje informaci o prostorových závislostech (Haralick, Shanmugam, Dinstein 1973; Hall-Beyer 2017).

Pro potřeby této práce byly na základě rešerše vybrány následující texturní míry:

- druhý úhlový moment (celková rovnoměrnost nebo hladkost obrazu),
- kontrast (podobnost odstínů šedi sousedních pixelů)
- korelace (jak moc je pixel korelován se svým okolím)
- suma průměrů (odráží průměrnou intenzitu párů pixelů v určitých vzdálenostech a orientacích a zvýrazňuje celkovou úroveň jasu v oblasti)
- suma rozptylu (heterogenita textury)
- entropie (míra náhodnosti intenzity obrazu)
- inverzní diferenční moment (homogenita textury)

Texturní charakteristiky byly vypočteny pomocí nástroje *r.texture* v softwaru QGIS. GLCM byla vygenerována pomocí posuvného okna o velikosti 5×5 pro zelené spektrální pásmo, neboť ledové plochy mají v tomto pásmu největší odrazivost. *r.texture* vypočítává texturní míry na základě GLCM v úhlech 0, 45, 90 a 135 stupňů. Velikostí pohyblivého okna se definuje vzdálenost, v níž se porovnávají hodnoty šedi pixelů. Velikost okna by měla být dostatečná, aby zachytila charakteristickou tónovou proměnlivost daného povrchu, a zároveň menší než jednotlivé objekty zkoumaných tříd. Výsledné hodnoty jsou průměrem hodnot ze všech čtyř orientací v pohyblivém okně (Antoniol a kol. 2024).

Data povrchové rychlosti pohybu ledovců

Dalším příznakem je průměrná roční rychlosti povrchového pohybu ledovců z mise ITS_LIVE. Jednotlivé soubory představují mapy průměrných ročních hodnot povrchové rychlosti pohybu ledovců v prostorovém rozlišení 120 m.

Pro účely této diplomové práce byla použita data povrchové rychlosti pohybu ledovců pro roky 1985, 2000 a 2018, jako pomocná data posloužily údaje o průměrných povrchových rychlostech za celé sledované období (1985–2018).

Topografická data

Pro odvození topografických vlastností terénu byla využita data z projektu ArcticDEM. Pro potřeby této práce byla získán mozaikový soubor digitálního výškového modelu pro ostrov Disko, ze kterého následně byly odvozeny topografické příznaky jako nadmořská výška, orientace, sklonitost terénu, zastínění a drsnost povrchu.

Topografické vlastnosti povrchu by měly přispět ke klasifikaci sutí pokrytých ledovců, neboť se vychází z předpokladu, že ledovce pokryté sutí se nachází na nížinných jazycích velkých údolních ledovců. Ledovce pokryté sutí mají tendenci se koncentrovat v oblastech, kde je přísun sutě vysoký a rychlost pohybu ledu po povrchu ledovce je nízká v porovnání s ablací sněhu a ledu, a proto se suťové pokryvy vyvíjejí především v dolních částech ablačních zón.

3.2.2 Referenční soubory dat

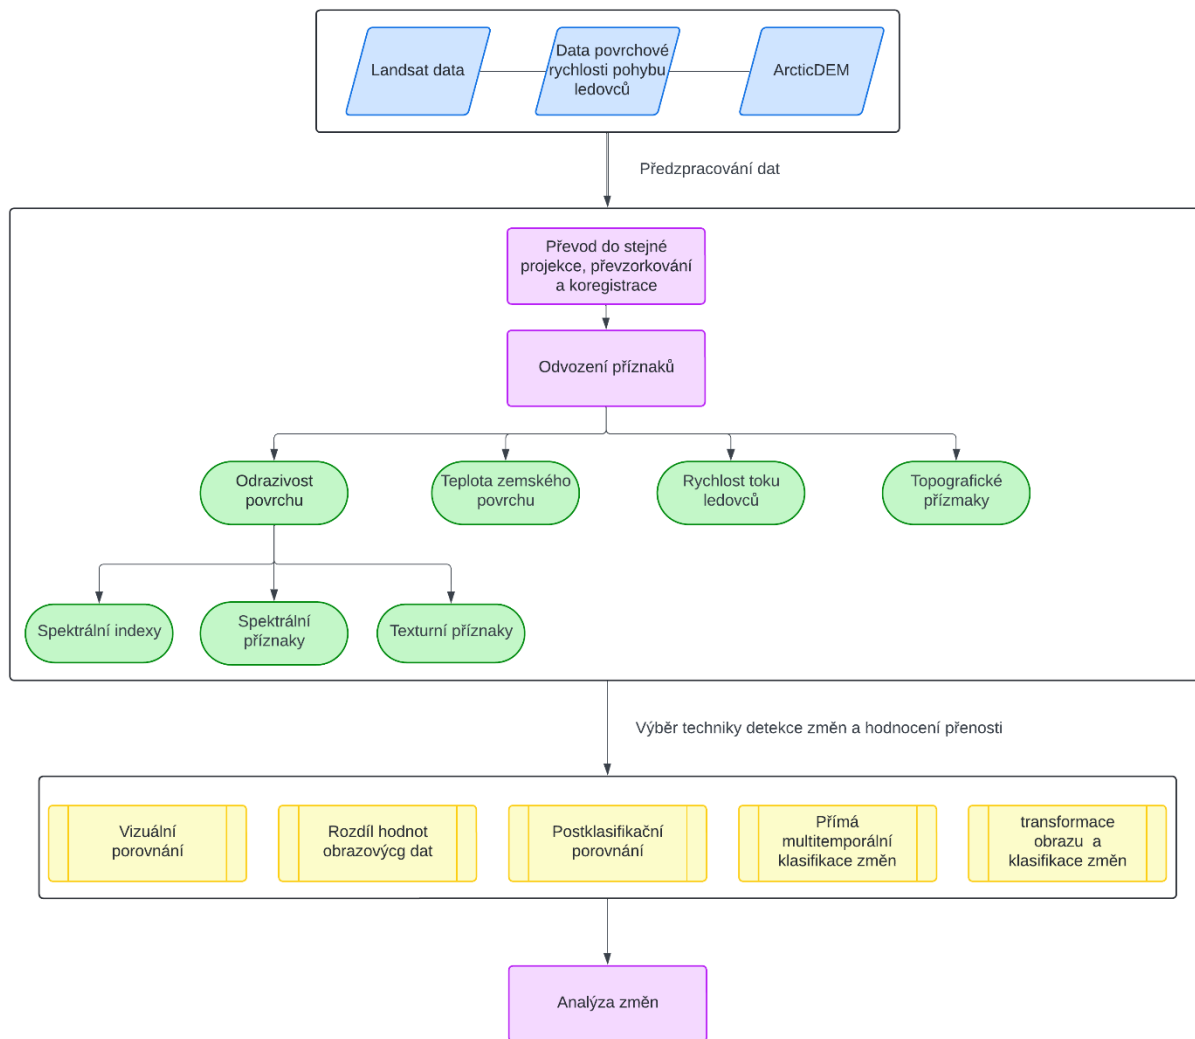
Jako kontrolní data pro mapování ledovců byly použity snímky velmi vysokého rozlišení družic QuickBird a PlanetScope a snímky z Google Earth. K ověření průběžných výsledků této práce sloužily údaje z inventarizace ledovců, která byla v podobě polygonů představující hranice ledovce volně stažena z webových stránek GLIMS.

3.3 Metodika

Pro přípravu dat byl použit software QGIS 3.28.10., zatímco jednotlivé techniky detekce změn, hodnocení jejich přesnosti a kvantitativní vyhodnocení změn bylo naprogramováno v jazyce Python 3.11. Veškeré skripty jsou součástí přílohy.

V rámci výzkumu byly vybrány čtyři techniky detekce změn, které byly vyzkoušeny pro monitorování změn v zaledněných horských oblastech. Jednotlivé techniky byly porovnány a vyhodnoceny za účelem výběru nejvhodnější techniky pro detekci skutečných i nepravých změn. Skutečné změny jsou v tomto kontextu přeměna tříd krajinného pokryvu, zatímco nepravé změny jsou dočasné změny stavu (změna osvětlení, změna vlhkosti, suť na ledovci). Tato kapitola se zaměřuje na postup implementace jednotlivých technik detekce změn, včetně použitých datových zdrojů, analytických nástrojů a parametrů, které byly použity při analýze.

Při realizaci úlohy detekce změn je nutné udělat tři hlavní kroky: výběr a předzpracování dat včetně geometrické registrace a odstranění oblačnosti; výběr vhodných technik pro analýzu změn; vyhodnocení změn a posouzení přesnosti. Zvolený postup včetně vstupních dat je shrnut v diagramu na Obrázku 3.



Obrázek 3: Schéma pracovního postupu

2.3.1 Předzpracování dat

Veškerá výše zmíněná data předzpracována v softwaru QGIS. Původní snímky byly oříznuty na území o přibližné velikosti 50×50 km. Vybrané území zachycuje centrální zaledněnou část ostrova, včetně největšího ledovce Storbræen. Celkově se ve vybraném území nachází zhruba 300 ledovců.

Snímek Landsat z roku 2000 byl v jiné projekci než zbylé dva Landsat snímky, a proto byl pomocí funkce *reproject* převeden do stejné projekce, jako snímky z let 1985 a 2021. Topografická data a data rychlosti pohybu ledovců byla nejprve oříznuta zájmovým územím, reprojektována do stejné projekce jako snímky Landsat a následně převzorkována na prostorové rozlišení 30×30 m.

Kvůli velkému množství chybějících pixelů rychlosti pohybu ledovců pro rok 1985 nebylo možné provést interpolaci chybějících hodnot, a hodnoty chybějících pixelů byly tedy

nahrazeny hodnotami průměrných rychlostí s využitím funkce *r.patch*. Pro rok 2000 data také nebyla kompletní, ale bylo možné hodnoty chybějících pixelů zaplnit s využitím funkce *fill nodata*, která interpolací doplní chybějící hodnoty rastru. Hodnoty pro oblasti bez dat se vypočítají z hodnot okolních pixelů pomocí metody vážené inverzní vzdálenosti, a následně dojde k vyhlazení výsledků. Metoda IDW odhaduje hodnotu v neznámém bodě váženým průměrem hodnot všech známých bodů v okolí, přičemž váhy jsou úměrné inverzní vzdálenosti (Ježek 2016, s. 17). Snímku z roku 2021 byla přiřazena data rychlosti pohybu z roku 2018, neboť novější data nebyla v době výzkumu dostupná. Na základě posouzení dat rychlosti pohybu ledovců všech dosud dostupných let se došlo k předpokladu, že se průměrná rychlost ledovců nebude mezi lety 2018 a 2021 zásadně lišit. Tato data navíc mají sloužit primárně k rozlišení zaledněných ploch od nezaledněného zemského povrchu, proto konkrétní hodnoty rychlosti nejsou zásadním faktorem.

Zhruba na 1 % plochy snímku z roku 2000 se nacházela oblačnost, a proto byla pro rok 2000 vytvořena maska oblačnosti. Informace o oblačnosti byly extrahovány z pomocných pásem hodnocení kvality Landsat.

Pro všechny přístupy k detekci uměn je zásadní přesná geometrická registrace multitemporálních datových souborů, neboť nesprávná registrace může vést k posunům mezi snímky, které by mohly vést k artefaktům a způsobit falešné pozitivní změny. Veškerá data byla proto koregistrována tak, aby se s přesností na jeden pixel překrývala.

Snímky Landsat společně se spektrálními indexy, topografickými daty, texturními rysy a informacích o povrchových rychlostech ledovců byly s využitím funkce *merge* sloučeny do jednoho souboru s 23 pásmy, který sloužil jako vstup do detekci změn.

2.3.2 Výběr technik a realizace

Cílem této práce je vybrat takovou techniku detekce změn, která dokáže odlišit skutečné změny od změn nepravých a určit jejich směr změn.

Před samotnou analýzou bylo provedeno vizuální porovnání snímků. Snímky Landsat byly nahrány do softwaru QGIS a vizualizovány pomocí barevné syntézy v nepravých barvách (SWIR-NIR-RED).

Detekce stavu

Základním předpokladem pro detekci změn je vypořádání se statickým stavem krajinného pokryvu v jednotlivých letech. Výsledek může sloužit nejen jako vstup pro postklasifikační

detekci změn, ale také k porovnání, jak dobře lze klasifikovat statickou situaci oproti přímé multitemporální klasifikaci změn, která je vždy obtížnější. Pro detekci stavu krajinného pokryvu v jednotlivých letech bylo potřeba provést klasifikaci každého snímku zvlášť.

Klasifikační legenda je uvedena v Tabulce 2.

Třída	Definice
Zaledněné plochy	Ledovce, sníh na ledovci, sněhová pole a sezónní sněhová pokrývka na ledovci
Zastíněné zaledněné plochy	Zaledněné plochy ve stínu způsobeným topografií terénu nebo oblačností
Suť na ledovci	Skalní suť pokrývající čelo a boční strany ledovce
Nezaledněné plochy	Skály, skalní úlomky, ledovcové morény, řídká roztroušená vegetace
Zastíněné nezaledněné plochy	Nezaledněné plochy ve stínu způsobeným topografií terénu nebo oblačností
Vodní plochy	Tavná voda z ledovce, ústí mořských zálivů, jezera různých původů

Tabulka 2: Klasifikační legenda

Pro sběr referenční množiny sloužila především syntéza v nepravých barvách popsána výše. Díky kontrastním spektrálním charakteristikám zaledněného a nezaledněného zemského povrchu v těchto pásmech bylo možné rozeznat jednotlivé třídy na snímku. Pro rozpoznání ledovců pokrytých sutí bylo klíčové termální pásmo a nový poměr pásem.

