

Univerzita Karlova
Přírodovědecká fakulta

Studijní program: Geografie
Studijní obor: Kartografie a geoinformatika



Bc. Tereza Klímová

**URČENÍ VÝSKYTU SNĚHOVÝCH LAVIN
Z DRUŽICOVÝCH DAT POŘÍZENÝCH RADAREM SE
SYNTETICKOU APERTUROU (SAR)**

**DETECTION OF SNOW AVALANCHE DEBRIS FROM
SATELLITE SYNTHETIC APERTURE RADAR (SAR) DATA**

Diplomová práce

Vedoucí práce: doc. Ing. Jan Kolář, CSc.

Praha 2019

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 ani stejného akademického titulu.

Ve Zdíkově, 31. 7. 2019

.....
Tereza Klímová

Poděkování

Na tomto místě bych chtěla poděkovat vedoucímu své práce doc. Ing. Janu Kolářovi, CSc. za cenné rady a připomínky, přátelům, a hlavně rodině za podporu během celé doby studia.

URČENÍ VÝSKYTU SNĚHOVÝCH LAVIN Z DRUŽICOVÝCH DAT POŘÍZENÝCH RADAREM SE SYNTETICKOU APERTUROU (SAR)

Abstrakt

Práce se zabývá určováním míst s lavinovým proudem na radarových snímcích pořízených radarem se syntetickou aperturou na družici Sentinel-1. Hlavním cílem je navrhnout postup pro rozpoznání míst na snímku, kde spadla sněhová lavina. Metodika je založena na principu neuronových sítí, konkrétně na využití předtrénovaného modelu neuronové sítě VGG-19. Dle výsledku trénování neuronové sítě jsou následně výřezy snímků zařazovány do dvou kategorií: na snímku se nachází nebo nenachází lavina. Jedná se tedy o binární klasifikaci. Výsledkem je statistické zhodnocení úspěšnosti zařazování do kategorií a porovnání s tradičními postupy.

klíčová slova: lavina, Sentinel-1, neuronová síť, VGG-19

DETECTION OF SNOW AVALANCHE DEBRIS FROM SATELLITE SYNTHETIC APERTURE RADAR (SAR) DATA

Abstract

This thesis engages with detection of snow avalanche debris at radar images taken with synthetic aperture radar on Sentinel-1 satellite. The aim is to find method for recognizing places at image where is the snow avalanche debris. A method is based on neural net principle, specifically on using pre-trained model of neural net VGG-19. According to results of neural net, training images are splitted into two categories: there is an avalanche and there is not. It is called binary classification. The result is statistical evaluation of success rate compared with other traditional methods.

keywords: snow avalanche, Sentinel-1, neural net, VGG-19

Obsah

Seznam použitých zkratk	6
Seznam obrázků	7
Seznam tabulek	8
1. Úvod	9
2. Mapování sněhových lavin	11
2.1 Pozemní mapování lavin	11
2.2 Mapování za pomoci DPZ	12
2.3 Detekce lavin radary se syntetickou aperturou	13
2.3.1 Princip radaru	13
2.3.2 Charakteristika radarového signálu	17
2.3.3 Sněhové charakteristiky při snímání radarem	20
2.3.4 Sněhová lavina	22
2.3.5 Metody určování lavin z radarových dat	23
2.3.5.1 AVAMAP	25
2.4 Neuronové sítě	25
2.4.1 Konvoluční neuronové sítě	26
2.4.2 Neuronová síť VGG-19	28
3. Data a metodika	33
3.1 Výběr a zpracování dat	33
3.1.1 Výběr území	34
3.1.2 Předzpracování a výběr radarových snímků	36
3.1.3 Výběr míst s lavinovým proudem	38
3.2 Metodika	44
3.2.1 Volba neuronové sítě	44
4. Výsledky	46
4.1 Tvorba datasetu	46
4.2 Trénování neuronové sítě	46
4.3 Hodnocení jednotlivých snímků	50
5. Diskuze	55
6. Závěr	57
Použitá literatura	58
Seznam příloh	62

Seznam použitých zkratek

Adam	Adaptive Model Estimation
AVAMAP	Worldwide avalanche detection using Sentinel-1
dB	Decibel
DPZ	Dálkový průzkum Země
DSM	Digital Surface Model
DTM	Digitální model terénu
ERS	European Remote Sensing
ESA	Evropská vesmírná agentura
GHz	Gigahertz
GPS	Global Positioning System
H	Horizontální polarizace
LiDaR	Light Detection and Ranging
NORUT	Nothern Research Institute
NVE	Norské ředitelství pro vodní zdroje a energetiku
Radar	Radio Detection and Ranging
ReLU	Rectified Linear Unit
RGB	Red, Green, Blue
SAR	Synthetic Aperture Radar
SNAP	Sentinel Application Platform
V, VV	Vertikální polarizace
VGG-19	Visual Geometry Group

Seznam obrázků

Obr. č. 1: Elektromagnetické spektrum	13
Obr. č. 2: Zobrazení snímání radaru se syntetickou aperturou	14
Obr. č. 3: Jevy způsobené bočním snímáním SAR.....	16
Obr. č. 4: Vliv vlnové délky na prostupnost povrchem	18
Obr. č. 5: Zobrazení elektromagnetické vlny	18
Obr. č. 6: Základní druhy odrazecích ploch podle drsnosti povrchu	20
Obr. č. 7: Vliv mocnosti sněhové pokrývky na odrazový koeficient	21
Obr. č. 8: Vliv vlhkosti sněhu na zpětnou odrazivost vzhledem k různým úhlům dopadu	22
Obr. č. 9: Algoritmus pro automatickou detekci lavin	25
Obr. č. 10: Struktura neuronové sítě	26
Obr. č. 11: Struktura konvoluční vrstvy	27
Obr. č. 12: Jednoduché schéma konvoluční neuronové sítě s podvzorkovací vrstvou... ..	28
Obr. č. 13: Konfigurace neuronových sítí VGG	29
Obr. č. 14: Aktivační funkce softmax a ReLU	31
Obr. č. 15: Umístění zájmových regionů v Norsku	35
Obr. č. 16: Poloha údolí Tamokdalen a Lavangsdalen	36
Obr. č. 17: Mechanismus předzpracování radarových dat.....	37
Obr. č. 18: Předzpracovaná scéna z 25. 12. 2014	38
Obr. č. 19: Sklon svahu na vybraném území v Norsku	40
Obr. č. 20: Výsledná maska pro určení výskytu lavin	41
Obr. č. 21: RGB syntéza referenčního a aktivního snímku	42
Obr. č. 22 Změna zpětné odrazivosti v jednotlivých údolích	42
Obr. č. 23: Příklady výřezů míst s lavinovým proudem a bez.....	43
Obr. č. 24: Rozmístění vybraných lavin v zájmových údolích v Norsku	44
Obr. č. 25: Důvod výběru modelu neuronové sítě VGG-19.....	45
Obr. č. 26: Ukázka průběhu jedné epochy neuronové sítě VGG-19	47
Obr. č. 27: Ukázka přeučení neuronové sítě	47
Obr. č. 28: Ukázka nedoučené neuronové sítě.....	48
Obr. č. 29: Ztrátová funkce „binary cross entropy“ při trénování neuronové sítě.....	49
Obr. č. 30: Parametr $\alpha=0,001$ u optimalizátoru Adam.....	49
Obr. č. 31: Výsledek trénování použitého modelu neuronové sítě.....	50
Obr. č. 32: Problematický snímek při zařazování do kategorie „Je lavina“	50
Obr. č. 33: Jednotlivé snímky, zařazené do špatné kategorie	51
Obr. č. 34: Příklady správně určeného snímku	52
Obr. č. 35: Výsledek trénování použitého modelu neuronové sítě po změně obsahu datasetu	53
Obr. č. 36: Chybně zařazený snímek do kategorie „není lavina“	53

Seznam tabulek

Tab. č. 1: Používaná frekvenční pásma SAR, frekvence a vlnové délky	13
Tab. č. 2: Režimy snímání zemského povrchu družic Sentinel 1A a 1B.....	33
Tab. č. 3: Pravděpodobnost zařazení do jednotlivých kategorií u problematických snímků	51
Tab. č. 4: Celkové výsledky při testování prvního modelu neuronové sítě.....	54
Tab. č. 5: Celkové výsledky při testování druhého modelu neuronové sítě	54

1. Úvod

Výskyt sněhových lavin je vázán na horské oblasti, kde jejich pád může způsobit škody na infrastruktuře nebo dokonce i ztráty na životech. Lavina je masa sněhu, jejíž objem je obvykle větší než 100 m³, která se rychle sesouvá svahem dolů (Kociánová, 2013). V Česku se vyskytují především v Krkonoších, v Jeseníkách a na Kralickém sněžníku (laviny.info, 2019). Ve světě poté v místech, kde je dostatečné množství sněhové pokrývky a sklon svahu takový, aby se lavina mohla utrhnout. Jedním z takových míst je Norsko, kde na příkrých svazích padá několik desítek lavin ročně. Jejich vznik je vázáný na mnoho faktorů, především na nadmořskou výšku, členitost terénu a vegetaci.

Kvůli možnosti výskytu laviny i v turistických nebo obydlených oblastech je důležitá předpověď jejich vzniku a detekce lavinových proudů těch lavin, které už spadly. Takové svahy většinou mapuje horská služba dané oblasti, ale velmi důležitá je i meteorologická předpověď. Díky tomuto mapování lze zabránit i ztrátám na lidských životech, k nimž došlo například v údolí Tamokdalen v lednu 2019 (Snoskred i Tamokdalen, 2019). S rozvojem techniky již není mapování lavin odkázáno jen na pozemní měření, ale velkým přínosem je zde mapování pomocí dálkového průzkumu Země (DPZ). Výhodou monitoringu lavin z dat DPZ je, že nezávisí na pozemním měření (in-situ) a nehrozí tak žádné nebezpečí. Díky DPZ také můžeme spatřit laviny v místech, kam by se člověk nedostal.

Mapování lavinových proudů a míst s jejich výskytem z radarových dat má dlouhou historii. První, kdo se zabýval zjišťováním lavinových proudů z dat radarů se syntetickou aperturou (SAR) změnovou metodou, kdy se používá kombinace referenčního a aktivního snímku (zjednodušeně řečeno snímku před a po pádu laviny) byl Wiesmann (2001). Další studie, zabývající se lavinovou aktivitou, popisuje Eckerstorfer a kol. (2017) a Vickers a kol. (2017). Obě tyto studie využívají data z družice Sentinel 1A. Tyto družice jsou součástí programu Evropské vesmírné agentury (ESA). Nejnověji se k detekci lavin z radarových snímků používá metoda strojového učení, konkrétně vícevrstevných neuronových sítí. Kummervold a kol. (2018) využívají metodu konvolučních neuronových sítí, aby určili výskyt lavin přesněji než autoři v předchozích případech. Neuronová síť se za pomoci trénovacích dat naučí, jak vypadají na snímku laviny, a následně je dokáže určit i z neznámých obrázků.

Tato diplomová práce se zabývá určováním lavin z dat radaru se syntetickou aperturou. Jsou zde použity snímky z radaru Sentinel 1A. pro území v Norsku z důvodu

častého pádu lavin a dobré dostupnosti validačních dat. Jako metodika je používána metoda rozpoznání laviny za pomoci konvolučních neuronových sítí, konkrétně předtrénované neuronové sítě VGG-19 (Visual Geometry Group). Základním metodickým přístupem je nejprve definice výchozích prostorových příznaků lavinových polí a návrhu následného klasifikačního pravidla, které tyto příznaky využívá.

Cílem práce je vytvořit postup pro rozpoznání míst, kde se vyskytl lavinový proud. Dílčím cílem je shrnutí problematiky, sestavení vlastní metodiky a návrh vhodného metodologického postupu pro určení místa s lavinou.

2. Mapování sněhových lavin

Globální pokrytí, možnost pravidelných měření a velká kvalita senzorů poskytuje častá a dynamická data o sněhové pokrývce. Laviny se považují za přírodní katastrofu a jejich mapování je velice důležité. Hlavním cílem mapování je dozvědět se, kde a jaký typ laviny spadl, jak byla velká a jak závisely její vlastnosti na topografii, meteorologických a sněhových vlastnostech. Používají se různé techniky – pozemní měření, letecké snímkování a DPZ.

2.1 Pozemní mapování lavin

Mapování lavin na území jednotlivých států provádí převážně horská služba dané oblasti. Historie výzkumu lavin na našem území sahá až do 17. století, kdy byla popsána lavina v Krkonoších. Byly zaznamenávány jen laviny, při kterých došlo k velkým škodám na majetku nebo na životech. V současné době jsou zaznamenávány téměř všechny sesuny. Jsou pozorovány druhy a vlastnosti sněhu, a díky tomu jsou pak odvozovány lavinové předpovědi (Horská služba ČR, 2019). V Česku je mapováním lavinových svahů, na kterých mohou vznikat laviny, pověřena právě horská služba, která přímo v terénu zjišťuje charakteristiky sněhové pokrývky (PřF MU, 2018).

Pozemní mapování lavin je velmi rozšířené v těch oblastech, kde je velký turistický ruch, a toto mapování je zaměřeno především na svahy, poblíž kterých se pohybují lidé. V odlehlých částech hor toto mapování prakticky neprobíhá z důvodu špatné dostupnosti pro člověka a možného nebezpečí. Vyskytly se ale pokusy o mapování za pomoci digitálního fotoaparátu. Christiansen, 2001, cit. v: Eckerstorfer (2016) provádí mapování lavin časovou řadou snímků pořízených digitálním fotoaparátem v severovýchodním Grónsku. Výhodou této techniky jsou aktuální data, kdy může být z každého dne pořízeno hned několik snímků, kvalita snímků záleží na prostorovém rozlišení kamery a jejím umístění. Špatné počasí ale neumožňuje kontinuální monitoring, dále je nevýhodou nutnost nabíjet baterii fotoaparátu a kontrolovat stav kamery.

Takto je možné mapovat svahy, které jsou přístupné člověku, ale odlehlá místa, kde se laviny také mohou vyskytovat, se pozemním mapováním zjistit nedají. Dalšími nevýhodami jsou vysoká časová náročnost a nekontinuální data kvůli špatnému počasí. Je tedy vhodné hledat další metody mapování, kterými by bylo možné zmapovat laviny i v odlehlých místech.

2.2 Mapování za pomoci DPZ

Metody mapování za pomoci dálkového průzkumu Země se začaly rozvíjet během posledních desítek let od schopnosti vytvořit fotografii a vyslat družici mimo Zemi. Podle zdroje elektromagnetického záření můžeme tyto metody dělit na aktivní a pasivní (Dobrovolný, 1998).

Pasivní senzory (optické) měří záření vyslané od objektu, aktivní senzory (LiDAR, Radar) vyzařují určitou energii a měří následně tu energii, která se odrazí zpět od předmětu (Eckerstorfer, 2016). Optické, LiDARové (Light Detection and Ranging) a Radarové (Radio Detection and Ranging) senzory používají specifické vlnové délky.

Další možností je využití leteckého skenování, které použil Bühler, 2009, cit. v: Eckerstorfer (2016). Využívá digitální pushbroom skener (elektronický s linií detektorů) a podařilo se touto metodou určit střední a velké lavinové proudy. Výhodou je možnost využití digitálního modelu povrchu (DSM) k odmaskování míst, kde není možnost pádu laviny. Využívá blízké infračervené pásmo, které bylo citlivé na velikost sněhového zrna, což také pomohlo k přesnějšímu určení míst s lavinovými proudy. Tato metoda je ovšem taktéž limitována počasím a velmi závisí na textuře sněhové pokrývky (Eckerstorfer, 2016).