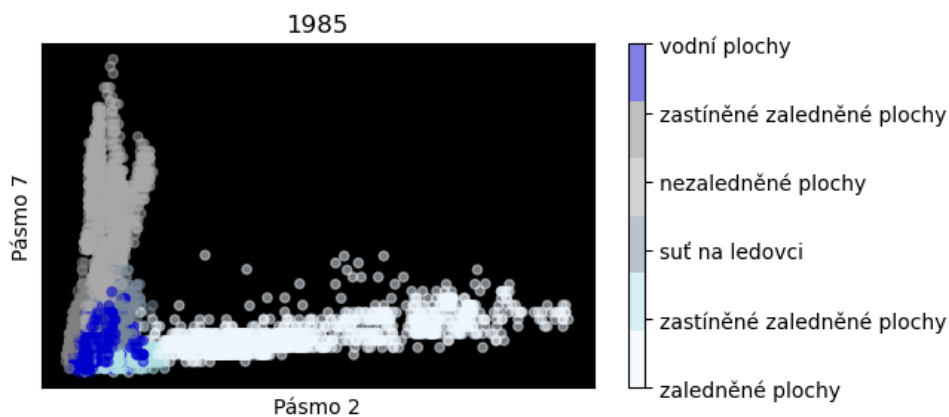
Pro každý rok bylo v softwaru QGIS nasbíráno přibližně 6 600 referenčních pixelů, což je zhruba 0,25 % z celkového počtu pixelů. Přestože byl při sběru referenčních dat kladen důraz na to, aby každá třída obsahovala podobný počet pixelů, některé třídy (suť na ledovci, vodní plochy) byly v oblasti zastoupeny značně méně než třídy jiné (zaledněné a nezaledněné plochy), což vedlo ke vzniku nevyvážené datové sady. Početní zastoupení jednotlivých tříd je uvedeno v Tabulce 3. Tabulka zároveň ukazuje vyváženost výběru trénovacích množin pro jednotlivé roky. Referenční polygony pak byly převedeny z vektorové podoby do rastrové.

	1985	2000	2021
Zaledněné plochy	1 416	1 470	1 282
Zastíněné zaledněné plochy	882	919	859
Suť na ledovci	679	696	1 033
Nezaledněné plochy	1 680	1 688	1 794
Zastíněné nezaledněné plochy	1 251	1 074	1 105
Vodní plochy	657	748	762
Celkem	6 565	6 595	6 835

Tabulka 3: Početní zastoupení jednotlivých tříd

Připravené soubory dat s 23 různými pásmy a referenční data byla nahrána do prostředí Visual Studio Code a dále analyzována pomocí jazyka Python. Nejprve byla data převedena do vícerozměrných matic. Pomocí masky byly z matice reprezentující původní snímky extrahovány informace o pixelech, kterým byla přiřazena nějaká třída krajinného pokryvu. Následně byla tato data převedena do datové struktury *pandas dataframe*, který je podobný tabulce, jejíž sloupce představují jednotlivá pásma rastrového souboru, a zároveň sloupec třídy krajinného pokryvu. Každý řádek potom reprezentuje jeden pixel a jeho hodnotu v jednotlivých pásmech a jemu přiřazenou hodnotu krajinného pokryvu.

Data byla zároveň vizualizována v příznakovém prostoru (pásma 2 a 7). Obrázek 4 představuje příznakový prostor pro rok 1985 a je z něj patrné, že jednotlivé třídy nejsou lineárně separabilní, a že bude zapotřebí komplexnějšího algoritmu pro jejich rozdělení. Příznakový prostor vykazuje stejný trend u všech sledovaných let.



Obrázek 4: Příznakový prostor tříd pro rok 1985

Množina dat byla pomocí stratifikovaného náhodného výběru rozdělena na trénovací a validační data v poměru 80:20.

Na základě rešerše literatury byly pro klasifikaci byly otestovány 3 algoritmy: KNN, RF a GBDT. Každý algoritmus byl pro jednotlivé snímky natrénován s výchozím nastavením a použit pro klasifikaci jednotlivých souborů. Pro každý algoritmus byla uložena nejen celková přesnost klasifikace ale i doba trénování a doba predikce (Příloha 1). Dále také výsledná mapa krajinného pokryvu. Na základě těchto informací byl jako výsledný klasifikátor vybrán RF.

Pro dosažení stabilnější predikce byly klasifikátoru RF upraveny některé hyperparametry. Provádění optimalizace parametrů modelů manuálně může být časově velmi náročné, a proto lze využít hledání v mřížce (*grid search*). Hledání v mřížce spočívá v tom, že se zadají hodnoty

jednoho nebo více parametrů a vyberou se hodnoty, které se pro každý parametr vyzkouší. Každá možná sada parametrů je pak vyhodnocena pomocí křížové validace.

Pro měření kvality rozdělení byla zvolena entropie, která je sice výpočetně náročnější než Giniho index, ale může být vhodnější pro složité datasety. Aby nevznikaly příliš hluboké stromy s komplikovanou strukturou, které by mohly vést k přetrénování, byla maximální hloubka stromu nastavena na 20. Ze stejného důvodu byla nastavena hodnota minimálního počet vzorků uložených v listu stromu na 2 a hodnota minimálního počtu vzorků potřebných pro rozdělení uzlu pak na 4. Důležitými parametry, které je při ladění parametrů modelů RF potřeba zvážit je maximální počet proměnných (*max features*), který je brán v potaz při hledání nejlepšího rozdělení a počet stromů v lese (*number of estimators*). Na základě hledání v mřížce bylo zkoumáno, jaký vliv budou mít níže uvedené hodnoty na výkon modelu:

Počet stromů: 100, 200, 300, 400, 500

Počet proměnných: 5, 6, 7, 8, 9

Deset nejlepších kombinací hyperparametrů bylo uloženo do tabulky (Příloha 2) a následně porovnáno. Před samotnou klasifikací byla pro model s nejlepší kombinací hyperparametrů vypočtena trénovací i testovací chyba, aby se ověřilo, že je model schopný generalizace. Všechny snímky byly následně s výše zmíněnými parametry klasifikovány a pro výslednou klasifikaci byla vypočtena nejen celková přesnost i F1 skóre.

Detekce změn pomocí rozdílů obrazových dat

Jako první technika byla vybrána detekce změn pomocí rozdílů obrazových dat, která byla aplikována na zelené pásmo, NDSI a termální pásmo. S využitím programovacího jazyka Python byly soubory dat pro všechna tři sledovaná období otevřeny jako vícedimenzionální matice v prostředí Visual Studio Code. Snímky z po sobě jdoucích let od sebe byly odečteny, záporné hodnoty byly převedeny na kladné. Následně byla pro každou variantu a pro každé období vybrána prahová hodnota pro odlišení změněných ploch od nezměněných. Výsledně snímky byly vyexportovány ve formátu *GeoTIFF*, aby mohly být vizualizovány v softwaru QGIS.

Postklasifikační porovnání

Vstupem do postklasifikačního porovnání byly vytvořené mapy krajinného pokryvu. Nejprve byly tyto mapy pro dvě po sobě jdoucí období překryty pro vytvoření matice změn k analýze veškerých změn v oblasti. K vizualizaci skutečných změn byly v původních mapách krajinného

pokryvu sloučeny dohromady třídy zaledněné plochy, zastíněné zaledněné plochy a suť na zaledněných plochách do jedné třídy reprezentující zaledněné plochy. Nezaledněné a zastíněné nezaledněné plochy byly sloučeny do jedné třídy reprezentující nezaledněné plochy. Vodní plochy zůstaly zachovány jako samostatná třída. Takto připravené mapy byly pro po sobě jdoucí roky navzájem překryty, aby bylo možné vytvořit matici změn a provést analýzu skutečných změn.

Přímá multitemporální klasifikace změn

Pro obě sledovaná období byly původní dvojice snímků se všemi pásmy sloučeny do jednoho souboru. Vznikly tak dva multitemporální soubory: pro období 1985–2000 a pro období 2000–2021, přičemž každý soubor obsahuje 46 pásem (tedy dvojnásobku původního počtu pásem). Pro tento multitemporální soubor byla vytvořena referenční sada dat, jejíž kategorie představovaly jak stabilní plochy, tak veškeré možné změny mezi původními šesti třídami. Pro natrénování těchto změn bylo využito multitemporální barevné syntézy, kdy dřívější snímek byl vizualizován v červeném pásmu a pozdější snímek v zeleném a modrém pásmu, změny pak byly vyobrazeny převážně v odstínech červené. Pro identifikaci změn také sloužily rozdílové obrazy vytvořené odečtením obrazových dat. Veškeré možné změny jsou uvedeny v Tabulce 4.

		změna „na“					
		led	stín na ledu	suť na ledu	skála	zastíněná skála	voda
změna „z“	led		dočasná změna stavu		ústup zalednění	roztátí zalednění	
	stín na ledu	dočasná změna stavu		dočasná změna stavu			
	suť na ledu	dočasná změna stavu					
	skála	postup zalednění				dočasná změna stavu	vznik vody
	zastíněná skála				dočasná změna stavu		
	voda	zamrznutí vody			vyschnutí vody		

Tabulka 4: Tabulka možných změn

Pro každý rok bylo nasbíráno více než 7 200 referenčních pixelů, což odpovídá zhruba 0,25 % z celkového počtu pixelů. Protože plošné zastoupení jednotlivých tříd se v oblasti značně liší, liší se i výskyt jednotlivých typů změn, což vedlo ke vzniku velmi nevyváženého datasetu. Stejně jako v předchozím případě byla data pomocí stratifikovaného náhodného výběru rozdělena na trénovací a testovací množinu v poměru 80:20.

Protože se RF osvědčil u klasifikace statického stavu, byl vybrán i pro úlohu přímé klasifikace. Pro optimalizaci klasifikátoru bylo opět použito hledání v mřížce pro nalezení optimálních parametrů. Kritériem pro měření kvality rozdělení byla opět zvolena entropie. Maximální hloubka stromu byla nastavena na 20, minimální počet vzorků uložených v listu na 2 a hodnota minimálního počtu vzorků potřebných pro rozdělení uzlu na 4. Pro nalezení optimálního počtu stromů a počtu proměnných zvažovaných při každém rozdělení bylo opět využito hledání v mřížce. Veškeré zvažované hodnoty parametrů jsou uvedeny níže:

Počet stromů: 100, 200, 300, 400, 500

Počet proměnných 7, 8, 9, 10, 11, 12, 13, 14, 15, 16

Deset nejlepších kombinací hyperparametrů bylo uloženo do tabulky (Příloha 3) a následně porovnáno. Oba soubory byly následně s nejlepšími parametry klasifikovány a pro výslednou klasifikaci byla vypočtena nejen celková přesnost i F1 skóre. Opět byla před klasifikací pro model s vybranou kombinací hyperparametrů vypočtena trénovací i testovací chyba, aby se ověřilo, že je model schopný generalizace. Pro výslednou klasifikaci byla zjištěna důležitost jednotlivých příznaků na základě informačního zisku a důležitosti permutovaných proměnných.

Důležitost proměnných v RF se počítá na základě toho, jak moc každý příznak přispívá ke snížení nečistoty v rozhodovacích uzlech. Bere v úvahu vnitřní strukturu stromů a to, jak konkrétní příznak zlepšuje přesnost predikce, i jak dobře na základě tohoto příznaku lze rozdělit jednotlivé pixely do tříd. Tato důležitost ale nevypovídá o tom, jak moc je příznak celkově důležitý pro klasifikaci. K tomu lze využít důležitost permutovaných proměnných (*permutation importance*). Důležitost permutovaných proměnných spočívá v měření poklesu výkonnosti modelu při náhodném promíchání hodnot jednoho příznaku a přímo posuzuje, jak důležitý je každý příznak pro předpovědi modelu (Pedregosa a kol. 2011).

Výstupem této klasifikace je změnová mapa, pro kterou bylo vypočteno plošné zastoupení nepravých i skutečných změn, protože tato metoda neposkytuje kompletní matici změn. Ve výsledných změnových mapách byly následně sloučeny třídy změn představující změny v osvětlení či změny stavu, aby mohly být vizualizovány skutečné změny.

Transformace obrazu a přímá klasifikace

Jako poslední technika byla vyzkoušena technika založená na transformaci obrazu pomocí analýzy hlavních komponent. Protože multitemporální soubory dat vytvořené v předchozím kroku obsahovaly mnoho pásem, byla na ně aplikována metoda analýza hlavních komponent

pro redukci dimenzionality a zvýraznění změn mezi soubory. Bylo vybráno prvních 15 komponent, které zachovávají více než 95 % původního rozptylu. Postup byl potom stejný jako u předchozí techniky s jediným rozdílem, že zvažované hodnoty pro maximální počet proměnných byly sníženy na 4, 5 a 6. Deset kombinací nejlepších parametrů je uloženo v tabulce v Příloze 4. Výstupem této klasifikace změnová mapa, na kterou byly aplikovány veškeré kroky jako u předchozí techniky.

3.3.3 Hodnocení změn

Před provedením každého hodnocení přesnosti bylo proveden postzpracování výsledných změnových map, aby došlo k omezení nežádoucích výstupů. Vzhledem k tomu, že v oblasti převažují velké ledovcové plochy, výsledné klasifikační mapy se skládají z objektů relativně větších rozměrů. Malé objekty a díry v zájmových objektech bylo tedy vhodné odstranit. V rámci postzpracování byl tedy aplikován *sieve filtr*, který slouží k odfiltrování izolovaných pixelů. Pokud je počet seskupených pixelů stejné třídy menší, než zadaná prahová hodnota (v pixelech), je jejich třída nahrazena třídou, která je určena na základě většinové třídy jejich sousedních pixelů. Prahová hodnota byla nastavena na 5 pixelů (Warmerdam, Roualt 2024).


Výsledky z jednotlivých metod byly vizualizovány a porovnány. U technik založených na klasifikaci bylo provedeno hodnocení přesnosti. U multitemporální přímé klasifikace a u multitemporální přímé klasifikace na transformovaném obraze bylo hodnocení přesnosti součástí metody, kdy pro výslednou klasifikaci byla vytvořena chybová matice, ze které byla vypočtena celková přesnost a další metriky. Pro postklasifikační techniku pak byla použita validační data vytvořená pro přímou multitemporální klasifikaci změn, která byla překryta se změnovou mapou, na základě čehož bylo možné vytvořit chybovou matici, a tak zjistit celkovou přesnost a další metriky.

U postklasifikačního porovnání a přímé multitemporální klasifikace změn byla také provedena validace změn napříč celým obdobím. Bylo zjišťováno, zda změny, které technika zachytila, jsou validní nebo chybné. Validní změny jsou všechny možné skutečné i nepravé změny, které v oblasti mohou nastat. Každá třída změny je v mapě reprezentována kombinací dvou čísel, kde první číslo označuje původní třídu krajinného pokryvu a druhé číslo novou třídu krajinného pokryvu. Pro zjištění validity změn byly tyto změnové mapy překryty tak, že vznikla čtyřčíselná kombinace čísel. Validní změny by mají podobu tří po sobě jdoucích stejných čísel a jednoho odlišného buď na prvním nebo posledním místě (např. 0001, 0111), což znamená že krajinný prvek byl stabilní během prvního období, ale v druhém prošel změnou, nebo naopak prošel

změnou v prvním období, ale v druhém již zůstal stabilní. Validní změny mohou být reprezentovány i kombinací dvou stejných čísel uprostřed (např. 0110, 0112), což znamená že krajinný prvek prošel nejprve transformací z jedné třídy do druhé v prvním období, z druhé třídy na třetí, případně zpět na první třídu v druhém období. V žádném případě by kombinace neměla obsahovat čtyři různá čísla, nebo dvě opakující se kombinace čísel (např. 0101, 0123). Nemělo by se stát, že by pixel v obou obdobích prošel stejnou změnou, protože to je jednoduše nemožné, a v takovém případě by se jednalo o chyby.

4 Výsledky

Při porovnání snímků na Obrázku 5 je patrné, že ve sledované oblasti dochází ke změnám. Kromě toho, že mezi jednotlivými obdobími lze pozorovat ústup ledovců, mezi lety 1985–2000 došlo také k velkému postupu dvou ledovců. Obrázek 5 je také součástí Přílohy 5.



Obrázek 5: Zobrazení snímků v syntéze nepravých barev


Detekce stavu

Protože se účinnost postklasifikační metody detekce změn odvíjí od kvality vstupních dat, je důležité mít vysokou přesnost klasifikace původních snímků. Proto byly jednotlivé klasifikace vyhodnoceny nezávisle na hodnocení výsledků detekce změn, aby se minimalizoval efekt, že chyby v klasifikaci nezpůsobí chyby v detekci změn. Trénovací přesnost byla pro všechny klasifikace větší než 99 %, testovací přesnost jednotlivých klasifikací je shrnuta v Tabulce 5. Pro testovací dataset je celková přesnost pro rok 1985 96,57 %, pro rok 2000 97,04 % a pro rok 2021 96,49 %. F1 skóre je pak 96,08 %, 96,69 a 96,67 %, což svědčí o velmi dobrých výsledcích. Model je tedy schopný generalizace a lze jej použít pro klasifikaci, a výsledky z klasifikace lze použít pro další analýzu. Výsledné mapy krajinného pokryvu jsou přiloženy jako Příloha 6, 7 a 8.

	1985			2000			2021		
	OA (%)		F1 (%)	OA (%)		F1 (%)	OA (%)		F1 (%)
	96,57		96,08	97,04		96,69	96,49		96,67
Třída	UP	ZP	F1	UP	ZP	F1	UP	ZP	F1
Led	99,64	98,94	99,29	98,99	99,66	99,32	99,22	99,61	98,42
Stín na ledu	100	98,86	99,43	99,44	96,2	97,79	97,65	96,51	97,08
Suť na ledu	88,97	88,97	88,97	91,85	89,21	90,51	92,23	91,79	92,01
Skála	94,77	97,02	95,88	94,83	97,63	96,21	94,75	95,54	95,15
Stín na skále	96,06	97,6	96,83	98,12	97,21	97,66	97,27	96,83	97,05
Voda	99,19	93,19	96,09	98,66	98,66	98,66	99,34	99,34	99,34


Tabulka 5: Přesnost klasifikace krajinného pokryvu

Suť na ledovci má nižší hodnotu F1 skóre než všechny ostatní třídy. Tato třída je nejproblematictější nejen kvůli tomu, že vykazuje podobné spektrální charakteristiky jako okolní skalnatý povrch, ale také kvůli tomu, že je v oblasti nejméně zastoupená a obsahuje tedy nejméně pixelů. Tento problém lze nejlépe pozorovat z chybové matice na Obrázku 6, kdy počet špatně klasifikovaných pixelů pro suť na ledovci a okolní skalnatý povrch je velmi podobný.



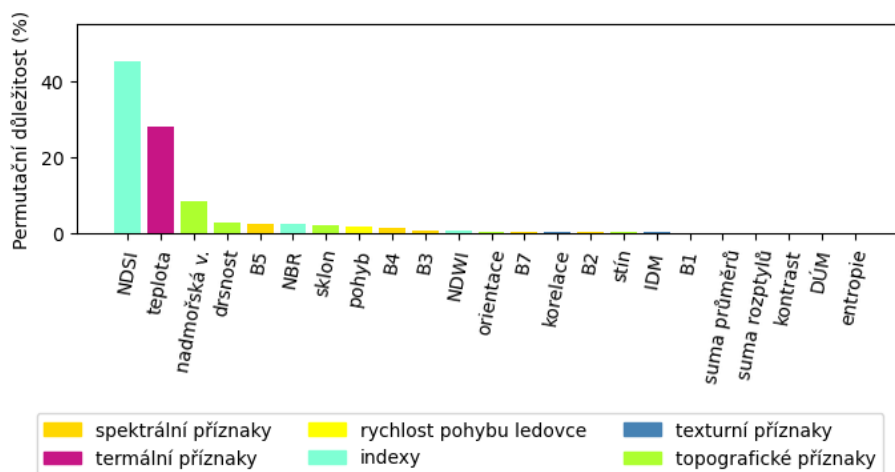
Obrázek 6: Chybová matice klasifikace pro rok 2000

Dále byla pro každou klasifikaci spočtena důležitost příznaků na základě informačního zisku a podle důležitosti permutovaných proměnných. Na základě informačního zisku se jako nejdůležitější příznaky u všech sledovaných let ukázaly spektrální příznaky a spektrálními indexy, následované termálními příznaky. Podobných důležitostí pak dosáhly některé topografické a texturní příznaky, přičemž velmi malá důležitost byla přiřazena rychlosti povrchového pohybu ledovce. Obrázek 7 zobrazuje důležitost pro rok 2000, přičemž trend je u jednotlivých let velmi podobný.



Obrázek 7: Důležitost příznaků pro klasifikaci stavu (informační zisk)


U permutační důležitosti se kromě NDSI ukázala daleko důležitější teplota a nadmořská výška (Obrázek 8).



Obrázek 8: Důležitost příznaků pro klasifikaci stavu (permutační důležitost)


Detekce změn pomocí rozdílu obrazových dat

Obrázek 9 představuje rozdíly v hodnotách pro zelené pásmo, NDSI a termální pásmo (zleva) pro období 1985–2000.



Obrázek 9: Binární změnové mapy pro období 1985–2000

Z rozdílových obrázků je vidět, že na základě hodnot odrazivosti v zeleném pásmu nelze dobře detekovat změny. U jednoho ze vstupních snímků došlo k saturaci odrazivosti kvůli nasycení senzoru, a proto dochází k detekci změn v akumulacích částech ledovce. Teplotní pásmo zahrnuje také příliš mnoho změn, které souvisí se změnou zastínění. Nejlépe změny související se změnou zalednění aproximuje rozdílový obraz NDSI. Z rozdílového obrazu však nelze odlišit ústup ledovce od postupu a zachytit změny související se sutí na ledovcích nebo změny vodních ploch. Podobný trend lze pozorovat na rozdílových obrázcích z druhého období (Obrázek 10). Oba obrázky jsou v plném rozlišení přiložené jako Příloha 9 a 10.




Obrázek 10: Binární změnové mapy pro období 2000–2021

Postklasifikační porovnání

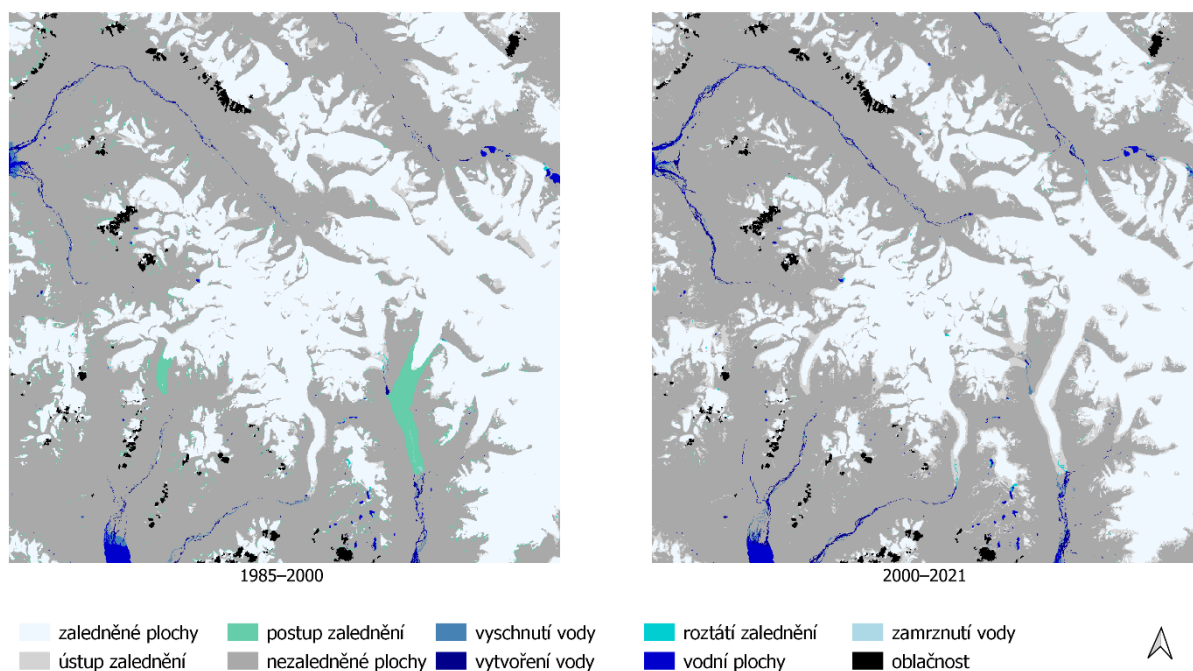
Veškeré změny vzniklé překrytím dvou map krajinného pokryvu byly kvantifikovány pomocí matice změn na Obrázku 11. Vybraný snímek pokrývá území o rozloze 2 498 km². Na základě analýzy matice změn bylo zjištěno, že mezi lety 1985–2000 změny nastaly na 323,26 km² území, což je přibližně 12,94 % z celkového území. Bylo zjištěno, že 41,39 % ze všech změn jsou změny nepravé a pouze 58,61 % je skutečných. Nepravé změny představují například změny v osvětlení povrchu, nebo změny stavu (zasucení ledovce). Skutečné změny (např. ústup a postup ledovce) tedy pokrývají území 189,45 km², což je zhruba 7,58 % z celkové území.

Mezi lety 2000–2021 nastaly změny na 365,28 km² území, což je přibližně 14,62 % z celkového území. Z celkového počtu změn je 33,63 % změn nepravých a 66,37 % skutečných. Skutečné změny pokrývají území o rozloze 242,42 km², což je zhruba 9,7 %.




Obrázek 11: Změnové matice pro všechny třídy krajinného pokryvu

Skutečné změny jsou zobrazeny na Obrázku 12 a kvantifikovány pomocí matic změn na Obrázku 13, který je v plném rozlišení součástí Přílohy 11.



Obrázek 12: Změnové mapy (postklasifikační porovnání)

Co se samotných změn týká, v oblasti jsou pozorovatelné dopady klimatických změn. Mezi lety 1985–2000 zůstalo stabilních zaledněných ploch 91,1 %, přičemž na zbylých 9 % lze pozorovat úbytek, ať už ve formě zmenšení plochy ledovců nebo roztátí ledovců. V tomto období lze pozorovat i nárůst zaledněných ploch, což je dáno především náhlým velkým postupem dvou ledovců v území, ale i sezónním pokryvem sněhem. Vodní plochy vykazují velké změny za obě pozorovaná období, což je dáno tím, že tavná voda z ledovce nemá stále koryto, a v jednotlivých letech odtéká různými směry.



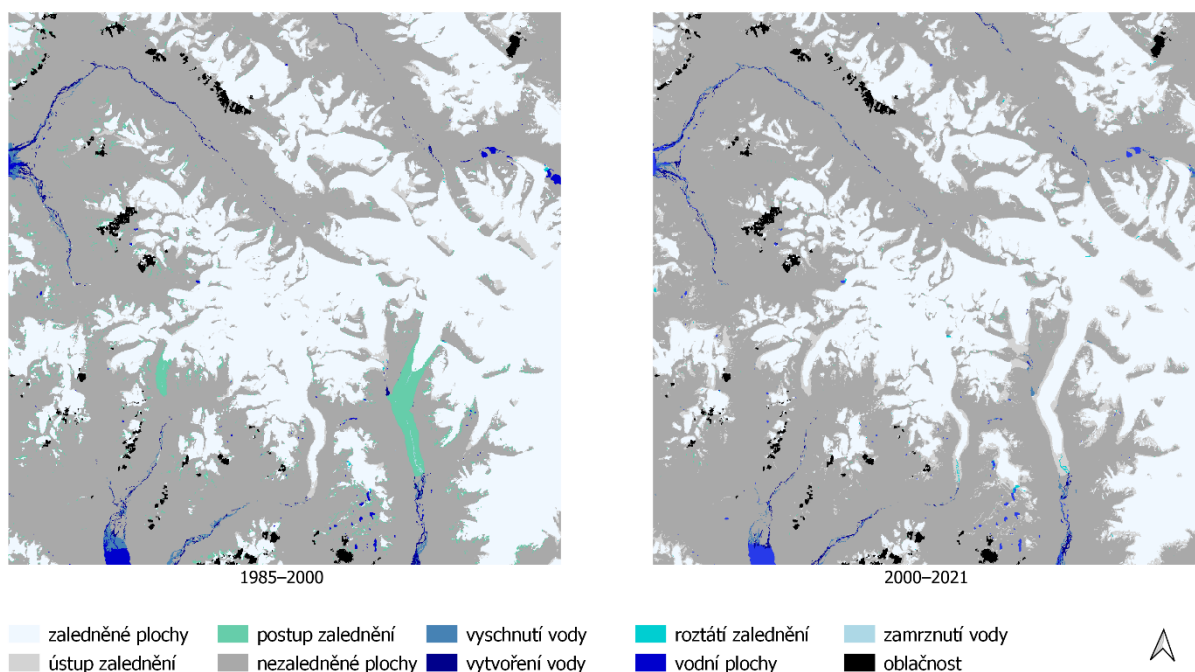
Obrázek 13: Matice skutečných změn

V letech 2000–2021 trend ústupu ledovců zesiluje, neboť stabilní zaledněné plochy v tomto období představují pouze 81,44 %. Mezi lety 2000–2021 se plocha ledovců zmenšila o 18,55 % což je dvakrát více než v minulém období.