Larsen a kol., 2013 cit. v: Eckerstorfer (2016) využívá algoritmus k detekci lavin na snímcích z vesmírných družic QuickBird v panchromatickém pásmu s velmi dobrým prostorovým rozlišením 0,6 metru na území západního Norska. Problém je s určením lavin v místech, kde je stín. Nevýhodou je, že uživatel musí zaplatit za poskytnutí snímku za každý kilometr čtvereční 24 dolarů. Možností je využít snímky z Landsat 8, které ale mají prostorové rozlišení 15 m, (Eckerstorfer, 2016), nebo Sentinel 2A s prostorovým rozlišením 10 m. U všech těchto snímků je ale nevýhoda sklon svahu, málo světla kvůli polární noci, špatné počasí a další problémy se zpracováním snímků. Další metoda – skenování LiDARem, ať už pozemním nebo neseným letadlem, je sice přesná, ale velmi drahá a logisticky náročná.


Detekce lavin pozemními radary je výhodná v dobrém časovém rozlišení (30 s), vysokém prostorovém rozlišení (1 m). Nezávisí na počasí. Je ale velice citlivá na malé změny ve sněhové pokrývce. Mohou být monitorována jen určitá území v dosahu radaru a je velice finančně náročná. Nejvíce zkoumanou metodou je zjišťování lavin z radarů nesených vesmírnou družicí. Nezávisí na počasí ani světelných podmínkách,

2.3 Detekce lavin radary se syntetickou aperturou

2.3.1 Princip radaru

Radar (Radio Detection and Ranging) je aktivní zařízení, které je schopné vysílat elektromagnetické vlny s vysokými frekvencemi. Tyto vlny se odráží od každého objektu zpět k radaru. Radar funguje v oblasti mikrovlnného záření. Vlnová délka se pohybuje v rozmezí od několika milimetrů do jednoho metru (viz Obr. č. 1).

Obr. č. 1: Elektromagnetické spektrum



Zdroj: Wikipedia, 2019

Radar se syntetickou aperturou (SAR) se používá ke snímání Země již více než 30 let. Je unikátní v tom, že provádí snímky s vysokým rozlišením, není závislý na denním světle, oblačnosti ani na počasí. Toho není dosaženo velikostí antény, ale opakovaným vysíláním pulzů a snímáním objektů (A Tutorial on Synthetic Aperture Radar, 2013). Radar dále vysílá i přijímá mikrovlnné záření nejběžněji ve frekvenčních pásmech Ka – P (viz Tab. č. 1). Pásmo Ka se používá pro vojenské účely, Ku je využíváno pro satelitní komunikaci, X a C pak využívají radary pro předpověď počasí, kontrolu námořní dopravy nebo například zjišťování rychlosti jízdy. Pásmo S využívá například NASA pro komunikaci s mezinárodní vesmírnou stanicí (ISS). Pásmo L je využíváno pro Global Positioning System (GPS) (Echoes in space, 2019a).

Tab. č. 1: Používaná frekvenční pásma SAR, frekvence a vlnové délky

Frekvenční pásmo	Ka	Ku	X	C	S	L	P
Frekvence [GHz]	40-25	17,6-12	12-7,5	7,5-3,75	3,75-2	2-1	0,5-,25
Vlnová délka [cm]	0,72-1,2	1,7-2,5	2,5-4	4-8	8-15	15-30	60-120

Zdroj: A Synthetic Aperture Radar Tutorial, 2013

SAR je aktivní zobrazovací zařízení, kde odraz elektromagnetického záření od objektu je zachycen anténou, která se pohybuje kolmo na směr měření. Velikost naměřené zpětně odražené energie je znázorněn jako černobílý obraz, intenzity odraženého elektromagnetického záření jsou ukládány s radiometrickým rozlišením 16 bit (Gisat, 2019). Rychlost šíření elektromagnetických vln je stejná jako rychlost světla.


Zobrazovací geometrie SAR se liší od používaných systémů pro optické snímání. Prostorové rozlišení je dáno délkou pulzu a šířkou paprsku antény, kdy délka pulzu určuje rozlišení v příčném směru (kolmý na dráhu letu) a šířka paprsku určuje směr azimutu, tj. rozlišení ve směru rovnoběžném s drahou letu (Dobrovolný, 1998). SAR má velmi dobré rozlišení, které není dáno délkou antény, ale použitím kratších vlnových délek, kdy je využíváno tzv. Dopplerova jevu. Tento jev vyjadřuje změnu frekvence a vlnové délky přijímaného signálu oproti vysílanému, podle vztahu [1]:

$$f = f_0 \frac{v}{v \pm v_{s,r}} \quad [1]$$

kde f_0 je vysílaná frekvence, v rychlost šíření vln a f přijímaná frekvence, $v_{s,r}$ je relativní radiální rychlost zdroje vůči pozorovateli, pokud je kladná, zařízení se vzdaluje, zatímco u záporné se přibližuje (Fyzweb, 2019). Díky vlivu Dopplerova efektu může být objekt přesněji lokalizován (Outrata, 2017).

Zařízení je schopno neustále vysílat a přijímat pulzy. Jak je zobrazeno na Obr. č. 2, družice se snímačem cestuje dopředu ve směru letu (A). (B) je nadir (bod na povrchu přímo pod senzorem). Radar vysílá paprsek šikmo v pravém úhlu ke směru letu a (C) je šířka pásma, která je snímána. Jedná se o boční geometrii, která je typická pro zobrazovací radarové systémy (ESA, 2019a). Zařízení zaznamenává celkový čas a amplitudu odraženého záření, díky nimž vypočítá vzdálenost k jednotlivým objektům ve směru kolmém na směr letu. Velikost intenzity odraženého záření závisí na vlastnostech povrchu. Tyto veličiny se převádí na obraz na základě kódování do stupňů šedi (Capaliniova, 2006 cit. v Součková, 2010).

Obr. č. 2: Zobrazení snímání radaru se syntetickou aperturou



Zdroj: ESA, 2019a

SAR využívá dopředného pohybu radaru, bočního snímání a vyslání série pulzů, díky čemuž dosáhne dobrého rozlišení i s malou anténou při relativně dlouhých vlnových délkách. Cílem zpracování je zkonstruovat scénu zkombinovanou z jednotlivých pulzů odražených od povrchu objektu a přijatých anténou. Surová data přijatá senzorem jsou jen kombinace odstínů šedi, kdy každý pixel obsahuje hodnotu skládající se z intenzity a fáze signálu (Echoes in space, 2019b; A Tutorial on Synthetic Aperture Radar, 2013). Fázová složka udává informaci o fázovém posunu odraženého záření a je využívána např. pro radarovou interferometrii (Karvánek, 2016).

Vztah mezi intenzitou vyslaného a přijatého signálu je u radarů, kde anténa vysílající i přijímací je totožná, následující:

$$P_r = \frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 R^3} \quad [2]$$

kde P_t je intenzita vyslaného signálu, P_r intenzita přijatého signálu, G zisk antény, λ vlnová délka, R vzdálenost mezi anténou a objektem (nazýváno také range), σ je efektivní odrazová plocha objektu (také radar cross section). Intenzita zpětného odrazu je vyjadřována jako průměr hodnot zpětné odrazivosti na jednotku plochy. Tato intenzita se vztahuje k diferenciálnímu odrazovému koeficientu nebo k odrazovému koeficientu se vztahem [3]:

$$\sigma^0 = \left(\frac{\sigma}{A_{ill}} \right) \quad [3]$$

kde A_{ill} je plocha ozářeného objektu, σ efektivní odrazová plocha a σ^0 odrazový koeficient, který může být následně vyjádřen takto [4]:

$$\sigma^0 = \frac{P_r (4\pi)^3}{P_t \lambda^2} * \frac{1}{\int_{A_{ill}} \frac{G_n^2}{r^4}} = \frac{P_r (4\pi)^3 r'^4}{P_t \lambda^2 G^2 A'_{ill}} \quad [4]$$

kde r'^4 je průměrná vzdálenost od ozářené oblasti a A'_{ill} je skutečná ozářená plocha (Součková, 2010).

Radarová měření jsou vyjadřována v logaritmickém měřítku [5]:

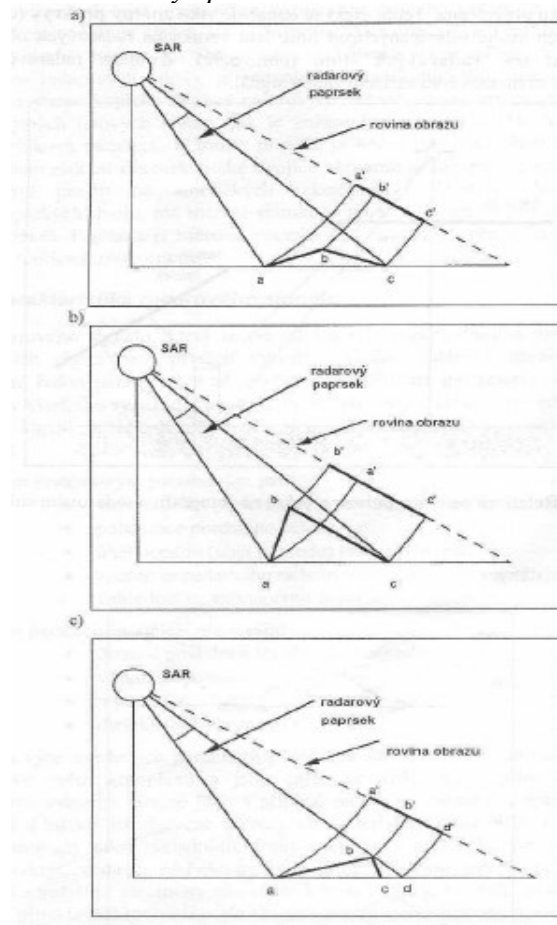
$$\sigma_{dB}^0 = 10 \log_{10} \sigma^0 \quad [5]$$

Decibel (dB) je bezrozměrná jednotka, která se používá k označení úrovně akustických vln a elektronických signálů. V radarovém měření je v decibelech vyjádřen koeficient zpětného rozptylu (nazývaný také odrazový koeficient), který vyjadřuje poměr přijaté energie k izotropnímu odrazu.

Geometrie radarových záznamů je zcela odlišná od geometrie fotografií nebo snímků vzniklých pasivním snímáním. Geometrická charakteristika radarových obrazových záznamů má svá specifika především ve změnách měřítka, pozičních chybách v důsledku různých nadmořských výšek terénu a v efektu paralaxy (Dobrovolný, 1998). Měřítkové zkreslení je způsobeno tím, že vzdálenosti od zařízení jsou měřeny v šikmém směru. Blízký objekt se tedy jeví menší než stejný objekt, který je vzdálenější. Zkreslení se rovnoměrně zvětšuje k oblasti vzdáleného dosahu. (Oustrata, 2017). Tento efekt může být odstraněn znalostí terénu (Echoes in space, 2019b).

Při snímání dochází k relativnímu přemísťování objektů ve směru kolmém na pohyb nosiče. Pokud je určitý objekt s vertikálním rozměrem snímán mikrovlnným paprskem, jeho vrchol je dosažen paprskem dříve než základna, tím pádem se signál od vrcholu objektu vrátí k anténě dříve. Objekt se tak jeví nakloněný k linii letu. Tento problém vzniká například při snímání hornatého území. Podle tvaru snímaného objektu pak dochází ke třem jevům – zhuštění signálu (foreshortening), zpětný překryv signálu (layover) a vznik radarového stínu (shadow), jak je vidět na Obr. č. 3 (Dobrovolný, 1998).

Obr. č. 3: Jevy způsobené bočním snímáním SAR



Zdroj: Dobrovolný, 1998; Pozn.: a) foreshortening, b) layover, c) shadow

Ke zhuštění signálu dochází u svahů orientovaných k linii letu, kdy se délka těchto svahů ve výsledném obraze výrazně zkrátí (Dobrovolný, 1998; Echoes in space, 2019). Překryv se objevuje v případech, kdy se signál z horní části objektu vrátí dříve než z dolní a dochází k němu u velmi strmých svahů. Relativní poloha vrcholu a základny objektu je na výsledném snímku převrácena (Dobrovolný, 1998; Součková, 2010). Pokud jsou svahy odvrácené od linie letu, vzniká na radarovém obraze stín, kdy k zařízení nepřichází zpět žádný signál, tato místa jsou na obraze černě (Dobrovolný, 1998).

K efektu paralaxy dochází, pokud je určitý objekt snímán ze dvou různých letových drah, kde dojde k relativní změně polohy objektů v důsledku jejich různé nadmořské výšky. Takto vznikne stereoskopická dvojice, ze které utvořit jeden snímek je velmi složité, protože objekty se na obou snímcích budou jevit jinak (Dobrovolný, 1998).


Specifickým problémem radarů je pak šum, který se nazývá *speckle*. Jedná se o tzv. pepř a sůl rozsypanou na snímku. Tento jev je způsoben konstruktivním nebo destruktivním sčítáním fáze vlnění. V obraze tak vznikají náhodně rozmístěné světlé a tmavé pixely. Tento jev nelze úplně odstranit, dá se však potlačit například filtrováním snímků. Existují adaptivní filtry, které upravují hodnotu pixelu na základě hodnot v okolí, a neadaptivní filtry, které zpracovávají celý snímek naráz (Mansourpour, 2006 cit. v Outrata, 2017).

2.3.2 Charakteristika radarového signálu

Koeficient zpětného odrazu (backscatter coefficient) poskytuje informaci o snímaném povrchu. Je formován řadou parametrů, které lze obecně rozdělit na vnitřní parametry a vnější. K vnitřním systémovým parametrům patří frekvence použitého mikrovlnného záření, polarizace, úhel dopadu a azimut dopadajícího radarového paprsku ve smyslu jeho orientace vzhledem ke snímanému objektu. Mezi vnější parametry patří vlastnosti povrchu: drsnost, vlhkostní poměry, topografie a dielektrické vlastnosti materiálů. V případě mikrovlnného aktivního snímání ale jednotlivé objekty nevykazují stále stejnou spektrální charakteristiku, jako je tomu například u optického snímání (Dobrovolný, 1998).

Vlnová délka záření ovlivňuje hloubku průniku paprsku. Jak je patrné na Obr. č. 4, větší vlnová délka prostupuje objektem hlouběji (pásmo L), tato hloubka je ale ovlivněna přítomností vody. Delší vlnové délky bez ovlivnění také prostupují atmosférou. SAR pracují nejčastěji s využitím pásem C nebo L (Dobrovolný, 1998; ESA, 2019a).


Obr. č. 4: Vliv vlnové délky na prostupnost povrchem



Zdroj: Součková, 2010

Při snímání objektů je důležité počítat i s různými polarizačními charakteristikami závislými na mnoha faktorech a ovlivňujícími následný odraz vlnění. Polarizaci signálu definuje orientace vektoru elektrické vlny v rámci elektromagnetického záření. Na Obr. č. 5 je znázorněna orientace roviny elektrického pole (E) a magnetického pole (M) u elektromagnetické vlny.