Celková přesnost pro postklasifikační techniku detekce změn pro období 1985–2000 byla 87,5 % a pro období 2000–2021 81,4 %. Protože zastoupení jednotlivých změnových tříd bylo poměrně nevyrovnané, bylo vypočteno i F1 skóre, které bylo pro první období 78,99 % a pro druhé 73,72 %. Průměrná přesnost této techniky pro detekci změn je 84,45 %. Z hlediska validace změn mezi oběma obdobími bylo 95,5 % změn z celkového počtu změn validních.

Přímá multitemporální klasifikace změn

Trénovací přesnost byla pro obě multitemporální klasifikace změn vyšší než 99 %. Celková testovací přesnost pak byla pro období 1985–2000 95,88 % a pro období 2000–2021 92,51 %. Kvůli nerovnoměrnému zastoupení jednotlivých změnových tříd bylo vypočteno i F1 skóre, které bylo pro první období 92,49 % a pro druhé 89,96 %. Průměrná přesnost této techniky pro detekci změn je 94,3 %. Z hlediska validních změn mezi oběma obdobími bylo validních pouze 71,81 % změn z celkového počtu změn. Obrázek 14 zobrazuje skutečné změny a v plném rozlišení je dostupný jako Příloha 12.




Obrázek 14: Změnové mapy (přímá multitemporální klasifikace změn)

Na základě analýzy změn bylo zjištěno, že mezi lety 1985–2000 změny nastaly na 290,06 km² území, což je přibližně 11,61 % z celkového území. Avšak bylo zjištěno, že 34,56 % ze všech změn jsou změny nepravé a pouze 65,44 % je skutečných. Skutečné změny tedy pokrývají území 189,83, což je zhruba 7,6 % z celkové území.

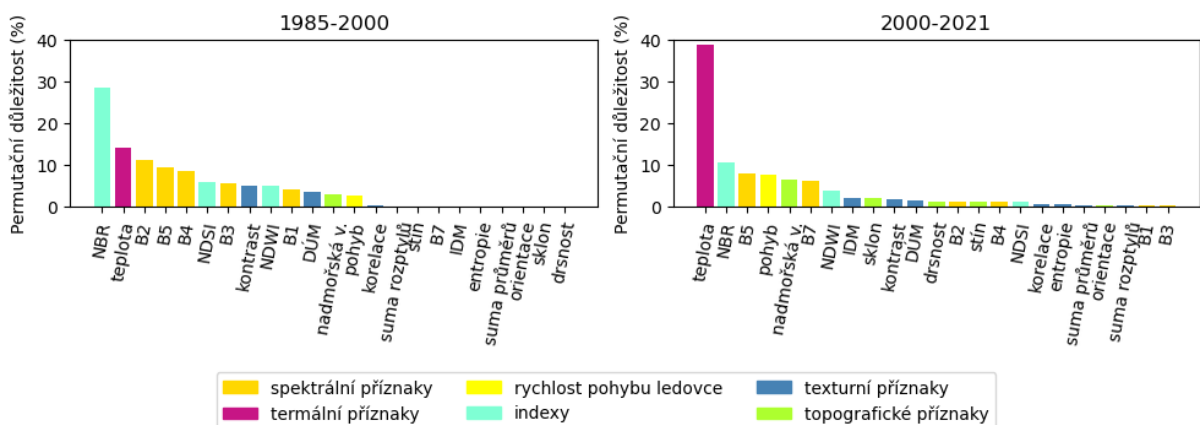
Mezi lety 2000–2021 nastaly změny na 289,57 km² území, což je přibližně 11,59 % z celkového území. Z celkového počtu změn je 28,44 % změn nepravých a 71,56 % pravých. Skutečné změny pokrývají území o rozloze 207,20 km², což je zhruba 8,3 %.

Pro obě klasifikace byla dále zjištěna důležitost příznaků na základě informačního zisku a podle důležitosti permutovaných proměnných. Na základě informačního zisku se jako nejdůležitější příznaky u obou sledovaných let ukázaly dva indexy – NDSI a NBR. Dále pak spektrální příznaky a teplota, následované topografickými a texturními příznaky (Obrázek 15).



Obrázek 15: Důležitost příznaků pro klasifikaci změn (informační zisk)

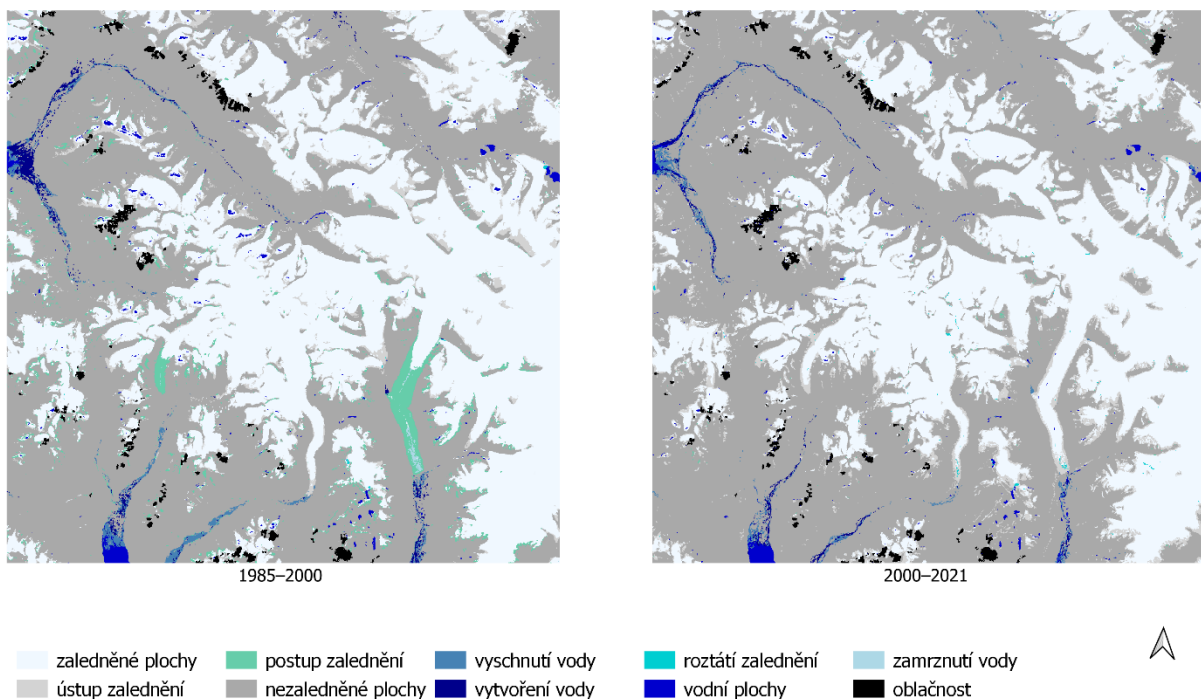
Důležitost permutovaných proměnných se lišila u obou sledovaných období. U obou období se kromě NBR ukázala daleko důležitější teplota, a v případě druhého období potom i rychlost povrchového pohybu ledovce (Obrázek 16).



Obrázek 16: Důležitost příznaků pro klasifikaci změn (permutační důležitost)

Transformace obrazu a přímá klasifikace

Průměrná přesnost této metody vyšla 87,4 % a F1 skóre 86,93 %. Přestože jsou tyto výsledky poměrně dobré, bylo zjištěno, že transformace obrazu nepomohla modelu RF lépe detekovat změny. Jak je vidět na Obrázku 17, v tomto případě ani RF není schopný transformovaný obraz dobře klasifikovat a změnová mapa neodpovídá změnám v oblasti. Na základě těchto skutečností, nebyla provedena podrobnější analýza, jako u předchozích metod. Výsledná mapa je součástí Přílohy 13.



Obrázek 17: Změnové mapy (transformace obrazu a klasifikace změn)

5 Diskuze

Pro detekci změn zalednění bylo vyzkoušeno několik různých metod. Před samotnou detekcí změn bylo provedeno vizuální porovnání multitemporálních snímků s využitím syntézy v nepravých barvách a klasifikace stavu v jednotlivých obdobích. Následně byla vyzkoušena technika detekce změn na základě diferenciacce obrazu, dvě techniky založené na klasifikaci a technika založená na transformaci obrazu.

Vizuální porovnání bylo prvním a zásadním krokem pro seznámení se s oblastí. Na základě multitemporálních snímků byla možná prvotní identifikace změn. To hrálo pro detekci změn klíčovou roli, neboť bylo zjištěno, že v oblasti se nachází množství ledovců pokrytých sutí, jejichž identifikace a zachycení vývoje v čase není triviálním úkolem. Kromě toho lze pozorovat i změny v akumulacích a ablačních částech ledovce, změny v poloze sněhové čáry změny vlhkosti povrchu ledovců, což naznačuje změny v klimatických podmínkách.

Klasifikace krajinného pokryvu

Před samotnou detekcí změn byla provedena detekce stavu v jednotlivých letech. Přestože se v oblasti nachází pouze tři hlavní třídy krajinného pokryvu (zaledněné, nezaledněné a vodní plochy), bylo potřeba vytvořit dvojnásobný počet tříd. Vzhledem k tomu, že se jedná o hornatou oblast, nachází se množství objektů ve stínu hor. Třídy krajinného pokryvu nacházející se v zastíněných oblastech mají jiné spektrální a teplotní vlastnosti, než ty v nezastíněných oblastech, a proto pro ně byly vytvořené třídy zvlášť. Zvláštní třída musela být vytvořena i pro sut' na ledovci, která je spektrálně podobná přilehlým horninám, avšak je součástí ledovce a nachází se na místech se specifickým sklonem či nadmořskou výškou.

Pro klasifikaci krajinného pokryvu byly vyzkoušeny 3 modely strojového učení. Algoritmus KNN ukázal jako nevhodný, neboť nedokázal zachytit komplexnější vztahy mezi daty a dosáhnul poměrně nízké přesnosti klasifikace, další jeho nevýhodou byl dlouhý čas predikce. RF a GBDT dosáhly velmi podobných výsledků, RF dokonce v jednom případě i překonal výkon GBDT. S ohledem na podobnost výkonu obou algoritmů a náchylnost GBDT k přetrénování při nedostatečně optimalizovaných hyperparametrech, byl jako finální algoritmus vybrán RF. Trénování RF navíc probíhá zhruba 15-krát rychleji než u GBDT a ladění jeho parametrů je časově méně náročné.


Při ladění RF se vycházelo z předpokladu, že modely se striktnějšími kritérii mohou dosahovat srovnatelné přesnosti jako ty s méně restriktivními kritérii. Větší počet stromů totiž znamená

větší časovou náročnost, a proto bylo zkoumáno, zda toto navýšení povede k významnému zlepšení přesnosti. Důležité je také říct, že hlavním cílem optimalizace nebylo najít model s největší přesností, nýbrž model s nejlepší schopností predikce. Přesnost totiž nemusí nutně odrážet to, jak je model schopný klasifikovat původní snímek.

Bylo vyzpozorováno, že při stejném počtu proměnných, ale různém počtu stromů, dosahují modely s nižším počtem stromů stejné nebo velmi podobné přesnosti jako modely s větším počtem stromů. Navyšování počtu stromů tedy nevede k výraznému zlepšení přesnosti. Při zkoumání přesnosti modelů se stejným počtem stromů, ale různým maximálním počtem proměnných, byla pozorována poměrně velká variabilita této hodnoty. Proto byla hledána kombinace parametrů, která se vyskytuje ve všech třech letech, aby bylo možné provést srovnání. Byly nalezeny pět takových kombinací: 1) maximální počet proměnných: 9, počet stromů: 300, 2) maximální počet prvků: 9, počet stromů: 400, 3) maximální počet proměnných 9, počet stromů 500, 4) maximální počet proměnných: 7, počet stromů: 500. Bylo tedy zkoumáno, jak se liší výsledek klasifikace s využitím modelů s kombinací parametrů 1) a 5). Na základě vizuálního porovnání bylo zjištěno, že model využívající větší počet prvků dokáže lépe postihnout variabilitu tříd – například u pixelů na hranici jednotlivých tříd. Pro výsledný model byl tedy vybrán počet rozhodovacích stromů roven 300, protože při větším počtu stromů není pozorovatelné výrazné zlepšení přesnosti a počet proměnných 9, přičemž hodnota 9 představuje přibližně 40 % z celkového počtu proměnných.

RF se dokázal úspěšně vypořádat i s problematickými plochami zastíněných zaledněných i nezaledněných oblastí, což dokládá vysoké F1 skóre, které u všech tříd přesahuje 95 % s výjimkou nejproblematictější třídy sutí na ledovci, která má průměrně 90,5 %. Veškeré klasifikace však měly celkovou přesnost vyšší než 95 %, čímž se potvrzuje, že RF je efektivní při řešení složitých, nelineárních problémů, což je v souladu se závěry autorů Zhang a kol. (2019) a Khan a kol. (2020). Do analýzy nebyly zahrnuty dvě problematické třídy, a to skalní ledovce a ledovce pokryté sutí nacházející se v zastíněných oblastech. Identifikace ledovců pokrytých sutí byla ze snímků Landsat obtížná kvůli jejich prostorovému rozlišení a slabému kontrastu mezi ledovcem a okolní skálou. Pokud byly tyto ledovce zcela zakryté stíny, bylo nemožné je odlišit od okolního terénu. Kvůli prostorovému rozlišení Landsat nebyly do analýzy zahrnuty ani skalní ledovce, protože jejich povrch je na těchto snímcích k nerozeznání podobný okolnímu terénu.

Obrázek 18 ukazuje plošné zastoupení tříd, na jehož základě je možné pozorovat zmenšení rozlohy zaledněných ploch, což souvisí jak se zvýšením rozlohy nezaledněných ploch, tak i s nárůstem vodních ploch, které souvisí s táním ledovce. Dále lze také pozorovat, jak se mění množství zaledněných ploch, které jsou pokryté suti, což je pro další výzkum změny klimatu velmi důležité.



Obrázek 18: Plošné zastoupení tříd krajinného pokryvu

Přínosem se ukázala i fúze dat, kdy všechny vybrané příznaky přispěly nějakým způsobem ke klasifikaci. Kromě spektrálních příznaků patřily k nejvýznamnějším příznakům i spektrální indexy. Důležité potom bylo termální pásmo a topografické příznaky, bez kterých by šlo jen stěží odlišit ledovce pokryté suti. Texturní příznaky se ukázaly jako méně důležité, přestože se pro klasifikaci ledovců z dat Landsat běžně používají (Khan a kol. 2020; Zhang a kol. 2019). Nejméně přínosným příznakem se ukázala rychlost povrchového pohybu ledovce. Vzhledem k tomu, že data pochází z globálního produktu s nízkým prostorovým rozlišením, je možné, že v případě tvorby vlastního produktu by se tento příznak ukázal jako důležitější. Avšak je možné, že pohyb ledovců na ostrově Disko je velmi pomalý, a ani lokální produkt rychlosti povrchového pohybu ledovců by neměl pro klasifikaci takový význam. Rychlost povrchového pohybu ledovce se při klasifikaci krajinného pokryvu běžně nepoužívá, a proto je do budoucna důležité podrobněji prozkoumat její přínos.

Nevýhodou technik využívajících optických dat je jejich neschopnost rozeznat ledovce od sněhových výležisek a sezónního sněhu, v případě, že je dostupný pouze jeden snímek za celou sezónu. Mohou proto detekovat nadbytečný úbytek nebo přírůstek zaledněných ploch, který ovšem nesouvisí s plošnými změnami ledovců, což může zkreslovat informace o plošných rozlohách zalednění. Řešením tohoto problému by pak mohla být objektová klasifikace,

případně využití metod hlubokého učení jako jsou CNN, které dokážou zachytit komplexní prostorové struktury.

Detekce změn

Technika detekce změn založená na rozdílu hodnot obrazových dat se pro tento úkol ukázala jako nevhodná. Přestože tato metoda funguje pro některé autory (Kääb a kol. 2014), kteří ji využívají například pro sledování úbytku ledovců, pro účely této práce není dostačující, neboť ve zkoumaném území dochází k různým typům změn zalednění. Hlavní nevýhodou této techniky je její omezená schopnost detekovat pouze zda ke změně došlo anebo nikoliv. V případě, že by v oblasti docházelo výhradně k úbytku ledovců, by tato technika mohla být dostačující, avšak v případě, kdy dochází k různým změnám (ústup ledovce, postup ledovce, vznik supraglaciálních jezer), je nemožné získat informace o trajektorii změn.

Lu a kol. (2004) v těchto případech doporučují použít tento rozdílový obraz pro tvorbu binární masky pro další klasifikaci. V tomto případě je však tento postup nedostatečný, neboť při použití rozdílu hodnot zeleného spektrálního pásma způsobuje proměnlivost různých podmínek velkou proměnlivost hodnot odrazivosti, a i při různě zvolených prahových hodnotách dochází k nadměrné detekci nepravých změn. Lepších výsledků pak lze dosáhnout rozdílem obrazových hodnot NDSI, která detekuje změny související se změnou zalednění velmi dobře. Problém však představují ledovce pokryté sutí, které takto nelze rozeznat. Podobných výsledků lze dosáhnout s využitím termálního pásma, které si dokáže poradit s oblastmi pokrytými tenkou vrstvou suti, má však problémy v zastíněných a vlhkých oblastech. Kvůli heterogenitě sledovaného prostředí a komplexnosti jednotlivých tříd není možné využít pouze jedno pásmo pro odhad změn. Obraz binárních změn lze v tomto případě použít v rámci explorační analýzy pro získání představy o rozsahu změn a o plošném rozmístění změn, pro samotnou detekci změn je vhodnější zvolit techniky založené na klasifikaci. Techniky založené na klasifikaci byly vyzkoušeny dvě: postklasifikační porovnání a přímá multitemporální klasifikace změn.

Technika postklasifikačního porovnání poskytuje kompletní matici změn, která ukazuje směrové informace o konkrétních změnách, tedy kolik plochy třídy zůstalo stabilní a kolik se jí změnilo a jakým způsobem. Výsledek této metody je závislý na přesnosti vstupní klasifikace, neboť chyby v jednotlivých klasifikacích se při překrytí násobí. Přestože průměrná přesnost jednotlivých klasifikací byla větší než 95 %, průměrná přesnost této techniky pro detekci změn byla pouze 84,45 %. Tuto nižší přesnost však lze přiřadit i tomu, že technika byla validována na jiných datech než na kterých byla natrénována. Nevýhodou této techniky je potřeba

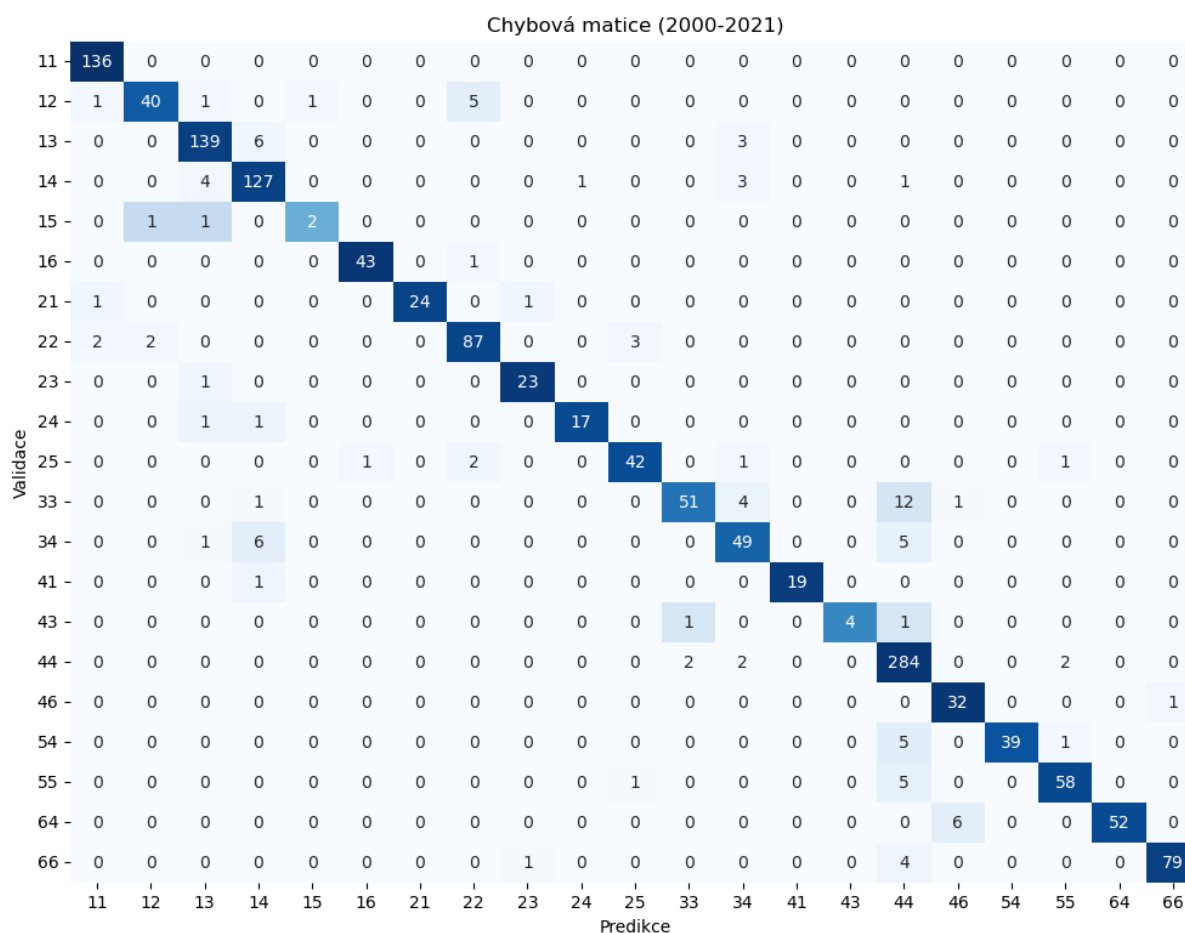
klasifikace pro každé časové období, což může být v případě složitého terénu a velkého množství snímků časově náročné. Pro tyto účely by pak bylo vhodné připravit univerzální soubor trénovacích dat, který bude obsahovat třídy v oblastech, které jsou méně náchylné na změnu, a pro každé období pak jen dodělat plošky na okrajích objektů, kde dochází ke změnám.

Další technikou byla přímá multitemporální klasifikace změn, kdy pro detekci změn mezi dvěma obdobími je potřeba pouze jedné klasifikace. Přesnost této techniky navíc vychází lépe, neboť trénovacími a validačními daty jsou přímo změnové třídy. Na druhou stranu, sběr změnových tříd může být netriviálním úkolem, zejména pokud v oblasti dochází k mnoha různým procesům. V této práci je celková přesnost přímé multitemporální klasifikace změn pomocí algoritmu RF o 10 % vyšší než u postklasifikačního porovnání. I v tomto případě se tedy RF osvědčil jako velmi dobrý klasifikátor, který se zvládnul vypořádat s multitemporálním datasetem a s nevyváženými rozložením tříd s velmi dobrou přesností.

Vstupních proměnných však bylo dvojnásobně více, a proto bylo potřeba zjistit, jak se výkon algoritmu bude s různými parametry měnit, a zda-li i v tomto případě nebude stačit menší počet stromů, aby klasifikace netrvala příliš dlouho. Jako dobrý kompromis bylo zvoleno 10 proměnných a 300 stromů se kterým byly oba multitemporální snímky klasifikovány. 10 proměnných odpovídá zhruba 22 % z celkového počtu proměnných.

Chybová matice pro období 2000–2021 na Obrázku 19 ukazuje, že největší problém představovaly nejméně zastoupené třídy změn a změnové třídy zahrnující suť a skálu. V případě že by došlo ke sloučení tříd reprezentující stejnou třídu krajinného pokryvu (zastíněných s nezastíněnými), mohla by být přesnost klasifikace vyšší, neboť i zde dochází k záměně. To může být dáno pixely ležícími na hranicích jednotlivých tříd, kdy pixel nejde jednoznačně přiřadit ani k jedné třídě.

Jednotlivé třídy jsou v matici označeny dvojicí čísel, kdy každé číslo reprezentuje jinou třídu krajinného pokryvu, přičemž první číslo označuje třídu v prvním období a druhé číslo v druhém. Kódy jsou přiřazeny následovně: 1 – zaledněné plochy, 2 – zastíněné zaledněné plochy, 3 – suť na ledovci, 4 – nezaledněné plochy, 5 – zastíněné zaledněné plochy, 6 – vodní plochy.