Obr. č. 5: Zobrazení elektromagnetické vlny



Zdroj: ESA, 2019a

Radarový signál může být vysílán ve vertikální (V), kolmý na povrch Země, nebo v horizontální (H) rovině, stejně tak ale může být radarový signál i přijímán. Tím pádem může dojít ke 4 režimům snímání – HH, VV (shodná polarizace) nebo HV, VH (rozdílná

polarizace) (Dobrovolný, 1998). Použitím různých druhů polarizací lze získat více informací o snímaném objektu. HH polarizace je používána pro zjišťování obsahu vody v půdě, VV pro zjišťování směru a rychlosti větru pomocí sledování vlnění na vodních plochách. Rozdílné polarizace se využívají v oblasti mapování stavu a objemu vegetace (Kolář, 2008 cit. v Outrata, 2017).

Dalším parametrem formujícím koeficient zpětného odrazu je úhel dopadu (θ). Je to úhel, který svírá rovina snímaného povrchu s normálou vedenou v místě dopadajícího paprsku. V případě rovného terénu je stejný jako pohledový úhel. Úhel dopadu ovlivňuje geometrii výsledného obrazového záznamu (zhuštění signálu, překryv a stín). Při velkém úhlu dopadu je echo radarového signálu intenzivnější od drsných povrchů, pod strmým úhlem způsobuje intenzivní odraz od hladkých povrchů (Dobrovolný, 1998).

Vzájemnou orientaci dopadajícího radarového paprsku a snímaného objektu pak určuje azimut. Tato orientace má vliv na vzhled výsledného snímku, především na vzhled liniových objektů. Dopadá-li radarový paprsek kolmo na uvedené liniové struktury, je radarové echo intenzivnější, než když jsou linie uspořádány rovnoběžně se směrem dopadajícího paprsku (Dobrovolný 1998).

Z vnějších parametrů ovlivňujících koeficient zpětného odrazu je třeba zmínit vliv drsnosti povrchu. Vzhledem k vlnové délce signálu je povrch považován za hrubý nebo hladký. Drsnost povrchu lze popsat za pomoci Rayleighova kritéria, kdy hladké povrchy jsou definovány dle vztahu [6]:

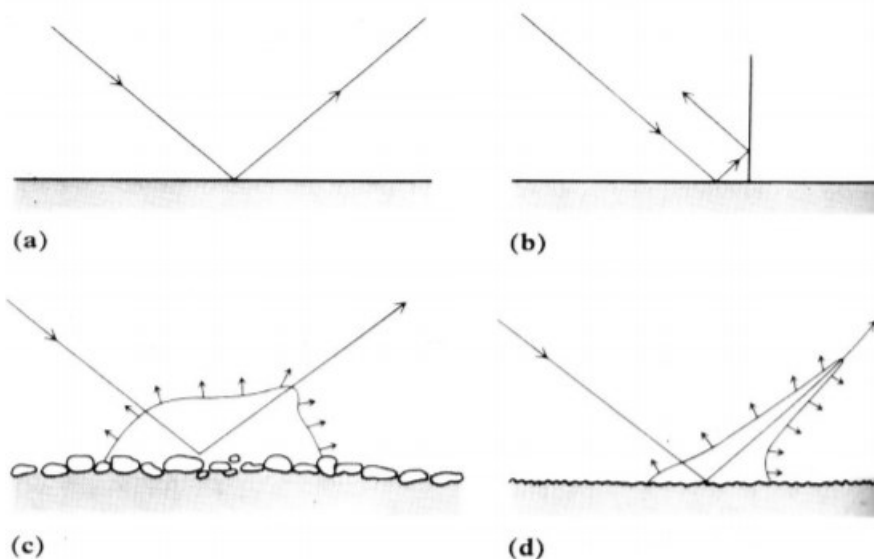
$$h < \frac{\lambda}{8 \cdot \cos \theta} \quad [6]$$

a drsné podle vztahu [7]:

$$h > \frac{\lambda}{8 \cdot \cos \theta} \quad [7]$$

kde h je průměrná výška nerovnosti povrchu, λ je vlnová délka a θ úhel dopadu (Dobrovolný, 1998; Rauch, 2011). Lokální změny v orientaci objektů vůči dopadajícímu radarovému signálu ovlivňují intenzitu odraženého signálu (viz Obr. č. 6). Lokální úhel dopadu je úhel mezi dopadajícím paprskem a normálou k zemskému povrchu v místě dopadu paprsku (Dobrovolný, 1998). Podle drsnosti se v závislosti na vlnové délce mikrovlnného záření rozlišují čtyři základní druhy odrazů: zrcadlový odražeč (a), koutový odražeč (b), difuzní odražeč (c) a hladký povrch s malým difúzním odrazem zpět (d) (Kolář, 2008 cit. v Outrata, 2017).

Obr. č. 6: Základní druhy odrážecích ploch podle drsnosti povrchu



Zdroj: Kolář, 2008, cit. v: Outrata, 2017

Vnějšími parametry jsou také elektrické vlastnosti materiálů, jejichž míru vyjadřuje dielektrická konstanta. Charakterizuje povrchy z hlediska schopnosti absorbovat, odrážet nebo vést mikrovlnnou energii. Hodnoty dielektrické konstanty souvisí s obsahem vody (Dobrovolný, 1998).

2.3.3 Sněhové charakteristiky při snímání radarem

Sněhová pokrývka se vyznačuje mnoha typickými vlastnostmi, díky nimž je dobře rozpoznatelná na radarových snímcích. Suchý sníh se skládá pouze z ledových částic a vzduchu, ale pokud začne docházet k tání, objeví se nový prvek: voda. Díky ní klesá odrazový koeficient a zvyšuje se dielektrická konstanta (Součková, 2010).

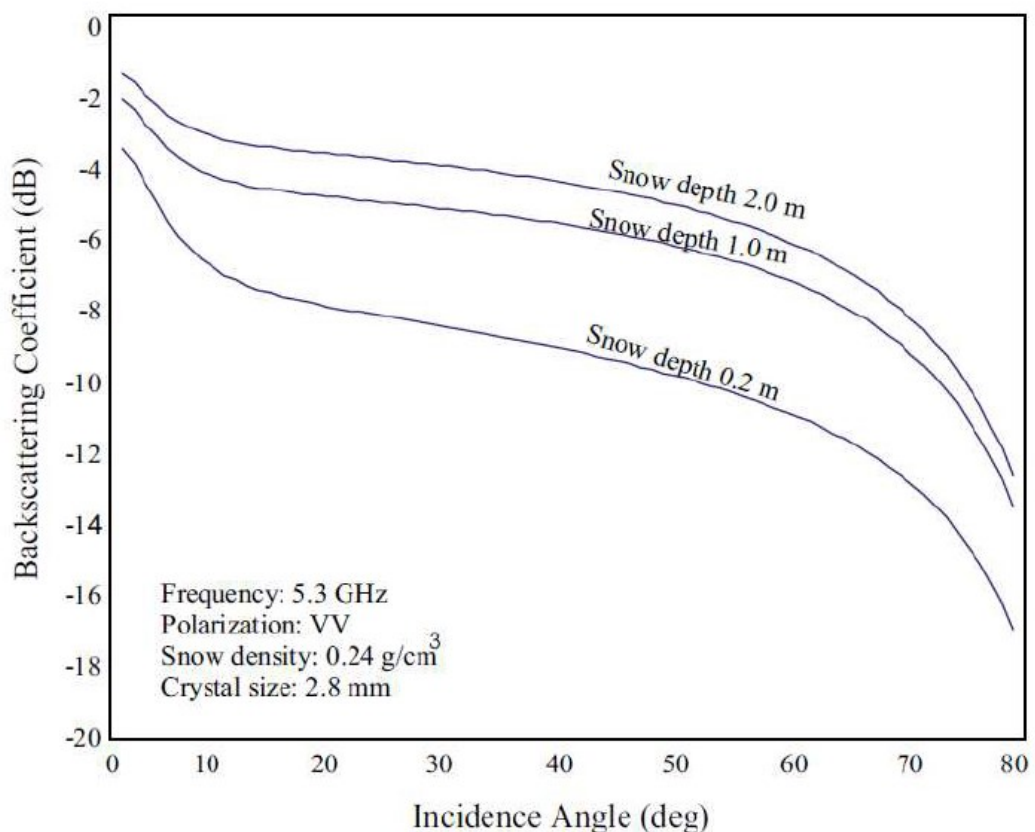
Dle Naglera (1996) se dielektrická konstanta (též relativní permitivita ϵ) skládá z reálné a imaginární části. Reálná složka permitivity je u suchého sněhu nezávislá na frekvenci a teplotě v mikrovlnném spektru. Imaginární složka naopak závisí na frekvenci, teplotě a hustotě sněhové pokrývky. Růst permitivity je pak méně závislý na hustotě sněhu, ale dielektrická konstanta suché sněhové pokrývky roste lineárně se vzrůstající hustotou sněhu (Hallikainen a kol., 1986 cit. v Součková, 2010).

Hloubka průniku mikrovlnného záření, představující vzdálenost, v níž je signál zeslaben z původní intenzity, závisí na obsahu vody v kapalném stavu (Součková, 2010).

Zpětný odraz sněhu ovlivňují následující fyzikální parametry: obsah vody v kapalném stavu, mocnost sněhové vrstvy, profil hustoty a teploty sněhové vrstvy, členitost povrchu na rozhraní vzduch-sníh a rozhraní sníh-země a velikost a tvar

sněhových částic (Součková, 2010). V pásmu C u suchého sněhu vede nepatrný rozdíl mezi dielektrickou konstantou vzduchu a suchého sněhu k slabému odrazu signálu a velkému přenosovému koeficientu (kolik se přeneso do další vrstvy). U suchého sněhu má tedy členitost povrchu minimální vliv na celkový zpětný odraz. Dielektrická konstanta a povrchový rozptyl suchého sněhu rostou s růstem hustoty sněhu (Ulaby a kol, 1986, Hallikainen a kol. 1986 cit. v Součková, 2010). Mocnost sněhové pokrývky má vliv na odrazový koeficient. Na Obr. č. 7 je popsán vliv mocnosti sněhové pokrývky na odrazový koeficient jako funkce úhlu dopadu (Koskinen, 2001 cit. v Součková, 2010).

Obr. č. 7: Vliv mocnosti sněhové pokrývky na odrazový koeficient




Zdroj: Koskinen, 2001 cit. v Součková, 2010

Pozn.: velikost zrna (crystal size), hustota sněhu (snow density), polarizace VV, frekvence v pásmu C, výška sněhu (snow depth)

U tajícího sněhu dochází k poklesu celkového odrazového koeficientu s rostoucí vlhkostí sněhu. Zpětný odraz je závislý na vlhkosti sněhové vrstvy a členitosti sněhové pokrývky (Luoju, 2009 cit. v Součková, 2010). U vlnění o frekvenci 5 GHz tak v souvislosti s tající sněhovou pokrývkou platí, že koeficient zpětného odrazu nezávisí na vodní hodnotě sněhu, ale na vlhkosti sněhu a členitosti povrchu sněhové pokrývky. Koeficient zpětného odrazu také závisí na úhlu dopadu (viz Obr. č. 8).

Obr. č. 8: Vliv vlhkosti sněhu na zpětnou odrazivost vzhledem k různým úhlům dopadu



Zdroj: Koskinen, 2001 cit. v Součková, 2010)

Na základě výše uvedených charakteristik zpětného odrazu, v závislosti na vlastnostech sněhu a dalších parametrech, je možné z radarových snímků rozpoznávat vlhký a suchý sníh. Při pádu laviny dochází ke zvýšení objemu sněhu na určitém místě, změně obsahu vody ve sněhu, změně hustoty sněhu, a především ke změně drsnosti povrchu, od kterého se záření odráží. Tyto parametry vedou ke zvýšení zpětného odrazu, díky němuž jsou laviny na snímku rozpoznatelné. Spadá lavina se na snímku zobrazí jako „jazyk“ vedoucí ze svahu dolů (Malnes, 2015).

2.3.4 Sněhová lavina

Sněhové laviny jsou druhem svahových pohybů způsobených především gravitační silou a meteorologickými podmínkami. Hlavním transportovaným materiálem je sníh. Laviny vznikají na svazích převážně o sklonu 25°- 45° a hlavními důvody jejich vzniku je vrstva sněhové pokrývky ležící na svazích a její stabilita, která závisí na hustotě a soudružnosti sněhu a na teplotě. Laviny vznikají v důsledku velkého množství nového sněhu, při tání, dešti nebo i lidskou činností (narušení soudružnosti sněhu). Laviny můžeme rozdělit do různých skupin. Podle tvaru odtrhu na čárový a bodový, podle tvaru dráhy na plošnou, kde převládá její šířka, a žlabovou, která je dlouhá a úzká, a podle

formy pohybu na prachovou a vrstevní. Prachové laviny dosahují vysokých rychlostí a patří mezi nejnebezpečnější, neboť se do pohybu zapojuje stále nový sníh. Vrstevní laviny vznikají v hustém sněhu a pohybují se pomalu, ale transportují větší množství materiálu (PřF MU, 2018, Šimčíková, 2013).

Laviny se následně dají dělit na malé, střední a velké. Malá lavina dosahuje délky do 100 m a objemu do 1 000 m³. Střední lavina se zastavuje až na spodní části svahu a dosahuje délky do 1 000 m a objemu do 10 000 m³. Velká lavina pak může dosáhnout až na dno údolí, zasypat a zničit auta, vlaky, velké budovy nebo i zalesněné plochy. Její délka je větší než 1 000 m a objem větší než 10 000 m³ (PřF MU, 2018).

2.3.5 Metody určování lavin z radarových dat

Mapování lavin z dat SAR zmiňuje Wiesmann (2001) na příkladu lavin ve Švýcarsku, kde provedli metodu porovnání dvou snímků – referenčního a aktivního (change detection) a následnou RGB (red, green, blue) kompozicí byly zvýrazněny laviny, které se zobrazily zelenou barvou. Snímky byly pořízeny družicí ERS1.

Zjišťování lavinových proudů se provádí především za pomoci pásma C radaru se syntetickou aperturou. V roce 2014 byla v Norsku na jaře velká lavinová aktivita a provádělo se mapování radarem Radarsat-2 Ultrafine Mode s vysokým prostorovým rozlišením 1 m (Eckerstorfer 2015). Tato metoda využívá manuální detekci lavin z radarových snímků s horizontální polarizací. Pro lepší určení laviny se provede odmaskování území, kde lavina být nemohla, a stanoví se práh zpětné odrazivosti. Lavinové proudy se vyznačovaly vyšší zpětnou odrazivostí než okolní plocha, práh byl stanoven na 1,5 dB. Bylo zjištěno celkem 467 lavinových proudů, z nichž pouze 68 jich mohlo být validováno daty z Landsatu-8 nebo z pozemního měření. Ačkoliv Radarsat poskytuje snímky s opravdu dobrým prostorovým rozlišením, pořízení těchto snímků je velmi nákladné a jedná se jen o malý pás snímání (Eckerstorfer 2015). Proto se jako výhodnější jeví použití dat ze Sentinelu.

Metodou change detection na území Norska v regionu Troms z dat Sentinelu 1A se zabývá Malnes (2015). Jedná se o první použití této metody pro snímky ze Sentinelu pro detekci lavinových proudů. Díky nárůstu zpětné odrazivosti v místě lavinového proudu je možná manuální detekce těchto míst. Jako validační data byly použity snímky ze satelitu Radarsat-2. Pro barevné zvýraznění byla opět použita RGB kompozice, kdy referenční snímek obsahoval červené a modré pásmo, zatímco aktivní snímek pásmo zelené. Výsledný snímek pak zobrazuje pokles zpětné odrazivosti červeně a lavinový

proud charakterizovaný nárůstem odrazivosti zeleně. Validace výsledků byla provedena také in-situ, protože se jednalo jen o 15 lavin s dobrou dostupností. Závěrem tohoto výzkumu je, že Sentinel 1A a snímání interferometrického pásu s prostorovým rozlišením 20 m může být využito pro manuální detekci lavin, ale tato metoda je velmi zdlouhavá a je potřeba vytvořit automatický algoritmus, který bude laviny ve snímku rozpoznávat.