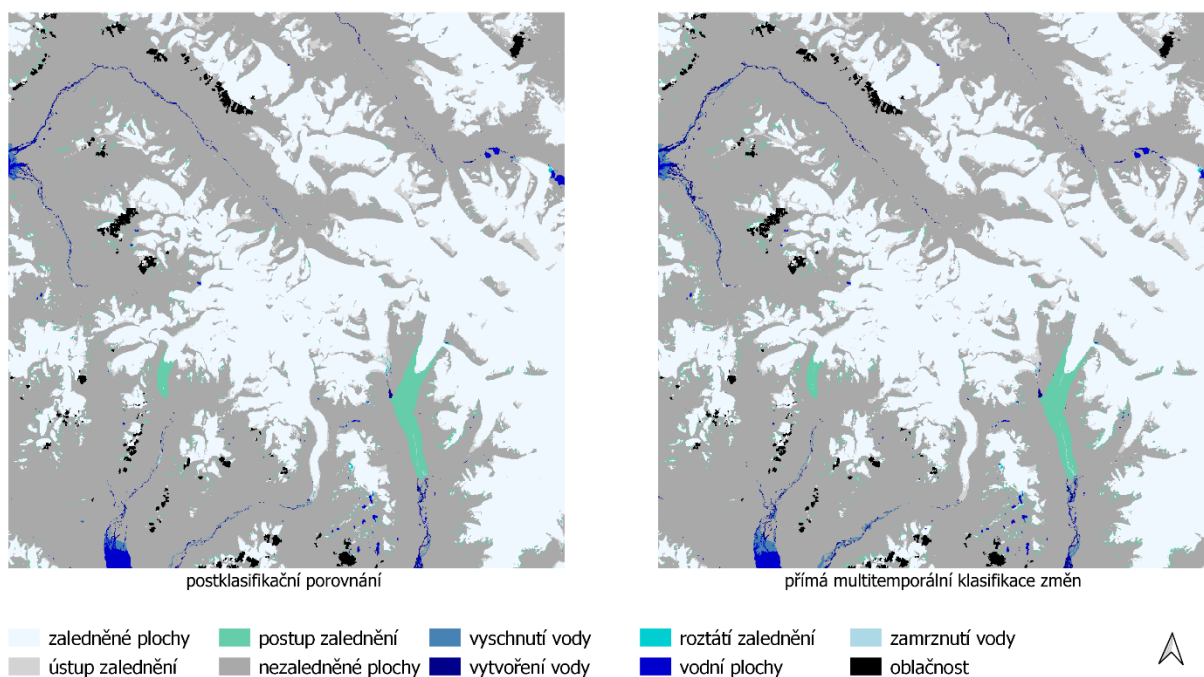


Obrázek 19: Chybová matice změnových tříd pro období 2000–2021

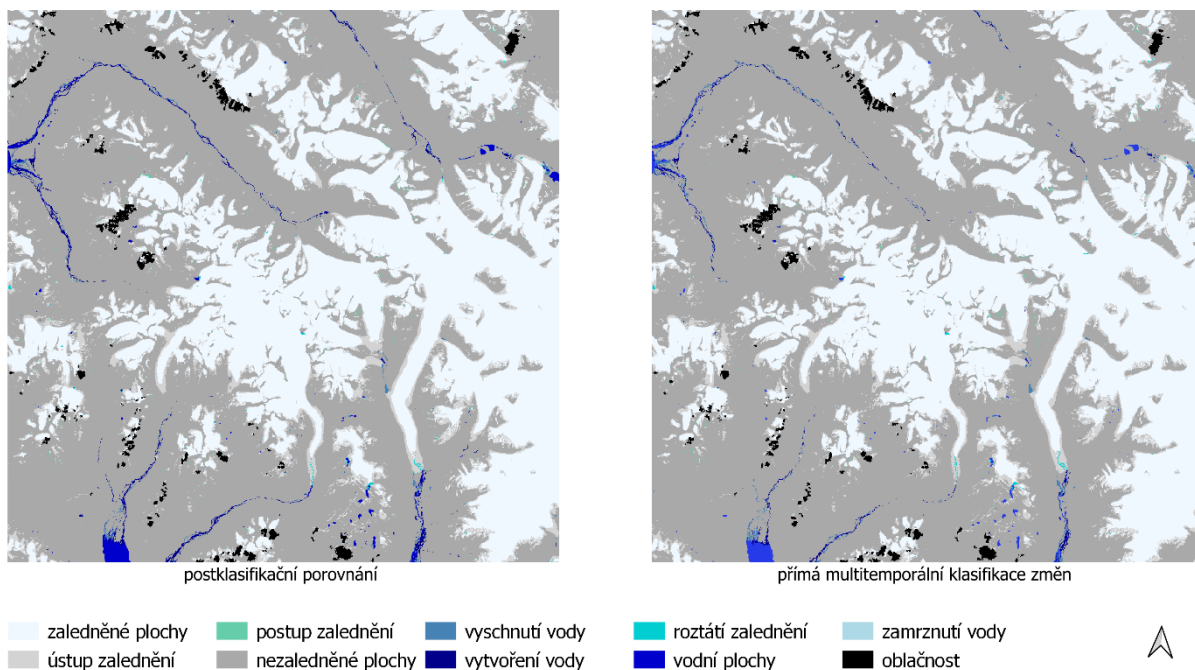
Jako poslední technika byla vyzkoušena transformace obrazu a přímá klasifikace změn. Ladění parametrů pro RF probíhalo obdobně jako u předchozí metody, kdy na základě výsledků hledání v mřížce bylo vybráno 300 stromů a 6 proměnných se kterými byly oba transformované multitemporální snímky klasifikovány. PCA transformace se jevila jako vhodná alternativa pro multitemporální klasifikaci, neboť se předpokládalo, že transformací obrazu se zvýrazní změny mezi jednotlivými obdobími a sníží se počet proměnných vstupujících do klasifikace. Transformací obrazu s využitím PCA se například autorům Deng a kol. (2008) podařilo dosáhnout lepších výsledků než u standardního postklasifikačního porovnání. V této práci sice snížení dimenze vedlo k menší výpočetní náročnosti, avšak transformace nepomohla modelu RF lépe detekovat změny. Naopak způsobila, že algoritmus strojového učení nebyl schopen transformovaný obraz dobře klasifikovat, a výsledné změnové mapy nebyly vhodné ani pro další analýzu. Lineární transformací se vytratily důležité informace o vlastnostech terénu, proto by v případě takto komplexního problému bylo vhodné vyzkoušet nelineární transformaci, případně vyzkoušet PCA jen na ty příznaky, které jsou mezi sebou hodně korelované (např. spektrální nebo texturní).

Pro detekci změn krajinného pokryvu v zaledněných horských oblastech ostrova Disko se tedy jako vhodná technika jeví postklasifikační porovnání nebo přímá multitemporální klasifikace změn. Postklasifikační porovnání dosáhlo nejlepší přesnosti i ve studii autorů Kamh a kol. (2011), kteří porovnávali techniky založené na rozdílu a poměru obrazových dat, techniku využívající barevné syntézy, transformaci obrazu pomocí PCA a přímou klasifikaci a postklasifikační porovnání. Postklasifikační porovnání patří v posledních dvou desetiletích k nejčastěji používané technice detekce změn. Technika postklasifikačního porovnání byla použita v mnoha výzkumných studiích pro různé oblasti (vegetace, urbánní oblasti, horské oblasti i zaledněné oblasti.), zatímco technika přímé multitemporální klasifikace je používána zřídka (Chugtai, Abbasi, Karas 2021).

Výsledné změnové mapy obou metod na Obrázcích 20 a 21 jsou si navzájem dost podobné a liší se především na úrovni jednotlivých pixelů, což může být způsobeno nejasným přechodem mezi jednotlivými třídami krajinného pokryvu a prostorovým rozlišením snímků Landsat. Obě mapy jsou v plném rozlišení dostupné jako Příloha 14 a 15.

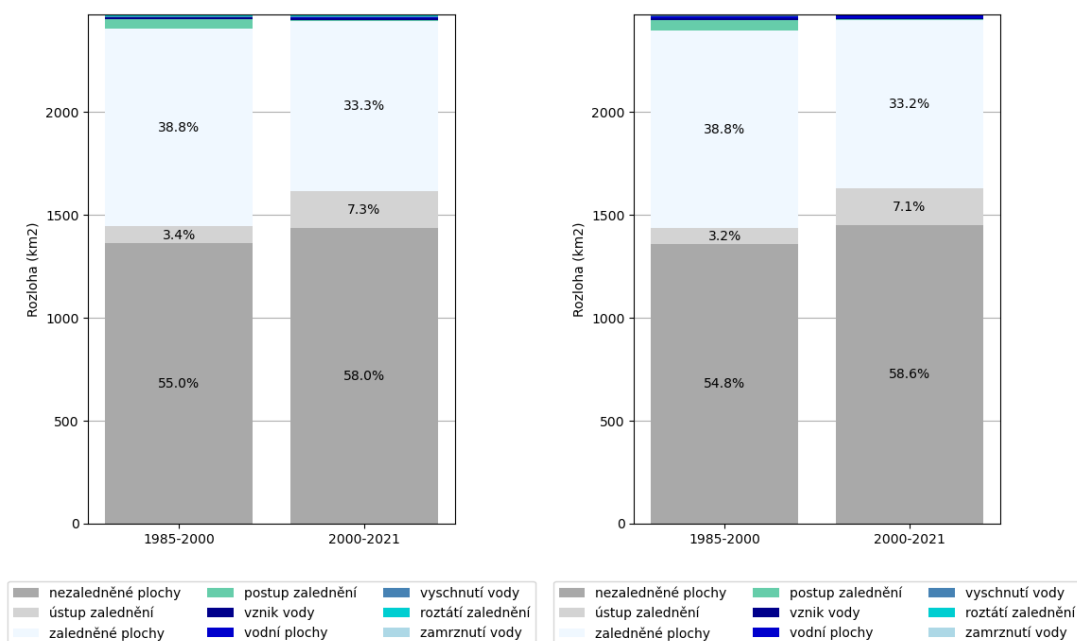


Obrázek 20: Změnové mapy pro období 1985–2000



Obrázek 21: Změnové mapy pro období 2000–2021

Rozdíly ve výsledcích jednotlivých metod lze lépe pozorovat při kvantitativním porovnání změnových ploch na Obrázku 22 (oblačnost je vynechána).



Obrázek 212: Zastoupení stabilních a změnových ploch – postklasifikační porovnání (vlevo), přímá multitemporální klasifikace změn (vpravo)

Rozdíly mezi plošným zastoupením stabilních ploch a jednotlivými kategoriemi změn se liší maximálně o 1 %. V případě stabilních ploch je takové množství zanedbatelné, avšak u jednotlivých změn může každá desetina představovat velký rozdíl. U postklasifikační metody je možné si všimnout, že detekuje více změn týkajících se vodních ploch (vyschnutí vody, vytvoření nové vody nebo roztátí ledovce). Není však možné říci, zda je to správné nebo

chybné. Vodní toky v oblasti nemají stálé koryto a často jsou z velké části zaneseny sutí. U ledovce se pak může jednat pouze o změny související s vlhkostí povrchu, nikoliv o přeměnu ledu na vodu. To je však na základě optických dat s takovýmto prostorovým rozlišením nemožné určit. Chybou postklasifikační techniky je však detekce několika mála pixelů představující změnu *zamrznutí vody*, která v období 2000–2021 nenastala.

Jednou z hlavních výhod přímé multitemporální klasifikace změn je, že při použití algoritmu RF lze získat důležitost jednotlivých příznaků pro detekci těchto změn. Důležitost jednotlivých příznaků pro detekci změn v zaledněných oblastech nebyla v literatuře dosud zkoumána. I když je důležitost příznaků možné určit i při klasifikaci krajinného pokryvu, tyto hodnoty odráží význam příznaků pro klasifikaci statického stavu, nikoliv změn. Trend důležitosti jednotlivých příznaků pro detekci změn je však velmi podobný jako u klasifikace stavu. Na základě informačního zisku se jako nejdůležitější opět ukázaly spektrální příznaky a spektrální indexy (zejména NDSI a NBR) a podle permutovaných proměnných také termální pásmo. Důležitost topografických příznaků byla nižší, protože pro všechny roky byl použit stejný výškový model.

Z hlediska validace změn napříč celým sledovaným obdobím si lépe vedla technika postklasifikačního porovnání nad technikou přímé multitemporální klasifikace změn. Pro postklasifikační porovnání vyšlo 95,5 % změn jako validních, zatímco pro přímou multitemporální klasifikaci pouze 71,8 %. To může být dáno tím, že mnoho pixelů má komplikovanou signaturu a nelze jim jednoznačně přiřadit jednu třídu (např. přechod mezi zastíněnými a nezastíněnými povrchy). V případě, že by se sloučily třídy reprezentující zastíněné a nezastíněné povrchy dohromady, mohlo by být dosaženo lepších výsledků.

Obě techniky mají své výhody a nevýhody, přesto ve srovnání s technikou založenou na rozdílu obrazových hodnot a s technikou transformace obrazu a přímou klasifikací změn dosahují velmi dobrých výsledků a jsou vhodné pro detekci změn v zaledněných horských oblastech.

Analýza změn

Z Obrázku 22 i ze změnových map na Obrázku 20 a 21 lze pozorovat, že ledovců ubývá čím dál tím více, rychlost úbytku ledu je v druhém období téměř dvojnásobná. Zatímco v prvním období (1985–2000) se ledovce zmenšily zhruba o 8,9 %, v druhém období (2000–2021) pak o 18,55 %. Během let 1985–2021 pak ustoupilo 22,69 % plochy ledovců, což je zhruba 239,4 km², což je zhruba 6,6 km² úbytku za rok. V oblasti lze tedy pozorovat vliv klimatických změn, a to nejen ústupem ledovců, ale i větším množstvím tavné vody z ledovců. Zároveň při vizuálním porovnání jsou pozorovatelné i změny v nadmořské výšce sněhové čáry a změny

vlhkosti povrchu ledovců, kdy povrchy v roce 2021 jsou mnohem lesklejší, což vypovídá o tom, že oblast je teplejší než v přechozích letech.

Horské ledovce po celém světě jsou ovlivněny globálními změnami. Ústup ledovců je pozorovatelný jak na ostrově Disko, tak po celém světě. Silva a kol. (2020) zjistili, že na antarktickém poloostrově ubylo v letech 2001–2015 1 339,68 km² ledu z celkem 1 093 ledovců. Přičemž 21 % ledovců vykazovalo ve sledovaném období výrazný ústup, 39 % ledovců vykazovalo ve sledovaném období mírný ústup u 9 % došlo k postupu (Silva a kol. 2020). Sommer a kol. (2020) zjistili že v Západních Alpách došlo v letech 2000–2014 k úbytku zhruba 39 km² plochy ledovců, což odpovídá přibližnému ročnímu úbytku o 1,8 %. V kanadských Andách autoři Ambinakudige a Intsiful (2022) zaznamenali zmenšení ploch u devíti velkých ledovců mezi lety 1985–2020. U všech devíti ledovců také došlo ke zvětšení přilehlých vodních ploch a ke zvětšení plochy ledovce pokryté sutí, což je jasným důkazem ústupu čela ledovce. Celkově se během sledovaného období ztratilo 10,4 % zaledněných ploch. Rashid a kol. (2021) v letech 1972–2019 zaznamenali ústup plochy ledovce Machoi o 29 %.

Zrychlení ústupu ledovců od začátku 21. století potvrzují například studie autorů Burns a Nolin (2014), kteří zjistili, že ledovce pohoří Cordillera Blanca v letech 2004–2010 ztrácely plochu přibližně 3,5-krát rychleji než v průměru v letech 1970–2003. V ledovcové oblasti Ladak, která se nachází mezi Himálajemi a Karákóramem, ztratili ledovce v letech 2000–2016 3-krát více plochy než v období 1969–2000 (Schmidt a Nüsser 2017).

Pro pochopení dopadů změn je proto i nadále potřeba sledovat změny nejen v rozloze, ale i v objemu ledovců v průběhu času. Očekává se, že ledovce a ostatní prvky kryosféry v horských oblastech budou i v následujících letech ubývat v důsledku rostoucích teplot. Ústup ledovců má vliv na hydrologické a ekologické režimy s významnými globálními a regionálními důsledky. Oteplování klimatu bude mít pro obyvatele ostrova Disko i nadále důsledky, z nichž mnohé jsou negativní: stoupající hladina moře zvýší míru pobřežní eroze, tání věčně zmrzlé půdy ovlivní stabilitu infrastruktury, snížení tloušťky a pokrytí mořským ledem bude mít dopad na tradiční obživu a oteplování pobřežních vod ovlivní zdraví populace a prostorové rozmístění komerčně lovených druhů ryb (AMAP 2017).

6 Závěr

Hlavním cílem diplomové práce bylo navrhnout metodu detekce pločných změn pro zaledněné horské oblasti, a odlišit skutečné změny (ústup, postup zalednění, vznik jezer) od změn nepravých (změny zastínění, změny stavu jednotlivých ledovcových zón). Dále potom implementovat navrženou metodu pro vizualizaci jednotlivých změn pomocí změnových map pro dvě sledovaná období (1985–2000 a 2000–2021), a ověřit vhodnost příznaků. Klíčovým úkolem byla volba modelu strojového učení pro odlišení jednotlivých tříd na základě různých vlastností povrchu.

K dosažení těchto cílů byla rozebrána teoretická východiska týkající se klimatických změn a ledovců, využití různých senzorů DPZ pro monitorování parametrů ledovců, využití metod strojového učení a rozbor používaných technik detekce změn. Postup byl implementován výhradně s využitím Open Source technologií. Pro přípravu dat a vizualizaci změnových map sloužil software QGIS, zatímco jednotlivé techniky detekce změn, hodnocení jejich přesnosti a kvantitativní vyhodnocení bylo naprogramováno v jazyce Python.

Pro odlišení problematických ploch bylo vybráno celkem 23 příznaků – spektrální odrazivost v červeném, zeleném, modrém, blízkém infračerveném a krátkovlnných infračervených pásmech, spektrální indexy (NDSI, NDWI, NBR), záření v termálním pásmu, nadmořská výška, sklonitost terénu, orientace, zastínění, drsnost povrchu, druhý úhlový moment, kontrast, korelace, suma průměrů, suma rozptylu, entropie, inverzní diferencní moment a povrchová rychlost pohybu ledovce.

Jako vhodnou technikou detekce změn se kromě postklasifikačního porovnání osvědčila přímá multitemporální klasifikace změn, díky které bylo možné odlišit nepravé změny od skutečných s velmi dobrou přesností, a zároveň získat informace o přínosu jednotlivých příznaků pro detekci změn zalednění. Na základě analýzy změn byl ve sledované oblasti pozorovatelný ústup zalednění, který v druhém sledovaném období akceleruje.

Random Forest se osvědčil jako velmi dobrý klasifikátor, neboť se zvládl vypořádat s komplexností tříd a vysokou dimenzionalitou, jak při klasifikaci stavu, tak při detekci změn s velmi vysokou přesností. Kromě toho umožňuje RF hodnocení důležitosti jednotlivých proměnných, což poskytuje cenné informace o tom, které příznaky nejvíce přispívají k přesnosti modelu. Největší přínos pro detekci změn měly spektrální příznaky, spektrální indexy a termální pásmo.

Zdroje

ALIFU, H. a kol. (2015): A new band ratio technique for mapping debris-covered glaciers using landsat imagery and a digital elevation model. *International Journal of Remote Sensing*, 36, 8, 2063–2075.

ALIFU, H. a kol. (2020): Machine-learning classification of debris-covered glaciers using a combination of sentinel-1/-2 (SAR/Optical), Landsat 8 (thermal) and Digital Elevation Data. *Geomorphology*, 369.

AMBINAKUDIGE, S., INTSIFUL, A. (2022): Estimation of area and volume change in the glaciers of the Columbia Icefield, Canada using machine learning algorithms and landsat images. *Remote Sensing Applications: Society and Environment*, 26.

ANTONIOL, G., BASCO, C., CECCARELLI, M., METZ, M., LENNERT, M. (2024): r.texture - GRASS GIS 8.3 Manual. OSGeo – Open Source Geospatial Foundation, <https://grass.osgeo.org/grass83/manuals/r.texture.html> (cit. 9. 3. 2024).

AMAP (2017): Baffin Bay / Davis Strait Region Overview Report. Arctic Monitoring and Assessment Programme (AMAP), Tromsø, Norsko.

AMAP (2021): Arctic Climate Change Update 2021: Key Trends and Impacts. Arctic Monitoring and Assessment Programme (AMAP), Tromsø, Norsko.

BERBEROGLU, S., AKIN, A. (2009): Assessing different remote sensing techniques to detect land use/cover changes in the eastern mediterranean. *International Journal of Applied Earth Observation and Geoinformation*, 11, 1, 46–53.

BURNS, P., NOLIN, A. (2014): Using atmospherically-corrected landsat imagery to measure glacier area change in the Cordillera Blanca, Peru from 1987 to 2010. *Remote Sensing of Environment*, 140, 165–178.

BELGIU, M., DRĂGUȚ, L. (2016): Random Forest in remote sensing: A review of applications and Future Directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31.

CALLAGHAN, T., CHRISTIENSEN, T. R., JANTZE, E. (2011): Plant and Vegetation Dynamics on Disko Island, West Greenland: Snapshots Separated by Over 40 Years. *Ambio*, 40, 6, 624–37.

- CAUFIELD, R., A. (1993): Aboriginal subsistence whaling in Greenland: The case of Qeqertarsuaq in west Greenland. *Arctic*, 46, 2, 144–159.
- CHEN, Y.-N., FAN, K.-C., CHANG, Y.-L., MORIYAMA, T. (2023): Special issue review: Artificial intelligence and machine learning applications in remote sensing. *Remote Sensing*, 15, 3, 569.
- CHRISTIANSEN, H. H. (1995): Observations of open system pingos in a marsh environment, Mellemfjord, Disko, Central West Greenland. – *Geografisk Tidsskrift – Danish Journal of Geography* 95: 42–48.
- CHRISTIANSEN, H. H., HUMLUM, O. (2000): Permafrost. In: Jakobsen, B. H. a kol. (ed): *Topografisk Atlas, Grønland*. – Det Kongelige Geografiske Selskab og Kort og Matrikelstyrelsen, 32–35.
- CHUGHTAI, A. H., ABBASI, H., KARAS, I. M. (2021): A review on Change Detection Method and accuracy assessment for land use land cover. *Remote Sensing Applications: Society and Environment*, 22, 100482.
- DENG, J.S., WANG, K., DENG, Y- H., QI, G. J. (2008): PCA-based land-use change detection and analysis using multitemporal and Multisensor Satellite Data. *International Journal of Remote Sensing*, 29, 16, 4823–4838.
- eoPortal (2024): Satellite Missions Catalogue, <https://www.eoportal.org/satellite-missions?Mission+type=EO> (cit. 4.7.2024).
- FRIEDL, M. A., BRODLEY, C. E. (1997): Decision Tree Classification of land cover from remotely sensed data. *Remote Sensing of Environment*, 61, 3, 399–409.
- GARDNER, A. S., FAHNESTOCK M. A., SCAMBOS T. A. (2023): ITS_LIVE Regional Glacier and Ice Sheet Surface Velocities. Data archived at National Snow and Ice Data Center, <https://doi.org/10.5067/6II6VW8LLWJ7> (cit. 4.12.2023).
- GISLASON, P. O., BENEDIKTSSON, J., A., SVEINSSON, J., R. (2006): Random forests for land cover classification. *Pattern Recognition Letters*, 27, 4, 294–300.
- GOLDHAR, C., FORD, J. D. (2010): Climate change vulnerability and food security in Qeqertarsuaq, Greenland. *Community Adaptation and Vulnerability in Arctic Regions*, 263–283.

HALL, D. K., MARTINEC, J. (1985): Remote Sensing of Ice and Snow, London, New York: Chapman & Hall.

HALL-BEYER, M. (2017): Practical guidelines for choosing GLCM textures to use in landscape classification tasks over a range of moderate spatial scales. *International Journal of Remote Sensing*, 38, 5, 1312–1338.

HARALICK, R. M., SHANMUGAM, K., DINSTEN, I. (1973): Textural features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3, 6, 610–621.

HJARTARSON, A., ARMANNSSON, H. (2010). Geothermal research in Greenland. In *Proceedings World Geothermal Congress 2010*. Bali, Indonesia, April 25-29, 2010.

HOLLESEN, J., BUCHWAL, A., RACHLEWICZ, G., HANSEN, B. U., HANSEN, M. O., STECHER, O., ELBERLING, B. (2015): Winter warming as an important co-driver for *Betula nana* growth in western Greenland during the past century. – *Global change biology*, 21, 2410-2423.

HUMLUM, O. (1982): Rock glacier types on Disko, central West Greenland. *Geografisk Tidsskrift-Danish Journal of Geography*, 82, 59–66.

HUMLUM, O. (1987): Glacier behaviour and the influence of upper-air conditions during the Little Ice Age in Disko, central West Greenland. *Geografisk Tidsskrift-Danish Journal of Geography*, 87, 1, 1–12.

HUMLUM, O. (1988): Rock glacier appearance level and Rock Glacier Initiation Line Altitude: A methodological approach to the study of Rock Glaciers. *Arctic and Alpine Research*, 20, 2, 160.

HUMLUM, O. (1998): The Climatic Significance of Rock Glaciers. *Permafrost and periglacial processes*, 9, 375-395.

HUSSAIN, M., CHEN, D., CHENG, A., WEI, H., STANLEY, D. (2013): Change detection from remotely sensed images: From pixel-based to object-based approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80, s. 91–106.

JAMES, G., WITTEN, D., HASTIE, T., TIBSHIRANI, R. (2023): An introduction to statistical learning with applications in Python. Springer International Publishing, Cham.

JEŽEK, J. (2016): *Geostatistika a prostorová interpolace*. Karolinum, Praha.

- KÄÄB, A., BOLCH, T., CASEY, K. A., HEID, T., KARGEL, J. S., LEONARD, G. J., PAUL, F., RAUP, B. E. H. (2014): Glacier mapping and monitoring using multispectral data. In: Kargel, J. S. a kol. (ed.): Global Land Ice Measurements from Space. ANON. (2014): Springer Berlin Heidelberg, Berlin, Heidelberg, 75–112.
- KAMH, S., MAHMOUD, A., KILIAS, A., CHRISTARAS, B. (2011): Evaluating urban land cover change in the Hurghada area, Egypt, by using GIS and Remote Sensing. *International Journal of Remote Sensing*, 33, 1, 41–68.
- KUMAR, S., ARYA, S. (2021): Change detection techniques for land cover change analysis using spatial datasets: A Review. *Remote Sensing in Earth Systems Sciences*, 4, 3, 172–185.
- KHAN, A. A., JAMIL, A., HUSSAIN, D., TAJ, M., JABEEN, G., MALIK, M. K. (2020): Machine-learning algorithms for mapping debris-covered glaciers: The Hunza Basin Case Study. *IEEE Access*, 8, 12725–12734.
- KUHN, M. (2010): The formation and dynamics of glaciers. In: Pellikka, P., Rees, W., G. (ed.): *Remote Sensing of Glaciers*. Taylor & Francis Group, London, 21–39.
- LARY, D. J., ALAVI, A. H., GANDOMI, A. H., WALKER, A. L. (2016): Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7, 1, 3–10.
- LU, D., MAUSEL, P., BRONDÍZIO, E., MORAN, E. (2004): Change detection techniques. *International Journal of Remote Sensing*, 25, 12, 2365–2401.
- MAXWELL, A. E., WARNER, T. A., FANG, F. (2018): Implementation of machine-learning classification in Remote Sensing: An applied review. *International Journal of Remote Sensing*, 39, 9, 2784–2817.
- MAXWELL, A. E., WARNER, T. A., GUILLÉN, L. A. (2021): Accuracy assessment in convolutional neural network-based Deep Learning Remote Sensing Studies—part 2: Recommendations and best practices. *Remote Sensing*, 13, 13, 2591.
- NIJHAWAN, R., GARG, P., THAKUR, P. (2016): A comparison of classification techniques for glacier change detection using multispectral images. *Perspectives in Science*, 8, 377–380.
- NSIDC (2024): Glaciers, <https://nsidc.org/learn/parts-cryosphere/glaciers> (cit. 5. 6. 2024).

- OLOFSSON, P., FOODY, G. M., HEROLD, M., STEHMAN, S. V., WOODCOCK, C.E., WULDER, M. A. (2014): Good practices for estimating area and assessing accuracy of Land Change. *Remote Sensing of Environment*, 148, 42–57.
- PACHECO, A., JUNIOR, J. A. d. S., RUIZ-ARMENTEROS, A. M., HENRIQUES, R. F. F. (2021): Assessment of K-nearest neighbor and Random Forest classifiers for mapping forest fire areas in central Portugal using landsat-8, sentinel-2, and Terra imagery. *Remote Sensing*, 13, 7, 1345.
- PANDEY, P., RAMANATHAN, A., VENKATARAMAN, G. (2016): Remote sensing of mountain glaciers and related hazards. In: Marghany, M. (ed.): *Environmental Applications of Remote Sensing*. InTech, 131–162.
- PAUL, F., HENDRIKS, J. (2010): Detection and visualization of glacier area changes. In: Pellikka, P., Rees, W., G. (ed.): *Remote Sensing of Glaciers*. Taylor & Francis Group, London, 231–243.
- PAUL, F. (2011): Automated Glacier Mapping. In: Singh, V. P, Singh, P, Haritashya, U. K. (ed.) *Encyclopedia of Snow, Ice and Glaciers*. Dordrecht: Springer, 76–85.
- PEDREGOSA, F., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., GRISEL, O., BLONDEL, M., PRETTENHOFER, P., WEISS, R., DUBOURG, V., VANDERPLAS, J., PASSOS, A., COURNAPEAU, D., BRUCHER, M., PERROT, M., DUCHESNAY, É. (2011): Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- PELLIKKA, P., REES, W., G. (2010a): Principles of remote sensing. In: Pellikka, P., Rees, W., G. (ed.): *Remote Sensing of Glaciers*. Taylor & Francis Group, London, 1–20.
- PELLIKKA, P., REES, W., G. (2010b): Glacier parameters monitored using remote sensing. In: Pellikka, P., Rees, W., G. (ed.): *Remote Sensing of Glaciers*. Taylor & Francis Group, London, 21–39.
- PORTER, C., HOWAT, I., NOH, M.-J., HUSBY, E., KHUVIS, S., DANISH, E., TOMKO, K., GADINER, J., NEGRETE, A., YADAV, B., KLASSEN, J., KELLEHER, C., CLOUTIER, M., BAKKER, J., ENOS, J., ARNOLD, G., BAUER, G., MORIN, P. (2023): 'ArcticDEM, Version 4.1', Harvard Dataverse, <https://doi.org/10.7910/DVN/3VDC4W> (cit. 4. 1. 2024).