Touto problematikou se následně zabývá Vickers (2016), kdy se za využití snímků ze Sentinelu snaží vytvořit algoritmus pro rozpoznání lavinových proudů v oblastech Tamokdalen a Lavangsdalen v regionu Troms v Norsku, a následně použít tento algoritmus pro jakékoliv jiné lavinové území. Metoda spočívá v odmaskování míst, ve kterých lavina spadnout nemohla, také použitím digitálního modelu terénu, kdy jsou odstraněna místa se sklonem svahu větším než 35°. Následně je provedena change detection, kdy je aktivní snímek odečten od referenčního a pokud změna zpětného odrazu je větší než 6 dB, počítá se s tím, že se jedná o lavinu. Pro větší zpřesnění je navíc použita neřízená klasifikace K-means s 30 trénovacími opakováními a dvěma třídami pro klasifikaci – je lavina, není lavina. Pro odstranění jevu speckle je využit mediánový filtr s velikostí filtrovacího okna 5x5. Jako validační data využívají snímky klasifikované expertem metodou, kterou uvádí Eckerstorfer (2015). Hlavní nevýhoda této metody je v nepřesnosti celkového výsledku, kdy v oblasti Tamokdalen bylo určeno pouze 62 % lavin algoritmem ve stejném místě jako je určil expert. Problém byl především v určení malých lavin, u lavin větších naopak nastal problém v tom, že algoritmus dva lavinové proudy blíž u sebe označil jako jeden. Autoři se snaží o zpřesnění své metody nadále přidáním dalších parametrů pro počáteční vytvoření masky a vzetím do úvahy více faktorů, například teplotu, vlhkost vzduchu a výšku sněhu (Vickers, 2017). Je využit i jiný filtr pro odstranění jevu speckle (tentokrát Gaussův filtr) a je provedena metoda change detection před samotnou klasifikací i po ní. Ve výsledku je dosaženo až 80% úspěšnosti, v ideálních případech dokonce 90 %. Dle Kummervolda (2018) už ale tato metoda dosáhla maximální úspěšnosti a nevidí v ní prostor k dalšímu zlepšení přesnosti určení lavin, ale při využití neuronových sítí je možné dosáhnout větší přesnosti. Neuronové sítě jsou metodou strojového učení, kdy se neurony chovají jako lidský mozek (více v kapitole Neuronové sítě). Metoda s využitím neuronových sítí, konkrétně typů konvolučních neuronových sítí, dosahuje přesnosti určení lavinových proudů až 90 %, v některých případech dokonce 93,5 %. Jako validační data jsou využita opět manuálně identifikovaná území. Závěrem zkoumání je, že neuronové sítě mohou být úspěšně

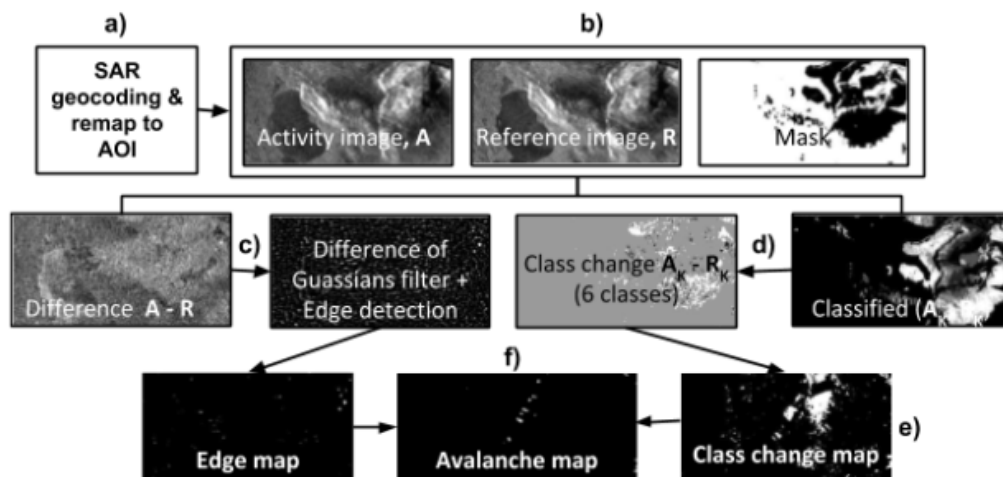
použité k detekci lavin i bez předchozích úprav snímků, které provádí Vickers (2016, 2017).

2.3.5.1 AVAMAP

AVAMAP (Worldwide avalanche detection using Sentinel-1) je projekt NORUT (Northern Research Institute) zabývající se detekcí lavin z dat Sentinelu. Za cíl má demonstrovat schopnost Sentinelu konzistentně monitorovat lavinové aktivity kdekoli na Zemi a začít budovat časovou řadu dat lavinových aktivit, která je důležitá pro mapování přírodních katastrof a studií souvisejících s klimatem. V současnosti se mapování lavin provádí ve vybraných testových územích po celé Zemi, například v USA, na Islandu, v Itálii a v Afghánistánu.

Tým výzkumníků z NORUTu vynalezl automatický algoritmus, který stáhne a předzpracuje data ze Sentinelu 1A a detekuje laviny, které označí a uloží do databáze. Algoritmus začíná geokódováním radarových dat a aplikováním masky na místa, kde lavina nemůže spadnout. Následně provede klasifikaci pixelů do šesti tříd podle jejich zpětné odrazivosti. Poté je provedena change detection a následně vytvořena lavinová mapa. Přesný postup algoritmu je zobrazen na Obr. č. 9. Přesnost detekce se pohybuje mezi 50 a 100 % (AVAMAP, 2019).

Obr. č. 9: Algoritmus pro automatickou detekci lavin



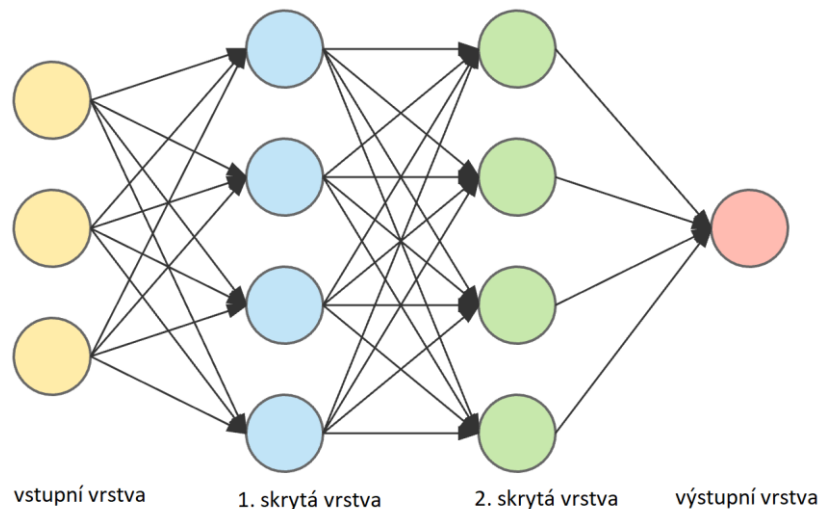
zdroj: AVAMAP, 2019

2.4 Neuronové sítě

Neuronová síť je algoritmus strojového učení, který je postaven na základě fungování a organizace neuronů v lidském mozku. Síť se skládá z jednotlivých jednotek,

kteře se nazývají neurony, a ty jsou utříděné do jednotlivých vrstev (viz Obr. č. 10). Všechny neuronové vrstvy jsou vzájemně propojeny a každá jednotka provádí jednoduchý matematický výpočet, díky kterému pak vznikne požadovaná výstupní vrstva (Sorokina, 2017). Neuronové sítě jsou vhodné pro klasifikaci obrázků, ale i pro úlohy z oblasti klasifikace, aproximace a predikce. (Štanglová, 2017).

Obr. č. 10: Struktura neuronové sítě



Zdroj: Sorokina, 2017

Neuronová síť se učí postupnými úpravami vah. Jako vstup dostávají množinu dvojic

$$\{(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)\} = x_i, y_i$$

kde x_i je vstup a y_i očekávaný výstup. Postupně upravují tyto hodnoty tak, aby byl výstup co nejbližší očekávané hodnotě. To se nazývá konvergence neuronové sítě. Poté, co neuron přijme vstupy, vynásobí jejich hodnoty váhami. Následně tyto součiny sečte a pokud je výsledek větší než stanovený práh, výsledek se transformuje předem zvolenou aktivační funkcí a pošle se na výstup, jak je patrné na v rovnici [8], kde x_i jsou vstupy, w_i váhy, θ prahová hodnota, f přenosová funkce a y výstup (Durčák, 2017). Aktivační funkce budou podrobněji popsány níže.

$$y = f\left(\sum_{i=1}^n w_i * x_i - \theta\right) \quad [8]$$


2.4.1 Konvoluční neuronové sítě

Konvoluce je matematický operátor, který zpracovává dvě a více funkcí najednou a následně z nich vytvoří jednu. Konvoluční sítě mají takových vrstev funkcí hned

několik (hluboké neuronové sítě), a jsou pevně propojeny. Váhy jsou v tomto případě považovány za konvoluční jádra sítě. Konvoluční neuronové sítě se učí fragmenty z obrázků a jejich hierarchii, aby je pak dokázaly rozpoznat například podle hran, tvarů nebo barev (Gogul09, 2017).

Vstupní vrstva této neuronové sítě je matice hodnot ve formátu výška x šířka x hloubka snímku. Hloubka se v tomto případě rozumí počet barevných kanálů. Pokud máme barevný obrázek, jsou 3 – RGB. U černobílých snímků je hloubka 1. Následuje konvoluční vrstva, kde probíhá rozpoznávání příznaků ve snímku se sadou konvolučních filtrů (kernel). Obvykle má filtr velikost 5 x 5 x 3 barevné kanály. Za konvoluční vrstvou pak následuje výstupní vrstva, kterou tvoří mapa příznaků. Schéma vrstev konvoluce je zobrazena na Obr. č. 11. Pro snímky s nalezenými stejnými příznaky se pak aplikují stejné konvoluční filtry (Štanglová, 2017).

Obr. č. 11: Struktura konvoluční vrstvy




Zdroj: Štanglová, 2017

V prvních několika vrstvách se neuronová síť učí rozpoznávat barvy a horizontální a vertikální linie. V dalších vrstvách se učí tvary a v následujících rozpoznává textury (v případě fotografií třeba nos, noha, oko...). Nakonec poslední vrstvy rozhodnou, co za objekt se na snímku nachází. Záporom těchto sítí je však fakt, že se učí přesnou polohu prvků ve vstupu, tzn. že jen malé pohyby prvku ve vstupním obrazu mají za následek jiné naučení sítě. Pro řešení tohoto problému se používá *pooling* (podvzorkování) – převedení snímku na nižší rozlišení aplikací vybrané *pooling* vrstvy. Přidává se za konvoluční vrstvou v síti, specificky za *nonlineární* aktivační funkci (například ReLU). *Pooling* vrstva je aplikována na všechny prvky. Filtrační okno této podzorkovací vrstvy je menší než vrstva v neuronové síti, např. pokud je *pooling* vrstva aplikována na mapu prvků o

rozměrech 6x6 pixelů a filtrační okno je 2x2 pixely, výsledek po podvzorkování bude okno o velikosti 3x3 (Brownlee, 2019). Příklad architektury takové sítě je na Obr. č. 12.

Obr. č. 12: Jednoduché schéma konvoluční neuronové sítě s podvzorkovací vrstvou



Zdroj: Ananthram, 2018

Nejvíce používaným algoritmem při trénování konvolučních neuronových sítí je algoritmus zpětného šíření. Nazývá se též backpropagation. Učení probíhá iterativně od nejnižší vstupní vrstvy k vrstvě výstupní. V prvním kroku dochází k dopřednému šíření vstupního signálu, poté následuje zpětné šíření chyby a aktualizace vah jednotlivých neuronů. Takto se postupně snižuje chyba trénování sítě, dokud není dostatečně nízká nebo nedosáhne k meznímu počtu iterací (Štanglová, 2017; Rek, 2018). Je tedy vlastně založen na hledání minima ztrátové funkce, jejíž význam je vysvětlen v následující kapitole.

2.4.2 Neuronová síť VGG-19

V roce 2014 vyhrála soutěž v přesnosti rozdělování snímků do jednotlivých kategorií síť VGG-19 (Visual Geometry Group) z oxfordské univerzity. Jedná se o vícevrstevnatou neuronovou síť, která se snaží o co nejlepší rozdělování snímků do 1000 výchozích kategorií. Jde o první síť, která dokázala mít chybovost trénování pod 10 % (Tsang, 2018). Díky použití velmi malého konvolučního filtru o velikosti 3x3 byli autoři schopni přidat do sítě více vrstev, které pomohly ke zpřesnění modelu. Výhodou této sítě je i její možné použití na různá data (nemusí se tedy jednat pouze o obrázky z ImageNet databáze) a natrénování na svých vlastních datech.

Vstupní velikost souborů do této sítě by měla být 224x224 a mělo by se jednat o RGB obrázek. Tento obrázek projde skrz blok konvolučních vrstev, jejichž filtrovací okno je 3x3. Blok vrstev je následován *Pooling* (podvzorkovací) vrstvou, a následně jsou připojeny plně spojené vrstvy. Poslední vrstva je doplněna o aktivační funkci *softmax*.

Všechny skryté vrstvy obsahují aktivační funkci ReLU, která je nonlineární (Simonyan, 2015).

VGG-19 proto, že síť obsahuje 19 konvolučních vrstev doplněných o pět vrstev podvzorkovacích vždy po určitém bloku vrstev a na konci je obohacená o vrstvu s aktivační funkcí softmax (viz Obr. č.13).

Obr. č. 13: Konfigurace neuronových sítí VGG

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Zdroj: Simonyan, 2015

Díky volné dostupnosti této sítě je zde možnost natrénovat si ji na vlastních datech. K tomu slouží aplikační prostředí Keras. Využívá se pro načítání a používání předtrénovaných modelů. Díky použití tohoto prostředí si může každý uživatel síť VGG-19 sám vyzkoušet. Obsahuje i další modely neuronových sítí, například VGG-16, ResNet50, InceptionV3, MobileNet (Keras, 2019).

Základní model neuronové sítě VGG-19 obsahuje kromě samotné neuronové sítě ještě volitelné parametry, které si může uživatel nadefinovat dle vlastní potřeby. Jedná se o:


- váhy (weights):
 - *none* – jedná se následně o náhodnou inicializaci dat, pokud je trénován model pro vlastní obrázky
 - *imagenet* – model použije předtrénované váhy z knihovny Imagenet. Knihovna Imagenet je výzkumný projekt sloužící k vytvoření velké databáze snímků (až 15 milionů obrázků) s anotacemi a s popisky. Základní databáze pro klasifikaci obrázků neuronovými sítěmi. Slouží jako základní vstup pro trénování sítí a díky tomu, že je pro všechny sítě stejná lze pak lépe určit, která vytvořená neuronová síť je přesnější. Obrázky jsou rozděleny do 1000 různých kategorií.
- `include_top`:
 - *true* – pokud chce uživatel zahrnout vrchní tři plně propojené vrstvy neuronové sítě
 - *false* – pokud je použita vlastní velikost vstupů
- `input_tensor`: plně volitelný parametr, slouží k definování vstupního obrázku do modelu
- `input_shape`: volitelná velikost vstupů (ve formátu počet pixelů v řádce x počet pixelů ve sloupci x počet barevných kanálů)
- `pooling`: nastavuje typ podvzorkovací vrstvy, která slouží k redukci dimenze pro snížení počtu parametrů sítě a výpočetní náročnosti a zároveň pomáhá proti přetrénování sítě. Dojde k aplikování filtru o určité velikosti (3x3) a k zachování prvku:
 - *pooling max* – s nejvyšší hodnotou
 - *pooling average* – průměr hodnot ve filtračním okně
- `classes`: pokud jsou použité váhy z knihovny ImageNet udá se číselně počet tříd, do kterých bude výsledný obrázek zařazený

Pro ještě větší modifikaci sítě na vlastní data se obvykle na konec přiřadí dvě plně propojené vrstvy, v nichž jsou definovány kategorie, do kterých by měla síť ve výsledku zařadit určovaný obrázek. Jedná se o tzv. *dense* vrstvy, u kterých se nastavují dva parametry: počet výstupních neuronů (pokud rozděluje obrázek do dvou výsledných


kategorií, nastaví se číslo 2) a aktivační funkce (viz Obr. č. 14). Nejčastěji bývají používány dvě aktivační funkce:

- softmax: používá se především u binárních klasifikací, kdy na konečném výstupu očekáváme hodnoty v intervalu $<0,1>$. Tato aktivační funkce udává pravděpodobnost, s jakou spadá výstup do dané klasifikační třídy a používá se ve výstupní vrstvě neuronové sítě (Rek, 2018).
- ReLU (Rectified Linear Unit): jedná se o nejpoužívanější aktivační funkci, očekává hodnoty v intervalu $<0,\infty)$. Pokud je hodnota negativní, je jí automaticky přiřazena 0 a díky tomu je trénování neuronové sítě mnohem rychlejší (Keras, 2019).

Obr. č. 14: Aktivační funkce softmax a ReLU



a) softmax



b) ReLU

Zdroj: Chen, 2017

Pro konfiguraci přidaných vrstev a kompilaci modelu je vhodné určit tři následující parametry:

- optimalizátor: výběr správného optimalizátoru neuronové sítě způsobuje rozdíl mezi dobou učení a dobrými výsledky, které je možné díky volbě dobrého optimalizátoru získat v mnohem kratším čase. Příkladem takového optimalizátoru

je *Adam* (Adaptive Moment Estimation). Udržuje jednotnou míru učení pro všechny aktualizace vah a rychlost učení se během trénování sítě nemění. Tento optimalizátor kombinuje výhody dvou dalších optimalizátorů AdaGrad, který udržuje rychlost učení, a Root Mean Square Propagation, který na základě průměru posledních hodnot vah také udržuje rychlost učení. Tyto optimalizátory zlepšují výsledné parametry neuronové sítě. U optimalizátoru Adam jsou další možnosti nastavení parametrů:

- *alfa (learning rate)*: tento parametr udává rychlost učení neboli velikost kroku, pokud je hodnota menší než 0,001 dojde ke zpomalení učení neuronové sítě
- *beta1*: vyjadřuje exponenciální míru poklesu rychlosti učení pro odhady prvního momentu, většinou se jedná o číslo 0,9
- *beta2*: jedná se o exponenciální míru poklesu rychlosti učení pro odhady druhého momentu, hodnota by se měla nastavit blízko 1
- *epsilon*: zabrání dělení nulou
- *ztrátová funkce*: vyjadřuje aktuální chybu sítě během trénování. Jde o hodnotu, která vyjadřuje rozdíl mezi aktuálním výstupem a očekávaným výstupem. Výstup je pak základem pro učící algoritmus, který se tuto chybu postupně snaží minimalizovat (Rek, 2018).
 - *střední kvadratická chyba*: používá se pro regresní úlohy
 - *cross entropy pro binární klasifikaci*: pro klasifikaci do dvou tříd
 - *cross entropy pro klasifikaci do více tříd*: každé třídě odpovídá jeden výstupní neuron
- *metrika*: parametr, který se používá k posouzení výkonu modelu neuronové sítě. Nastaví, které hodnoty je primárně potřeba sledovat při trénování modelu a tyto hodnoty poté vypisuje (Keras, 2019).
 - *střední kvadratická chyba*
 - *přesnost (accuracy)*

3. Data a metodika

V této kapitole jsou uvedena použitá data, průběh jejich výběru a předzpracování. V metodické části je poté popsána metodika využívaná v praktické části práce.

3.1 Výběr a zpracování dat

Pro tuto práci byla vybrána data z družice Sentinel 1A. Sentinel využívá jednofrekvenční radarový senzor C-SAR v pásmu C. Na polární dráze jsou dvě družice – Sentinel 1A a 1B, obíhající na stejné dráze s posunem 180°. Snímání zemského povrchu probíhá ve čtyřech režimech (viz Tab. č. 2) a s různým prostorovým rozlišením. Časové rozlišení je nad rovníkem 12 dní. Sentinel 1A byl vypuštěn 3. dubna 2014, výška letu družice je 693 km. Sentinel 1B byl vypuštěn 25. dubna 2016.

Tab. č. 2: Režimy snímání zemského povrchu družic Sentinel 1A a 1B

Režim	Způsob využití	Prostorové rozlišení	Šířka záběru
Strip Map Mode	pouze při zvláštním požadavku pro monitorování krizových událostí	5 x 5 m	80 km
Interferometric Wide Swath Mode	hlavní režim snímání nad pevninou, částečně nad mořem a v polárních oblastech	5 x 20 m	250 km
Extra Wide Swath Mode	částečně používaný nad mořem a v polárních oblastech	20 x 40 m	400 km
Wave Mode	hlavní režim snímání nad otevřeným mořem	prostorové rozlišení 5 m ve čtvercích 20 x 20 km každých 100 km, snímáno pod dvěma různými úhly	

Zdroj: CollGS, 2019

Data z družice Sentinel 1A jsou volně dostupná v různých stupních předzpracovanosti, v režimu snímání Interferometric Wide Swath Mode (IW). IW kombinuje velkou šířku záběru a střední geometrické rozlišení. Snímání probíhá ve třech páslech s využitím techniky Terrain Observation with Progressive Scans SAR (TOPSAR), která umožňuje vychýlení radarového pulsu a tím i vyšší kvalitu obrazu. IW režim je hlavním režimem snímání nad pevninou (CollGS, 2019).


Produkty družice jsou dostupné z webové adresy Copernicus Open Acces Hub (SciHub, 2019). Tato data jsou zdarma a jsou poskytována ve třech úrovních zpracování – produkty označované jako Level 0-2. Level 0 jsou pouze surová data, která nejsou nijak zpracována a obsahují šum, vnitřní kalibraci a informaci o poloze na dráze při pořízení snímku. Produkty označované L1, použité i pro tuto práci, se dále rozdělují na Single Look Complex (SLC) a Ground Range Detected (GRD). Tato data už jsou georeferencována, dochází k redukci šumu (speckle). Produkty GRD mají odstraněn termální šum. Pro tuto práci byla využita data L1 GRD. Dále je k dispozici i Level 2, který už obsahuje konkrétní produkty, zaměřené například na mapování oceánů nebo zemského povrchu (CollGS, 2019).

3.1.1 Výběr území

Pro detekci lavin bylo potřeba, aby se ve vybraném území laviny vyskytovaly velmi často, aby byly na radarových snímcích dobře rozpoznatelné. Proto bylo zvoleno Norsko, kde se nachází Skandinávské pohoří s velmi prudkými a nezalesněnými horami. Konkrétněji byl zvolen kraj Troms a pohoří Lyngalpane, které se v tomto kraji nachází. Bylo zjištěno, že v této oblasti se přes zimu vyskytne několik desítek lavinových událostí, například v zimě 2014/2015 zde spadlo několik stovek menších či větších lavin (Vickers, 2016). Dle Vickers (2016) bylo vybráno území v údolí Tamokdalen a Lavangsdalen v regionech Lyngen, Nord a Idre Troms (viz Obr. č. 15). Údolí Tamokdalen je 30 kilometrů dlouhé a leží v nadmořské výšce 200 m n. m. Nejvyšší hory dosahují až do výšky 1600 m n. m. Údolí Lavangsdalen měří 16 kilometrů a prochází jím hlavní silnice do Tromsø.

..


Obr. č. 15: Umístění zájmových regionů v Norsku



Zdroj: Kartverket.no (2019), Geonorge.no (2019), vlastní zpracování

Bližší vyobrazení údolí Tamokdalen a Lavangsdalen je patrné na Obr. č.16.

Obr. č. 16: Poloha údolí Tamokdalen a Lavangsdalen



Zdroj: Kartverket.no (2019), Geonorge.no (2019), vlastní zpracování

3.1.2 Předzpracování a výběr radarových snímků

Předzpracování radarových dat bylo provedeno v softwaru Sentinel Application Platform (SNAP). Tento software byl vyvinut Evropskou vesmírnou agenturou (ESA) pro zpracování a úpravu radarových snímků a obsahuje dále toolboxy i pro úpravu produktů dalších misí Sentinel (Step 2019). Tento software je poskytován zdarma.

Pro zpracování práce byly vybrány scény z následujících datumů:

Referenční snímek – 25. 12. 2014 a 23. 12. 2018


Aktivní snímek – 6. 1. 2015 a 4. 1. 2019

Tyto datumy byly zvoleny podle toho, že družice Sentinel 1A proletí nad stejným územím na stejné orbitě 1x za 12 dní. Referenční snímek pochází z doby, kdy na území byly stále klimatické podmínky, to znamená nesněžilo ani nepršelo, zároveň se v horách nacházel již dostatek sněhu, aby v případě změny počasí mohlo dojít k pádu laviny. Aktivní snímky

pořízené o 12 dní později jsou také pořízeny za stálého počasí. Mezi pořízením aktivního a referenčního snímku došlo k výraznému srážkovému úhrnu a oteplení, tím pádem vznikly ideální podmínky pro pád laviny. Informace o počasí byly zjištěny na internetových stránkách Norského ředitelství pro vodní zdroje a energetiku (NVE, 2019). Snímky jsou pořízeny s rozlišením 20 m/pixel, režim snímání IW, Level 1 GRD. Orbita je stoupající (ascending). Sentinel 1 provádí snímky s vertikální i horizontální polarizací senzoru. Dle Vickers (2016) byla využita polarizace VV (přijetí i vyslání signálu ve vertikální pozici senzoru).

Ačkoliv tyto scény jsou již částečně zpracované, je potřeba je ještě dále upravit pro následnou lepší práci se snímkem. Mechanismus předzpracování je uveden na Obr. č. 17.


Obr. č. 17: Mechanismus předzpracování radarových dat



Radiometrická kalibrace slouží k převedení DN hodnot (digital number) každého pixelu na radianci (zář). Pro korekci jevu speckle, což je šum vzniklý v radarových datech, byl použit mediánový filtr s velikostí filtrovacího okna 3x3. Tento filtr patří k jednoduchým, odstraňuje šum způsobený pulsem. Pulsní hodnota menší než polovina šířky filtrovacího okna je potlačena nebo odstraněna (Mansourpour, 2006).

Pro terénní korekci obrazu byl použit dostupný digitální model terénu (DTM), který nabízí software SNAP. Nejprve měl být použit DTM Space Shuttle Radar Topography Mission (SRTM) s rozlišením 30 metrů. Ukázalo se však, že tento model je dostupný pouze v omezené zeměpisné šířce, do které ale nespadá vybrané území (NASA, 2019), tudíž bylo přikročeno k modelu Altimeter Corrected Elevation (ACE) 30, také s rozlišením 30 m. Tento model vychází ze SRTM, avšak má globální pokrytí (Berry, 2008). V tomto kroku bylo nastaveno i zobrazení, kde bylo zvoleno Universal Transverse Mercator (UTM), pás 33 vhodný k zobrazení norského území. Následně již byly snímky připraveny k dalšímu zpracování. Souřadnicový systém už je u produktu L1 předem daný a jedná se o World Geodetic System (WGS) 84. Výsledek předzpracované scény je zobrazen na Obr. č. 18.

Obr. č. 18: Předzpracovaná scéna z 25. 12. 2014



Zdroj: Scihub (2019), vlastní zpracování

Takto byly zpracovány všechny vybrané scény. Následně byly tyto scény nahrány do softwaru ArcMap 10.4.1. Některé další kroky lze uskutečnit i v softwaru SNAP, ale pro rychlejší a přehlednější zpracování a následnou práci s potřebnými vektorovými vrstvami byl zvolen ArcMap.

3.1.3 Výběr míst s lavinovým proudem

Pro výběr míst, kde je jasně rozpoznatelné, že zde v určitém období spadla lavina, muselo být provedeno několik následujících kroků, aby nebylo toto místo označeno chybně.

Metodika použitá v této práci slouží především k tomu, aby mohl být zjištěn pád laviny i v nepřístupných místech například vysoko v horách, a tím se mohlo zamezit pohybu člověka v období, kdy hrozí pád lavin. V současné době NVE vede lavinové ročenky a zároveň poskytuje vektorová data s informacemi o místě, velikosti a datu pádu laviny. Jedná se zde ale pouze o laviny, které byly spatřeny člověkem, případně zjištěny

na některé z měřících stanic. Do této databáze navíc může přispívat kdokoliv s přihlašovacími údaji, a data jsou jen minimálně ověřována (Skredregistrering, 2019).

Takto je určeno v zájmovém území pouze 10-20 větších lavin ročně, tudíž by muselo být použito mnoho radarových scén. Eckerstorfer (2015) a Vickers (2016) však zmiňují velmi propracovanou metodiku pro zjišťování lavinových proudů z radarových snímků bez nutnosti znalosti přesného místa určení z pozemních stanic. Tato metodika pro určení těchto míst byla použita i zde pro eliminování obrovského množství radarových scén.

Nejprve je nutné vytvořit si masku území, na kterém pád laviny nehrozí. Tato maska zohledňuje sklon svahu a vegetaci. Dle Avalanche Canada (2019), nebo Kukala (1983 cit. v: PřF MU, 2018) se nejčastěji laviny vyskytují ve svahu se sklonem větším než 22-25° a menším než 45°. Potom už je sklon svahu příliš prudký na to, aby se na něm udržela větší vrstva sněhu. Pád lavin potom nehrozí v zalesněném území, kde stromy sesouvání sněhu zabrání. Digitální model terénu pro území Norska byl získán přes Kartverket.no (2019). Tato služba poskytuje jednotlivé dlaždice pro vybrané území o velikosti 50 x 50 km. Tyto dlaždice byly spojeny a z tohoto DTM vypočítán sklon svahu v zájmových údolích a jejich okolí. Sklon byl rozdělen do tří kategorií – pod 25°, 25-45° a více než 45°. Na Obr. č. 19 je dobře patrné, kde všude mohou laviny vzniknout. Není vyloučené, že lavinový proud zasáhne i do území s menším sklonem, které se může nacházet ve svahu pod místem, kde se lavina vytvořila.


Obr. č. 19: Sklon svahu na vybraném území v Norsku



Zdroj: Kartverket.no (2019), vlastní zpracování

Následně byla k zobrazení sklonu svahu přidána ještě vektorová vrstva lesů, dostupná na OpenStreetMap, a vrstva vodních ploch, aby nedošlo k chybnému určení lavinového proudu. Výsledná maska je zobrazena na Obr. č. 20. Z obrázku je patrné, že startovací zóna laviny se může nacházet pouze na žlutě vyobrazeném území.