- RAMAGE, J., JUNGSBERG, L., MEYER, A., GARTLER, S. (2022): ‘No longer solid’: Perceived impacts of permafrost thaw in three Arctic communities. *Polar Geography*, 45, 3, 226–239.
- RASHID, I., NAJAR, N. A, MAJEED, U., BHAT, I., A. (2021): Retreat of Machoi Glacier, Kashmir Himalaya between 1972 and 2019 using remote sensing methods and field observations. *Science of The Total Environment*, 785, 147376.
- RAUP, H., B., ANDREASSEN, L. M., BOLCH, T., BEVAN, S. (2014): Remote sensing of glaciers. In: Tedesco, M. (ed.): *Remote Sensing of the Cryosphere*. John Wiley & Sons, New York, 123–156.
- RAZA, I.-U.-R., KAZMI, S. S. A, ALI, S. S., HUSSAIN, E. (2012): Comparison of pixel-based and object-based classification for Glacier Change Detection. 2012 Second International Workshop on Earth Observation and Remote Sensing Applications.
- SI SALAH, H., GOLDIN, S. E, REZGUI, A., ISLAM B. N. E, AIT-AOUDIA, S. (2019): What is a remote sensing change detection technique? towards a conceptual framework. *International Journal of Remote Sensing*, 41, 5, 1788–1812.
- SCHMIDT, S., NÜSSER, M. (2017): Changes of high altitude glaciers in the Trans-himalaya of Ladakh over the past five decades (1969–2016). *Geosciences*, 7, 2, 27.
- SILVA, A. B., ARIGONY-NETO, J., BRAUN, M. H, ESPINOZA, J. M. A., COSTI, J., JAÑA, R. (2020): Spatial and temporal analysis of changes in the glaciers of the Antarctic Peninsula. *Global and Planetary Change*, 184, 103079.
- SOMMER, C., SEEHAUS, T. C, LIPPL, S., ZEMP, M., BRAUN, M. H. (2020): Rapid glacier retreat and downwasting throughout the European Alps in the early 21st Century. *Nature Communications*, 11, 1.
- SOOD, V., GUSAIN, H., S., GUPTA, S, TALOOR, A. K., SINGH, S. (2020): Detection of snow/ice cover changes using subpixel-based change detection approach over Chhota-Shigri Glacier, Western Himalaya, India. *Quaternary International*, 575–576, 204–212.
- Statistics Greenland (2023): *Greenland in Figures 2023* (20. edice). Statistics Greenland. Nuuk.
- TAYLOR, L. S., QUINCEY, D., J., SMITH, M, W., BAUMHOER, C., A., MCMILLAN, M., MANSELL, D., T. (2021): Remote Sensing of the mountain cryosphere: Current capabilities

and future opportunities for research. *Progress in Physical Geography: Earth and Environment*, 45, 6, 931–964.

TEDESCO, M. (2014a): Remote sensing and the cryosphere. In: Tedesco, M. (ed.): *Remote Sensing of the Cryosphere*. John Wiley & Sons, New York, 1–16.

TEDESCO, M. (2014b): Electromagnetic properties of components of the cryosphere. In: Tedesco, M. (ed.): *Remote Sensing of the Cryosphere*. John Wiley & Sons, New York, 17–30.

TEWKESBURY, A. P., COMBER, A. J., TATE, N., J., LAMB, A., FISHER, P. F. (2015): A critical synthesis of remotely sensed optical image change detection techniques. *Remote Sensing of Environment*, 160, 1–14.

UHULAG (2024): Dálkový průzkum Země. Prezentace k přednáškám. Ústav geoinformačních technologií, Lesnická a dřevařská fakulta MENDELU, <http://uhulag.mendelu.cz/cz/studium/dpz> (cit. 4. 3. 2024).

USGS (2023): Landsat Mission, Landsat Satellite Missions, <https://www.usgs.gov/landsat-missions/landsat-satellite-missions> (cit. 4.12.2023).

WARMERDAM, F., ROUAULT, E. (2024): GDAL SieveFilter, https://gdal.org/programs/gdal_sieve.html (cit. 4. 3. 2024).

WEGEBERG, S., BOERTMANN, D. (2016): Disko Island and Nuussuaq Peninsula, West Greenland. A strategic environmental impact assessment of petroleum exploration and exploitation. Scientific Report from DCE, Danish Centre for Environment and Energy, Aarhus University, 199.

YDE, J. C., KNUDSEN, N. T. (2007): 20th-century glacier fluctuations on Disko Island (Qeqertarsuaq), Greenland. *Annals of Glaciology*, 46, 209–214.

ZHANG, J., JIA, LI., MENENTI, M., GUANGCHENG, H. (2019): Glacier Facies Mapping Using a Machine-Learning Algorithm: The Parlung Zangbo Basin Case Study. *Remote Sensing*, 4, 11, 452.

Přílohy

Příloha 1: Porovnání přesnosti a rychlosti algoritmů

Příloha 2: Výsledek hledání v mřížce pro klasifikaci jednotlivých let

Příloha 3: Výsledek hledání v mřížce pro klasifikaci změn

Příloha 4: Výsledek hledání v mřížce pro klasifikaci změn v transformovaném obraze

Příloha 5: Vizualizace snímků v nepravých barvách

Příloha 6: Krajinný pokryv v roce 1985

Příloha 7: Krajinný pokryv v roce 2000

Příloha 8: Krajinný pokryv v roce 2021

Příloha 9: Binární změnová mapa pro období 1985–2000

Příloha 10: Binární změnová mapa pro období 2000–2021

Příloha 11: Postklasifikační porovnání změn

Příloha 12: Přímá multitemporální klasifikace změn

Příloha 13: Transformace obrazu a klasifikace změn

Příloha 14: Porovnání změnových map pro období 1985–2000

Příloha 15: Porovnání změnových map pro období 2000–2021

	1985			2000			2021		
	Přesnost (%)	Trénování (s)	Predikce (s)	Přesnost (%)	Trénování (s)	Predikce (s)	Přesnost (%)	Trénování (s)	Predikce (s)
KNN	76,54	0,1	184,98	77,48	0,08	186,46	68,76	0,09	169,06
RF	96,73	2,9	24,22	97,27	2,68	27,2	96,27	3,26	26,42
GBDT	97,03	45,28	21,94	97,5	43,2	26,19	95,83	55,34	21,79

Příloha 1: Porovnání přesnosti a rychlosti algoritmů

pořadí	1985		2000		2021	
	přesnost (%)	parametry	přesnost (%)	parametry	přesnost (%)	parametry
1	97,05	{'max_features': 9, 'n_estimators': 100}	96,76	{'max_features': 9, 'n_estimators': 400}	96,07	{'max_features': 9, 'n_estimators': 200}
2	97,05	{'max_features': 7, 'n_estimators': 200}	96,76	{'max_features': 7, 'n_estimators': 400}	95,05	{'max_features': 8, 'n_estimators': 500}
3	97,03	{'max_features': 9, 'n_estimators': 300}	96,72	{'max_features': 7, 'n_estimators': 500}	96,03	{'max_features': 9, 'n_estimators': 400}
4	97,03	{'max_features': 7, 'n_estimators': 300}	96,7	{'max_features': 9, 'n_estimators': 500}	96,01	{'max_features': 9, 'n_estimators': 300}
5	97,01	{'max_features': 9, 'n_estimators': 500}	96,68	{'max_features': 5, 'n_estimators': 500}	95,99	{'max_features': 9, 'n_estimators': 500}
6	97,01	{'max_features': 8, 'n_estimators': 500}	96,68	{'max_features': 8, 'n_estimators': 100}	95,99	{'max_features': 8, 'n_estimators': 200}
7	97,01	{'max_features': 8, 'n_estimators': 400}	96,66	{'max_features': 5, 'n_estimators': 400}	95,99	{'max_features': 7, 'n_estimators': 500}
8	97,01	{'max_features': 7, 'n_estimators': 500}	96,65	{'max_features': 9, 'n_estimators': 300}	95,96	{'max_features': 9, 'n_estimators': 100}
9	96,99	{'max_features': 9, 'n_estimators': 400}	96,65	{'max_features': 9, 'n_estimators': 200}	95,96	{'max_features': 7, 'n_estimators': 400}
10	96,99	{'max_features': 5, 'n_estimators': 500}	96,65	{'max_features': 6, 'n_estimators': 400}	95,92	{'max_features': 8, 'n_estimators': 400}

Příloha 2: Výsledek hledání v mřížce pro klasifikaci jednotlivých let

pořadí	1985-2000		2000-2021	
	přesnost (%)	parametry	přesnost (%)	parametry
1	96,16	{'max_features': 10, 'n_estimators': 300}	93,4	{'max_features': 7, 'n_estimators': 200}
2	96,15	{'max_features': 15, 'n_estimators': 300}	93,37	{'max_features': 8, 'n_estimators': 500}
3	96,13	{'max_features': 9, 'n_estimators': 500}	93,35	{'max_features': 8, 'n_estimators': 400}
4	96,11	{'max_features': 10, 'n_estimators': 400}	93,33	{'max_features': 10, 'n_estimators': 300}
5	96,11	{'max_features': 15, 'n_estimators': 100}	93,32	{'max_features': 9, 'n_estimators': 400}
6	96,11	{'max_features': 9, 'n_estimators': 400}	93,3	{'max_features': 9, 'n_estimators': 200}
7	96,11	{'max_features': 15, 'n_estimators': 500}	93,3	{'max_features': 15, 'n_estimators': 400}
8	96,11	{'max_features': 10, 'n_estimators': 500}	93,3	{'max_features': 8, 'n_estimators': 200}
9	96,09	{'max_features': 7, 'n_estimators': 300}	93,3	{'max_features': 12, 'n_estimators': 400}
10	96,09	{'max_features': 15, 'n_estimators': 200}	93,28	{'max_features': 9, 'n_estimators': 500}


Příloha 3: Výsledek hledání v mřížce pro klasifikaci změn

pořadí	1985-2000		2000-2021	
	přesnost (%)	parametry	přesnost (%)	parametry
1	88,92	{'max_features': 4, 'n_estimators': 300}	85,47	{'max_features': 4, 'n_estimators': 500}
2	88,87	{'max_features': 4, 'n_estimators': 400}	85,31	{'max_features': 4, 'n_estimators': 300}
3	88,81	{'max_features': 4, 'n_estimators': 500}	85,31	{'max_features': 4, 'n_estimators': 400}
4	88,81	{'max_features': 6, 'n_estimators': 300}	85,31	{'max_features': 5, 'n_estimators': 500}
5	88,76	{'max_features': 6, 'n_estimators': 400}	85,28	{'max_features': 5, 'n_estimators': 400}
6	88,76	{'max_features': 6, 'n_estimators': 500}	85,16	{'max_features': 6, 'n_estimators': 500}
7	88,73	{'max_features': 4, 'n_estimators': 200}	85,16	{'max_features': 6, 'n_estimators': 300}
8	88,67	{'max_features': 5, 'n_estimators': 400}	85,14	{'max_features': 5, 'n_estimators': 300}
9	88,65	{'max_features': 6, 'n_estimators': 100}	85,11	{'max_features': 6, 'n_estimators': 400}
10	88,65	{'max_features': 5, 'n_estimators': 500}	85,11	{'max_features': 4, 'n_estimators': 100}


Příloha 4: Výsledek hledání v mřížce pro klasifikaci změn v transformovaném obraze

Příloha 5: Změny krajinného pokryvu na ostrově Disko


vizualizace v nepravých barvách



1985



2000




2021



Příloha 6: Ostrov Disko

krajinný pokryv v roce 1985




Typ krajinného pokryvu

- zaledněné plochy
- zastíněné zaledněné plochy
- sut' na ledovci
- nezaledněné plochy
- zastíněné nezaledněné plochy
- vodní plochy



Příloha 7: Ostrov Disko

krajinný pokryv v roce 2000




Typ krajinného pokryvu

- oblačnost
- zaledněné plochy
- zastíněné zaledněné plochy
- sut' na ledovci
- nezaledněné plochy
- zastíněné nezaledněné plochy
- vodní plochy



Příloha 8: Ostrov Disko

krajinný pokrýv v roce 2021




Typ krajinného pokrýv

- zaledněné plochy
- zastíněné zaledněné plochy
- sut' na ledovci
- nezaledněné plochy
- zastíněné nezaledněné plochy
- vodní plochy




Příloha 9: Změny krajinného pokryvu na ostrově Disko


rozdíli hodnot obrazových dat pro období 1985–2000



zelené pásma



NDSI




termální pásma

■ nezměněné plochy □ změněné plochy




Příloha 10: Změny krajinného pokryvu na ostrově Disko


rozdíl hodnot obrazových dat pro období 2000–2021



zelené pásmo



NDSI





termální pásmo

■ nezměněné plochy □ změněné plochy





Příloha 11: Změny krajinného pokryvu na ostrově Disko

postklasifikační porovnání





Příloha 12: Změny krajinného pokryvu na ostrově Disko

přímá multitemporální klasifikace změn



Příloha 13: Změny krajinného pokryvu na ostrově Disko

transformace a klasifikace změn



zaledněné plochy
ústup zalednění

postup zalednění
nezaledněné plochy

vyschnutí vody
vytvorení vody



roztátí zalednění
vodní plochy

zamrznutí vody
oblačnost



Příloha 14: Změny krajinného pokryvu na ostrově Disko

mezi lety 1985–2000



Příloha 15: Změny krajinného pokryvu na ostrově Disko

mezi lety 2000–2021