Obr. č. 20: Výsledná maska pro určení výskytu lavin



Zdroj: OpenStreetMap (2019), Kartverket.no (2019), vlastní zpracování

Po vytvoření masky je dalším krokem RGB syntéza radarových snímků. Jako R kanál je použit referenční snímek staršího data (v tomto případě 25. 12. 2014 a 23. 12. 2018), jako G je zvolen aktivní snímek (6. 1. 2015 a 4. 1. 2018) a jako B opět referenční snímek. Výsledkem je snímek zobrazující změny ve zpětné odrazivosti. Zelenou barvou je zde vidět zvýšení zpětného záření, zatímco snížení má fialovou barvu. Na místech, kde neproběhla výrazná změna zpětné odrazivosti, je šedá barva (viz Obr. č. 21).


Obr. č. 21: RGB syntéza referenčního a aktivního snímku



Zdroj: Scihub (2019), vlastní zpracování

Na Obr. č. 22 jsou jednotlivá údolí přiblížena, aby byla lépe patrná změna zpětné odrazivosti.

Obr. č. 22 Změna zpětné odrazivosti v jednotlivých údolích




Zdroj: Scihub (2019), vlastní zpracování

Dle AVAMAP (2019) jsou zeleně zobrazeny nové laviny. Zpětná odrazivost na aktivním snímku se oproti referenčnímu zvýšila. Fialovou barvou je vyobrazen mokrý sníh a ukazuje na pokles zpětné odrazivosti, šedou barvou je zobrazeno území, kde nastala pouze malá změna mezi aktivním a referenčním snímkem. Černě je pak stín vzniklý radarovým snímáním.


Správnost určení laviny v RGB kombinaci snímků je možné ještě zkontrolovat odečtením referenčního snímku od aktivního, kde se jako lavinový proud zobrazí pixely s hodnotou zpětné odrazivosti větší než 6 dB (Vickers, 2016).

Pokud jsou snímky takto zpracované, je možné přikročit k dalšímu kroku, kterým je vyřezání obrázků o určité velikosti, které budou použité pro trénování neuronové sítě. Bylo rozhodnuto, že jednotlivé snímky budou mít velikost 64 x 64 pixelů pro rychlejší a přesnější natrénování sítě. Příklady výřezů jsou uvedeny na Obr. č. 23 a umístění konkrétních lavin v zájmových údolích na Obr. č. 24.

Obr. č. 23: Příklady výřezů míst s lavinovým proudem a bez




a) místa s lavinovým proudem



b) místa bez lavinového proudu

Obr. č. 24: Rozmístění vybraných lavin v zájmových údolích v Norsku



3.2 Metodika

3.2.1 Volba neuronové sítě

V práci je použita neuronová síť VGG-19, jejíž váhy jsou předtrénované na datasetu ImageNet. Použití této již předtrénované sítě se nazývá *transfer learning*. Jeho výhodou je v tom, že není potřeba strávit hodiny a hodiny trénováním sítě na obrovském trénovacím souboru. Je nutné pouze přidat na konec předtrénované neuronové sítě vrstvy tak, aby model určoval rozdělení do výsledných kategorií, v případě této práce do dvou: na obrázku se nachází lavina, nebo nenachází.

Neuronová síť VGG-19 je dostupná v aplikačním prostředí Keras. Tato síť byla vybrána z důvodu její dobré dostupnosti, přijatelného počtu vrstev a vzhledem k tomuto počtu vrstev také výborné úspěšnosti v určování snímků (viz Obr. č. 25) a je napsána v jazyce Python. V tomto programovacím jazyce je následně řešen veškerý další postup při používání neuronové sítě. Aby operace s neuronovými sítěmi správně fungovaly, bylo

využíváno open source platformy pro hluboké učení TensorFlow, díky níž lze používaný skript spustit.

Obr. č. 25: Důvod výběru modelu neuronové sítě VGG-19

Model	Image size	Weights size	Top-1 accuracy	Top-5 accuracy	Parameters	Depth
Xception	299 x 299	88 MB	0.790	0.945	22,910,480	126
VGG16	224 x 224	528 MB	0.715	0.901	138,357,544	23
VGG19	224 x 224	549 MB	0.727	0.910	143,667,240	26
ResNet50	224 x 224	99 MB	0.759	0.929	25,636,712	168
InceptionV3	299 x 299	92 MB	0.788	0.944	23,851,784	159
Inception ResNetV2	299 x 299	215 MB	0.804	0.953	55,873,736	572
MobileNet	224 x 224	17 MB	0.665	0.871	4,253,864	88

Zdroj: Keras, 2019

Skript, se kterým bylo pracováno, byl poskytnut Per Egil Kummervoldem z Norského výzkumného ústavu v Tromsø. Tento skript byl ale nefunkční a musel doznat značných úprav. Posloužil jako inspirace pro úpravy modelu neuronové sítě. Úpravy byly provedeny v softwaru PyCharm (JetBrains Community Edition 2018.3.1), kde pak probíhalo i trénování neuronové sítě a určování jednotlivých snímků. Celý skript je na přiloženém CD pod názvem *neuronova_sit*.

Pro určování jednotlivých snímků pak byl vytvořen další samostatný skript, který na základě uloženého modelu umí roztrždit obrázky do kategorií „Je lavina“ a „Není lavina.“ Skript vypíše název určovaného snímku a číselné zařazení (v procentech) do jednotlivých kategorií. Skript je uveden na přiloženém CD pod názvem *urcovani_lavin*.

4. Výsledky

V následující kapitole jsou popsány výsledky včetně popisu tvorby datasetu, trénování modelu neuronové sítě a celkového vyhodnocení následného testování na konkrétních datech.

4.1 Tvorba datasetu

Jak bylo uvedeno v kapitole výše, dataset obrázků pro trénování neuronové sítě se skládal z výřezů o velikosti 64 x 64 pixelů. Celkem bylo z radarových snímků vybráno 60 unikátních výřezů, na kterých se vyskytovala lavina či její část. Podmínkou bylo, aby se v každém výřezu vyskytovala lavina alespoň na 10 pixelech. Stejný počet obrázků byl vybrán i z oblastí, kde se lavina nevyskytovala. Celkem by tak dataset obsahoval 120 unikátních výřezů. Tento počet je ale pro trénování neuronových sítí velmi malý. Tyto sítě potřebují tisíce až desítky tisíc vzorků k tomu, aby byly natrénovány optimálně. Jelikož se ale zde jedná o již předtrénovanou síť VGG-19, není potřeba vytvořit tak obrovský dataset, přesto však byl počáteční počet výřezů uměle rozšířen otočením původních snímků o 90, 180 respektive 270 stupňů. Celkem tak vznikl dataset o počtu 480 snímků.

Následně bylo nutné rozdělit celý dataset na trénovací, validační a testovací. Trénovací složka je tvořena z 60 % obrázků (tj. 288, 144 snímků s lavinou a 144 bez) a testovací 40 % (96+96).

4.2 Trénování neuronové sítě

Na začátku je potřeba stanovit velikost dávky (batch size). Tato číselná hodnota určuje počet tréninkových obrázků, které projdou skrz neuronovou síť v rámci jedné epochy. Velikost dávky se stanovuje na základě počtu trénovacích dat, tzn. čím více trénovacích příkladů, tím větší může být dávka. Epocha je doba, kdy neuronovou sítí projdou všechny trénovací vzorky tam i zpět. Model neuronové sítě zobrazuje ještě počet iterací. Ten se zjišťuje na základě počtu trénovacích příkladů a velikosti dávky, např. když má neuronová síť provést 20 epoch s 288 trénovacími příklady a velikostí dávky 15, bude potřeba 19 iterací v jedné epoše (288/15, viz Obr. č. 26).

Obr. č. 26: Ukázka průběhu jedné epochy neuronové sítě VGG-19

```
1/19 [>.....] - ETA: 2:21 - loss: 0.6966 - acc: 0.4667
2/19 [=>.....] - ETA: 1:34 - loss: 0.7927 - acc: 0.5333
3/19 [==>....] - ETA: 1:16 - loss: 0.7601 - acc: 0.4889
4/19 [====>..] - ETA: 1:06 - loss: 0.7561 - acc: 0.5000
5/19 [=====>.] - ETA: 1:00 - loss: 0.7502 - acc: 0.4933
6/19 [=====>.] - ETA: 56s - loss: 0.7391 - acc: 0.5111
7/19 [=====>.] - ETA: 50s - loss: 0.7337 - acc: 0.4952
8/19 [=====>.] - ETA: 45s - loss: 0.7295 - acc: 0.4750epoch finished - C:/Users/Tereza/Desktop/obrazky/train_finish/


9/19 [=====>.] - ETA: 41s - loss: 0.7252 - acc: 0.4889
10/19 [=====>.] - ETA: 36s - loss: 0.7211 - acc: 0.5067
11/19 [=====>.] - ETA: 32s - loss: 0.7177 - acc: 0.5091
12/19 [=====>.] - ETA: 27s - loss: 0.7161 - acc: 0.5056
13/19 [=====>.] - ETA: 23s - loss: 0.7132 - acc: 0.5077
14/19 [=====>.] - ETA: 19s - loss: 0.7136 - acc: 0.4952
15/19 [=====>.] - ETA: 15s - loss: 0.7117 - acc: 0.4933
16/19 [=====>.] - ETA: 11s - loss: 0.7102 - acc: 0.4917
17/19 [=====>.] - ETA: 7s - loss: 0.7082 - acc: 0.4980
18/19 [=====>.] - ETA: 3s - loss: 0.7061 - acc: 0.5037epoch finished - C:/Users/Tereza/Desktop/obrazky/validation_finish/

19/19 [=====>.] - 86s 5s/step - loss: 0.7037 - acc: 0.5263 - val_loss: 0.6507 - val_acc: 0.7969
```

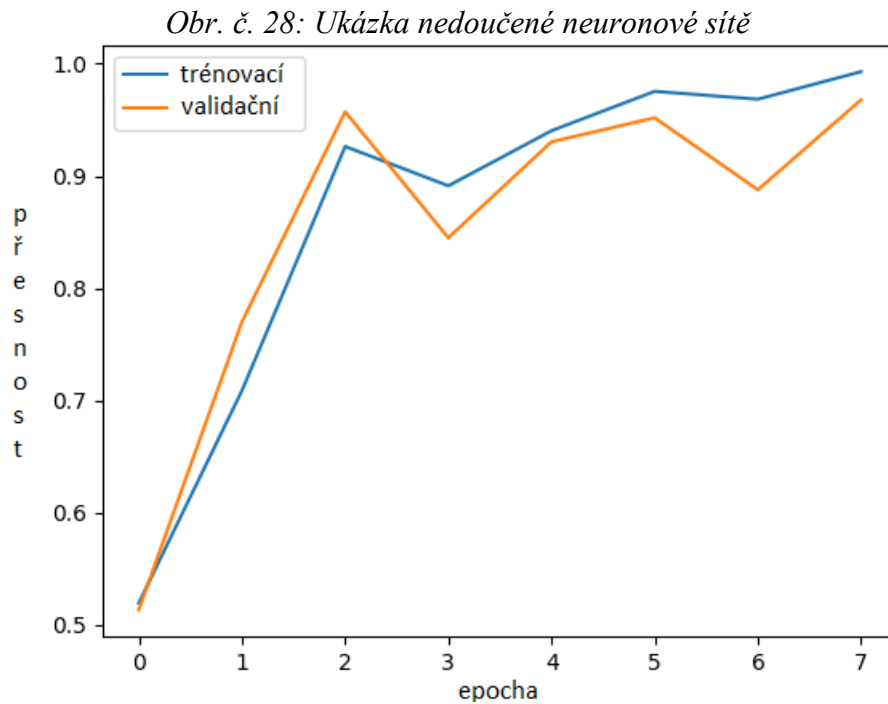
Na Obr. č. 26 je vidět průběh trénování neuronové sítě. Skript je schopen vypisovat výsledky po jednotlivých iteracích. Zobrazuje čas zbývající do ukončení epochy (ETA), hodnotu po provedení ztrátové funkce (loss), průměrnou přesnost jednotlivých iterací (acc) a na závěr epochy u provedené poslední iterace ještě hodnotu, s jakou přesností bude model předpovídat kategorie s novými daty (val_acc), a hodnotu val_loss, která je hodnotou ztrátové funkce u validačních dat.

Jako neuronová síť byla použita již zmíněná VGG-19. I přesto, že je možné si tuto nadefinovanou síť importovat z knihovny Keras, je potřeba provést úpravy tak, aby fungovala na konkrétní data. Je nutné také dbát na to, aby nebyla neuronová síť přeučená či nedoučená. K přeučení sítě dochází, pokud je přesnost trénovací složky větší než validační, jejíž přesnost zároveň s každou další epochou klesá (Obr. č. 27).

Obr. č. 27: Ukázka přeučení neuronové sítě




K nedoučení sítě dochází, pokud už učení skončí, ale křivky stále ukazují vzestupnou tendenci (Obr. č. 28).



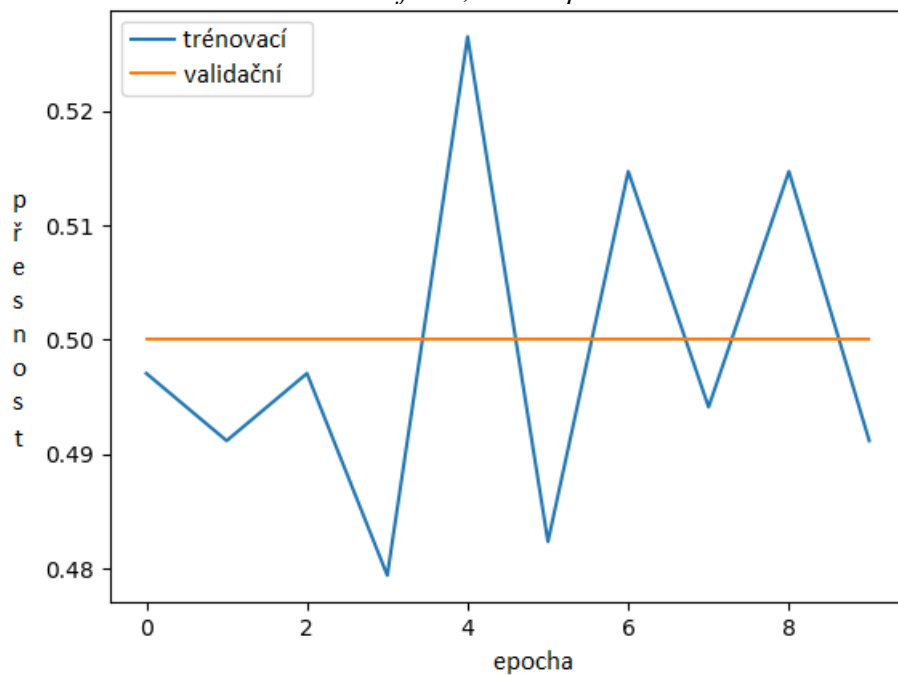
Oba tyto problémy – přeučení a nedoučení neuronové sítě způsobí následné nepřesnosti v určování požadovaných snímků. Na základě těchto výsledků byl stanoven počet epoch při trénování neuronové sítě na 8, velikost dávky 15.

Následně byly nastaveny parametry samotného modelu neuronové sítě. Jako váhy bylo nastaveno *None*, *include_top False*, *pooling average*. Jako optimalizátor byl nastaven Adam s doporučenými parametry kromě *alfa*, kde se doporučovaná hodnota ukázala jako příliš malá. Sice tak při snížení této hodnoty došlo ke zpomalení učení, ale také došlo ke zvýšení přesnosti trénování. Jako ztrátová funkce byla nakonec zvolena *categorical_crossentropy*, která sice neslouží pro binární klasifikaci, ale s jejím použitím došlo ke zlepšení výsledků. Metrika byla zvolena *accuracy*. Na obrázcích je vidět, jak se chovaly grafy přesnosti učení neuronové sítě, pokud byla nastavena ztrátová funkce binary cross entropy (Obr. č. 29) a parametr *alfa=0,001* u optimalizátoru Adam (Obr. č. 30).

Obr. č. 29: Ztrátová funkce „binary cross entropy“ při trénování neuronové sítě

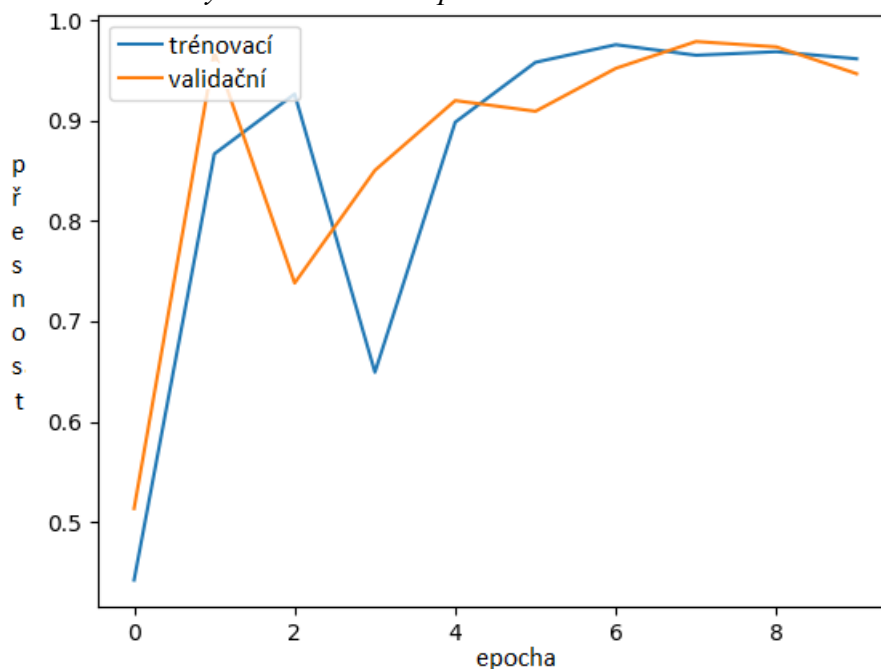


Obr. č. 30: Parametr $\alpha=0,001$ u optimalizátoru Adam



S takto nastavenými parametry zmíněnými výše pak vyšel model, kde byl výsledek přesnosti trénování sítě 97 % (Obr. č. 31), kde maxima bylo dosaženo po 8 epochách. Tento model sítě byl uložen ve formátu *.model*, a následně použit pro určování jednotlivých snímků. Schéma modelu je uvedeno v Příloze.

Obr. č. 31: Výsledek trénování použitého modelu neuronové sítě




4.3 Hodnocení jednotlivých snímků

Z celkového počtu 192 snímků, z toho 96 snímků s lavinou a 96 bez laviny, bylo zařazeno do kategorie „lavina“ 96 snímků, kde se lavina opravdu nacházela, ale také 15 snímků, kde lavina ve skutečnosti nebyla. Celkem se jedná o úspěšnost 92 %.

Snímky s lavinou byly do kategorie „lavina“ zařazovány celkem s 99 % pravděpodobností, většinou se jednalo o 100% určení, že na obrázku opravdu je lavina. Problematickým se stal pouze jeden snímek, který byl určen neuronovou sítí jako lavinový z 80 % (viz Obr. č. 32). Nižší pravděpodobnost, že na snímku je lavina, způsobil fakt, že se jednalo o malý lavinový splaz zobrazený ne tak velkým množstvím zelených pixelů.

Obr. č. 32: Problematický snímek při zařazování do kategorie „Je lavina“




U snímků bez laviny byla úspěšnost zařazení do kategorie „není lavina“ horší. Celkem bylo z 96 snímků zařazeno správně 81 snímků, ale ani u správně zařazených obrázků se většinou nejednalo o 100% pravděpodobnost určení kategorie. Celkem byly snímky zařazovány do kategorie „není lavina“ s pravděpodobností 79 %. Problematické snímky a pravděpodobnosti jejich zařazení do kategorií jsou v Tab. č. 3

Tab. č. 3: Pravděpodobnost zařazení do jednotlivých kategorií u problematických snímků

číslo snímku	je lavina [%]	není lavina [%]
150	52	48
151	61	39
157	71	29
158	82	18
160	64	36
176	57	43
187	98	2
192	83	17
195	74	26
211	71	29
217	81	19
218	94	6
219	53	47
220	72	28
236	65	35


Na Obr. č. 33 jsou jednotlivé snímky, které byly zařazeny do kategorie „je lavina“, přestože se na nich lavina nenachází. Z výsledků je patrné, že neuronová síť nebyla schopná zařadit správně určité typy snímků, a to takové, na kterých se nachází větší množství zelených pixelů, které lavinu zobrazují. Dále byl také problém např. u snímku č. 176, kde se v levé části vyskytl stín při snímání radarem. Tento samý jev je patrný i na snímku č. 195 nebo č. 236.

Obr. č. 33: Jednotlivé snímky, zařazené do špatné kategorie



Oproti tomu na Obr. č. 34 jsou uvedeny příklady správně určených snímků, které byly zařazeny do kategorie „není lavina“. Na těchto snímcích nejsou patrné žádné fragmenty lavinového splazu, zelené, fialové a šedé pixely jsou rovnoměrně rozmístěny po celém výřezu a pro neuronovou síť tak bylo jednodušší zařadit tyto obrázky do správné kategorie s pravděpodobností 97 %.


Obr. č. 34: Příklady správně určeného snímku



Celkově se tedy ukázalo, že neuronová síť zvládá určovat snímky s lavinou mnohem lépe než ty, kde se lavina nenachází a kde velmi často dochází k tomu, že je neuronová síť chybně vyhodnotí. Výsledek 81 snímků bez laviny určených správně a 15 špatně, kdy u některých příkladů neuronová síť určila snímek jako lavinový z 98 %, byl neuspokojivý. Bylo tedy vhodné nalézt takové řešení, aby neuronová síť neměla takové problémy s určováním snímků bez lavin.

V představeném řešení byly snímky do trénovacího a testovacího datasetu vybrány náhodně. Prvních 144 snímků z každé kategorie bylo zařazeno do trénovacího a zbylých 96 snímků do testovacího datasetu. Tím pádem se stalo, že v trénovacím datasetu nebyly všechny typy snímků, které se pak mohly vyskytnout při testování. Po druhé tedy bylo rozdělení do datasetů provedeno pečlivěji, aby se v obou dvou skupinách nacházely všechny typy příkladů. Následně byla celá neuronová síť znovu natrénována na nových trénovacích datech (Obr. č. 35). Tentokrát bylo dosaženo maxima už po pěti epochách na 99 %.


Obr. č. 35: Výsledek trénování použitého modelu neuronové sítě po změně obsahu datasetu



Model takto natrénované sítě byl opět uložen a následně spuštěn na jednotlivé snímky. Bylo opět vybráno 96 snímků a lavinou a 96 bez laviny.

Nově natrénovaný model neuronové sítě zařadil 95 snímků s lavinou do kategorie „je lavina“ a 1 snímek s lavinou do kategorie „není lavina“. Ostatní snímky byly zařazovány do kategorie „je lavina“ s 97 % pravděpodobností. Chybně zařazený snímek (Obr. č. 36). Jedná se o podobný typ obrázku, jaký byl i v předchozím případě označen za lavinový jen z 80 %. Je to způsobené opět malým počtem zelených pixelů označujících lavinu.

Obr. č. 36: Chybně zařazený snímek do kategorie „není lavina“



Při určování 96 snímků, na kterých se lavina nenacházela, ale došlo k výborným výsledkům. Ani jeden snímek nebyl zařazen do chybné kategorie, a neuronová síť označovala snímky jako „není lavina“ s pravděpodobností 99,86 %.

V Tab. č. 4 a č. 5 je uvedeno shrnutí výsledků obou testování a celková úspěšnost určování. Výsledky určení jednotlivých snímků jsou pak uvedeny v Příloze.

Tab. č. 4: Celkové výsledky při testování prvního modelu neuronové sítě

1. testování	lavinové snímky		snímky bez laviny	
kategorie	je lavina	není lavina	je lavina	není lavina
pravděpodobnost určení [%]	99,14	0,86	21,07	78,93

celková pravděpodobnost určení do správné kategorie: 92,19 %

Tab. č. 5: Celkové výsledky při testování druhého modelu neuronové sítě

2. testování	lavinové snímky		snímky bez laviny	
kategorie	je lavina	není lavina	je lavina	není lavina
pravděpodobnost určení [%]	97,38	2,62	0,14	99,86

celková pravděpodobnost určení do správné kategorie: 99,48 %

5. Diskuze

Pro zjišťování lavin z dat radaru se syntetickou aperturou bylo navrženo poměrně velké množství postupů, z nichž je základním určování z barevné kompozice referenčního a aktivního snímku. Volba těchto snímků je pro nalezení laviny velmi zásadní. Je důležité, aby v době pořízení snímku panovalo konstantní počasí, to znamená nebyly srážky a sníh netál. Na tento problém narazila Vickers (2016), kdy se některé laviny na snímkách zobrazily, ačkoliv ve skutečnosti na místě žádná nespadla.

V současnosti je na základě výše zmíněné metodiky aktuální projekt AVAMAP, kde na vybraných územích testují uvedený algoritmus pro rozpoznávání lavin, a následně jsou z něho schopni vygenerovat vektorovou vrstvu lavinových splazů. Přestože úspěšnost určování tohoto algoritmu není stoprocentní, je jejich cílem vytvořit časovou řadu dat, která bude sloužit pro další zkoumání lavin a pro plánování infrastruktury nebo sledování změn klimatu.

Podle Kummervolda (2018) jsou ale metody určování lavin, jak představuje Vickers (2017) na hranici nejvyšší dokonalosti. V článku dosahují přesností 90 % u ideálních případů lavin, ale u více problematických lavinových splazů přesnost klesá k pouhým 50 %. Za problematické případy považují malé laviny nebo laviny poblíž radarového stínu, anebo náhlou změnu teploty sněhu v době pořízení referenčního a aktivního snímku. Proto přišli s návrhem klasifikace lavin pomocí neuronových sítí. Konkrétně se jedná o VGG-19 a AConvNet, což je jednoduchá konvoluční neuronová síť. Následně kombinují polarizace radarových snímků, ale u všech výsledků dosahují přesnosti trénování neuronových sítí kolem 90 %. Neuvádí ale, kolik přesně lavinových snímků se jim podařilo správně určit, a kolik snímků bylo zařazeno do nesprávné kategorie, jsou zde uvedeny pouze vybrané příklady, můžeme se tak tedy jenom domnívat, jak moc dobře se podařilo neuronovou síť natrénovat.

V této práci je použitý postup, který uvádí jak Vickers (2016, 2017), tak Kummervold (2018). Co se týče natrénování sítě, bylo dosaženo lepších výsledků na menším množství trénovacích dat. Souvisí to pravděpodobně s nastavením parametrů modelu neuronové sítě, s tím, že předtrénovaná síť nepotřebuje takové množství dat, a také s výběrem trénovacích dat, což je velmi důležitý prvek, na který Kummervold (2018) neupozorňuje. Ukázalo se totiž, že k tomuto kroku se musí přistoupit velmi pečlivě tak, aby trénovací data obsahovala opravdu všechny příklady výřezů lavin a především míst, kde se laviny nenachází. Pokud byl totiž dataset rozdělen náhodně, neuronová síť sice při

trénování dosáhla obdobné přesnosti, ale následné určování jednotlivých výřezů už tak úspěšné nebylo.

Model neuronové sítě byl použit pro jiné výřezy lavin, než je tomu u Kummervolda (2018), a přesto bylo dosaženo větší úspěšnosti. Tím bylo prokázáno, že metoda s neuronovými sítěmi může být použita pro kterékoliv území, kde se laviny vyskytují, nemusí se jednat jen o zde zmíněná údolí. I přesto, že trénování neuronové sítě zabere poměrně dlouhou dobu, než se správně naladí volitelné parametry pro konkrétní obrázky, určování následných snímků do kategorií už pak funguje automaticky a nevyžaduje žádné úpravy.

Následné přiřazování do kategorií bylo dle názoru autorky velmi úspěšné, protože se podařilo dosáhnout 99 %. V dostupné literatuře se nikde nenachází, které konkrétní výřezy lavin byly zařazeny do správné nebo do špatné kategorie a s jakými pravděpodobnostmi, proto by se dalo směle říci, že tato práce přináší velký pokrok, neboť jsou zde představeny problematické snímky a také to, že záleží na obsahu trénovacího datasetu.

6. Závěr

Cílem této práce bylo na základě rešerše literatury stanovit algoritmus pro rozpoznávání lavinových splazů na radarových snímcích za pomoci neuronových sítí. Původní záměr vytvořit svou vlastní neuronovou síť nebyl dodržen, jelikož téma neuronových sítí jako takové je velmi náročné a problematické a nikde nejsou stanoveny konkrétní postupy. I tak zabralo pochopení fungování předtrénované neuronové sítě největší díl času při tvorbě této práce.

Po nastudování literatury bylo rozhodnuto, že bude použita síť VGG-19, která i přesto, že obsahuje 19 vrstev, stále vykazuje vysoký stupeň přesnosti při trénování. Skript v jazyce Python byl získán od Per Egil Kummervolda, ale následně byl upraven tak, aby fungoval na vlastní data a byla k němu připojena část, která rozliší jednotlivé výřezy do potřebných kategorií. K předzpracování snímků z radarových dat byla využita metoda, kterou uvádí Vickers (2016 a 2017).

Pro správné provedení bylo zapotřebí jak pečlivě vybrat aktivní a referenční snímek ze Sentinelu-1, tak důkladně zvolit takové území, aby na něm docházelo k pravidelnému pádu lavin. V Evropě se mohlo jednat o alpské oblasti, nebo o Norsko. To bylo nakonec vybráno z důvodu toho, že se autorka s Norskem setkala již při své bakalářské práci, a měla tak lepší přehled o dostupnosti dat o počasí na tomto území.

Největší problém byl se získáním validačních pozemních dat, která jsou k dispozici jen v omezené míře. Tento problém zmiňuje i Eckerstorfer (2016). Pro tuto práci byla použita validační data z Norského ředitelství pro vodní zdroje a energetiku, kteří vydávají lavinové ročenky a provozují webovou stránku s informacemi o spadlých lavinách. Jedná se však pouze o zlomek lavin, který na tomto území spadne. Proto byla použita tato data v kombinaci s vizuální interpretací zobrazených radarových dat, v nichž lze určit místa zasažená lavinou podle prostorových příznaků.

Celkově by se dalo říci, že cíle práce byly splněny. Algoritmus rozpoznává laviny ale pouze na malých výřezech, mohlo by se tedy do budoucna uvažovat o zvětšení výřezů, případně o vylepšení algoritmu o to, aby uměl například určit i velikost laviny nebo vymežit její přesný tvar. Bylo dokázáno, že neuronové sítě mohou výrazně napomoci při určování lavinových splazů v nepřístupném terénu z radarových dat a určovat místa pádu lavin s lepší přesností než jiné doposud známé metody.

Použitá literatura

BERRY, P. A. M., BENVENSITE, J., SMITH, R. G. (2008): ACE2: The New Global Digital Elevation Model. Gravity, Geoid and Earth Observation: IAG Commission 2: Gravity Field, Chanie, Crete, Greece. p. 231-237.

ECKERSTORFER, M., MALNES, E. (2015): Manual detection of snow avalanche debris using high-resolution Radarsat-2 SAR images. Cold Regions Science and Technology, vol. 120, s. 205-218.

ECKERSTORFER, M., BÜHLER, Y., FRAUENFELDER, R., MALNES, E. (2016): Remote sensing of snow avalanches: Recent advances, potential and limitations. Cold Regions Science and Technology 2016, vol. 121, str. 126-140.

ECKERSTORFER, M., MALNES, E., MÜLLER, K. (2017): A complete snow avalanche activity record from a Norwegian forecasting region using Sentinel-1 satellite-radar data. Cold Regions Science and Technology, article in press, 14 s.

KARVÁNEK, M. (2016): Využití dat Sentinel-1 pro tvorbu digitálního modelu terénu metodou radarové interferometrie. Diplomová práce. Přírodovědecká fakulta Univerzity Karlovy v Praze. 83 s.

KOCIÁNOVÁ, M. (2013): Sněhové laviny. Geografické rozhledy 3/13-14, s. 8-9.

KUMMERVOLD, P. E., MALNES, E., ECKERSTORFER, M., ARNTZEN, I. M., BIANCHI, F. (2018): Avalanche detection in sentinel-1 radar images using convolutional neural networks. Researchgate [online]. Dostupné z: https://www.researchgate.net/publication/328042094_Avalanche_detection_in_Sentinel-1_radar_images_using_convolutional_neural_networks. [cit. 22-02-2019].

MALNES, E., ECKERSTORFER, M., LARSEN, Y., FRAUENFELDER, R., JÓNSSON, Á., JAEDICKE, CH., SOLBØ, S. A. (2013): Remote sensing of avalanches in northern Norway using Synthetic Aperture Radar. International Snow Science Workshop Grenoble 2013, 5 s.

MALNES, E., ECKERSTORFER, M., VICKERS, H. (2015): First Sentinel-1 detections of avalanche debris. The Cryosphere Discuss, vol. 9, s. 1943-1963.

MANSOURPOUR, M., RAJABI, M. A., BLAIS, J. A. R. (2006): Effects and Performance of Speckle Noise Reduction Filters on Active Radar and SAR Images. Dept. of Geomatics Eng, University of Tehran, Tehran. 7 s.

MOREIRA, A., PRATS-IRAOLA P., YOUNIS, M. (2013): A Tutorial on Synthetic Aperture Radar. IEEE Geoscience and Remote Sensing Magazine, vol. 1, Issue 1, s. 6-43.

NAGLER, T. (1998): Methods and Analysis of Synthetic Aperture Radar Data from ERS-1 and X-SAR for Snow and Glacier Applications. Disertační práce. University of Innsbruck. 184 s.

OUTRATA, D. (2017): Určování vlhkosti půdy s využitím radarových dat Sentinel-1. Diplomová práce. Přírodovědecká fakulta Univerzity Karlovy v Praze. 75 s.

RAUCH, T. (2011): Využití družicových radarových dat pro monitorování záplav v závislosti na typu krajinného pokryvu. Diplomová práce. Přírodovědecká fakulta Univerzity Karlovy v Praze. 83 s.

REK, P. (2018): Knihovna pro návrh konvolučních neuronových sítí. Diplomová práce. Fakulta informačních technologií, Vysoké učení technické v Brně. 75 s.

SOROKINA, K. (2017): Image Classification with Convolutional Neural Networks. [online] Dostupné z: <https://medium.com/@ksusorokina/image-classification-with-convolutional-neural-networks-496815db12a8> [cit. 25-03-2019].

SIMONYAN, K., ZISSERMAN, A. (2015): Very deep convolutional networks for large-scale image recognition. Conference paper at ICLR 2015, 14 s.

SOUČKOVÁ, J. (2010): Stanovení rozsahu sněhové pokrývky z radarových dat. Diplomová práce, Přírodovědecká fakulta Univerzity Karlovy v Praze, 77 s.

ŠIMČÍKOVÁ, J. (2013): Lavinové nebezpečí a záchranné práce. Bakalářská práce. Vysoké učení technické v Brně. 50 s.

ŠTANGLOVÁ, T. (2017): Detekce specifických objektů v digitálním snímku pro potřeby určení druhu obsahu scény. Diplomová práce. Fakulta aplikovaných věd, Západočeská univerzita v Plzni, 66 s.

VICKERS, H., ECKERSTORFER, M., MALNES, E., LARSEN, Y., HINDBERG, H. (2016): A method for automated snow avalanche debris detection through use of synthetic aperture radar (SAR) imaging. *Earth and Space Science*, 3, s. 446-462.

VICKERS, H., ECKERSTORFER, M., MALNES, E., DOULGERIS, A. (2017): Synthetic Aperture Radar (SAR) Monitoring of Avalanche Activity: An Automated Detection Scheme. Springer International Publishing, SCIA 2017, Part II, LNCS 10270, s. 136-146.

WESSELINK, D. S., MALNES, E., ECKERSTORFER, M., LINDENBERGH, R. C. (2017): Automatic detection of snow avalanche debris in central Svalbard using C-band SAR data. *Polar Research* 2017, vol. 36 [online]. Dostupné z: <https://www.tandfonline.com/doi/full/10.1080/17518369.2017.1333236> [cit. 22-02-2019].

WIESMANN, A., WEGMÜLLER, U., HONIKEL, M., STROZZI, T., WERNER, CH. L. (2001): Potential and methodology of satellite based SAR for hazard mapping. *Proceedings of IARSS 2001*, Sydney, Australia, 3 s.

Internetové zdroje:

ANANTHRAM, A. (2018): Deep Learning For Beginners Using Transfer Learning In Keras. Dostupné z: <https://towardsdatascience.com/keras-transfer-learning-for-beginners-6c9b8b7143e> [cit. 23-06-2018].

AVALANCHE CANADA (2019): Online Avalanche Tutorial. Dostupné z: <https://www.avalanche.ca/tutorial/avalanche-terrain/slope-angle> [cit. 09-07-2019].

AVAMAP (2019): Worldwide avalanche detection using Sentinel-1. [online] Dostupné z: <https://sites.google.com/norut.no/avamap/home> [cit. 27-03-2019].

BROWNLEE, J. (2019): A Gentle Introduction to Pooling Layers for Convolutional Neural Networks. Dostupné z: <https://machinelearningmastery.com/pooling-layers-for-convolutional-neural-networks/> [cit. 23-06-2019].

COLLGS (2019): Sentinel 1 – Datové specifikace. Dostupné z: <http://collgs.czechspaceportal.cz/sentinel-1-datove-specifikace/> [cit. 16-06-2019].

DURČÁK, P. (2017): Neuronové sítě a princip jejich fungování. Dostupné z: <https://www.napocitaci.cz/33/neuronove-site-a-princip-jejich-fungovani-uniqueidgOkE4NvrWuNY54vrLeM670eFNQh552VdDDulZX7UDBY/> [cit. 23-06-2019].

ECHOES IN SPACE (2019a): The Radar Bands. Dostupné z: <https://eo-college.org/topic/the-sar-bands/> [cit. 17-07-2019].

ECHOES IN SPACE (2019b): What does the term SAR mean? Dostupné z: <https://eo-college.org/topic/the-sar-principle/> [cit. 17-07-2019].

EO-COLLEGE.ORG (2018): Echoes in Space. Introduction to Radar Remote Sensing. Dostupné z: <https://eo-college.org/courses/echoes-in-space/> [cit. 15-06-2019].

ESA (2019a): Geometry glossary. Dostupné z: <https://earth.esa.int/handbooks/asar/CNTR5-5.html#eph.asar.gloss.geo:GEOMETRY> [cit. 17-07-2019].

FYZWEB (2019): Dopplerův jev a rázová vlna. Dostupné z: http://fyzweb.cz/materialy/aplety_hwang/Doppler/index.html [cit. 17-07-2019].

GEONORGE.NO (2019): Kartkatalogen. Dostupné z: <https://www.geonorge.no/> [cit. 16-06-2019].

GISAT (2019): Radarová interferometrie. Dostupné z: <http://www.gisat.cz/content/cz/dpz/zpracovani-dat/radarova-interferometrie> [cit. 17-07-2019].

GOGUL09 (2017): Using Keras Pre-trained Deep Learning models for your own dataset. Dostupné z: <https://gogul09.github.io/software/flower-recognition-deep-learning> [cit. 23-06-2019].

HORSKÁ SLUŽBA ČR (2019): Historie výzkumu lavin v ČR. Dostupné z: <https://www.horskasluzba.cz/cz/horska-sluzba/laviny/informace-o-lavinach/historie-vyzkumu-lavin-v-cr> [cit. 15-07-2019].

- CHEN, B., DENG, W. (2017): Noisy Softmax: Improving the Generalization Ability of DCNN via Postponing the Early Softmax Saturation. Dostupné z: https://www.researchgate.net/publication/319121953_Noisy_Softmax_Improving_the_Generalization_Ability_of_DCNN_via_Postponing_the_Early_Softmax_Saturation [cit. 20-07-2019].
- KARTVERKET.NO (2019): Open and free geospatial data from Norway. Dostupné z: <https://www.kartverket.no/en/> [cit. 16-06-2019].
- KERAS (2019): Keras: The Python Deep Learning library. Dostupné z: <https://keras.io> [cit. 23-06-2019].
- LAVINY.INFO (2019): Lavinové dráhy. [online]. Dostupné z: <http://www.laviny.info/lavinove-drahy.html> [cit. 22-02-2019].
- NASA (2019): Jet Propulsion Library. Dostupné z: <https://www2.jpl.nasa.gov/srtm/coverage.html> [cit. 09-07-2019].
- NORSKÉ ŘEDITELSTVÍ PRO VODNÍ ZDROJE A ENERGETIKU (2019): All weather data. Dostupné z: <http://www.senorge.no/index.html?p=fag> [cit. 16-06-2019].
- OPENSTREETMAP (2019): Geofabrik downloads. Dostupné z: <http://download.geofabrik.de/europe/norway.html> [cit. 10-07-2019].
- PŘF MU (2018): Přírodní katastrofy a environmentální hazardy, Sněhové laviny. Dostupné z: <http://www.sci.muni.cz/~herber/avalanche.htm> [cit. 22-02-2019].
- SCIHUB (2019): Copernicus Open Access Hub. Dostupné z: <https://scihub.copernicus.eu/> [cit. 09-07-2019].
- SKREDREGISTRERING (2019): Skredregistrering. Dostupné z: <https://www.skredregistrering.no/#Forsiden> [cit. 20-07-2019].
- SNOSKRED I TAMOKDALEN (2019). Dostupné z: <https://www.nrk.no/troms/snoskred-i-tamokdalen-1.14363523> [cit. 16-06-2019].
- STEP (2019): SNAP. Dostupné z: <https://step.esa.int/main/toolboxes/snap/> [cit. 16-06-2019].
- TSANG, SIK-HO (2018): Review: VGGNet – 1st Runner-Up (Image Classification), Winner (Localization) in ILSVRC 2014. Dostupné z: <https://medium.com/coinmonks/paper-review-of-vggnet-1st-runner-up-of-ilsvrc-2014-image-classification-d02355543a11> [cit. 23-06-2019].
- WIKIPEDIA (2019): Elektromagnetické spektrum. Dostupné z: https://cs.wikipedia.org/wiki/Elektromagnetick%C3%A9_spektrum [cit. 27-03-2019].

Seznam příloh

Příloha 1: Zařazení jednotlivých snímků do kategorií

Příloha 2: Model neuronové sítě

Příloha 3: Obsah přiloženého CD

Příloha 1: Zařazení jednotlivých snímků do kategorií

Tab. č. 1: Zařazení vybraných snímků do kategorií po prvním natrénování sítě

snímky s lavinou			snímky bez laviny		
č. snímku	Je lavina [%]	Není lavina [%]	č. snímku	Je lavina [%]	Není lavina [%]
145	100	0	145	6	94
146	100	0	146	7	93
147	97	3	147	15	85
148	100	0	148	45	55
149	100	0	149	4	96
150	100	0	150	52	48
151	100	0	151	61	39
152	100	0	152	14	86
153	100	0	153	6	94
154	100	0	154	4	96
155	100	0	155	12	88
156	100	0	156	4	96
157	100	0	157	71	29
158	100	0	158	82	18
159	100	0	159	41	59
160	100	0	160	64	36
161	100	0	161	7	93
162	100	0	162	3	97
163	100	0	163	4	96
164	100	0	164	4	96
165	100	0	165	17	83
166	100	0	166	5	95
167	100	0	167	28	72
168	100	0	168	2	98
169	100	0	169	10	90
170	100	0	170	19	81
171	100	0	171	6	94
172	100	0	172	7	93
173	93	7	173	8	92
174	100	0	174	7	93
175	100	0	175	7	93
176	100	0	176	57	43
177	100	0	177	7	93
178	100	0	178	8	92
179	100	0	179	14	86
180	100	0	180	9	91
181	100	0	181	7	93
182	100	0	182	24	76
183	100	0	183	4	96
184	100	0	184	5	95
185	100	0	185	5	95

snímky s lavinou			snímky bez laviny		
č. snímku	Je lavina [%]	Není lavina [%]	č. snímku	Je lavina [%]	Není lavina [%]
186	100	0	186	7	93
187	100	0	187	98	2
188	100	0	188	32	68
189	100	0	189	10	90
190	99	1	190	37	63
191	100	0	191	4	96
192	100	0	192	83	17
193	100	0	193	23	77
194	80	20	194	36	64
195	100	0	195	74	26
196	100	0	196	3	97
197	100	0	197	40	60
198	100	0	198	5	95
199	100	0	199	5	95
200	95	5	200	17	83
201	100	0	201	3	97
202	100	0	202	7	93
203	100	0	203	6	94
204	85	15	204	4	96
205	100	0	205	5	95
206	100	0	206	5	95
207	96	4	207	11	89
208	88	12	208	12	88
209	100	0	209	9	91
210	100	0	210	30	70
211	100	0	211	71	29
212	100	0	212	28	72
213	100	0	213	7	93
214	100	0	214	5	95
215	100	0	215	9	91
216	100	0	216	3	97
217	100	0	217	81	19
218	100	0	218	94	6
219	100	0	219	53	47
220	100	0	220	72	28
221	100	0	221	3	97
222	100	0	222	3	97
223	100	0	223	5	95
224	100	0	224	4	96
225	97	3	225	20	80
226	96	4	226	4	96
227	100	0	227	29	71
228	100	0	228	31	69
229	100	0	229	13	87

snímky s lavinou			snímky bez laviny		
č. snímku	Je lavina [%]	Není lavina [%]	č. snímku	Je lavina [%]	Není lavina [%]
230	100	0	230	28	72
231	100	0	231	8	92
232	93	7	232	6	94
233	99	1	233	8	92
234	100	0	234	7	93
235	100	0	235	7	93
236	100	0	236	65	35
237	100	0	237	7	93
238	100	0	238	5	95
239	100	0	239	11	89
240	100	0	240	8	92
celkem	99,146	0,854	celkem	21,073	78,927

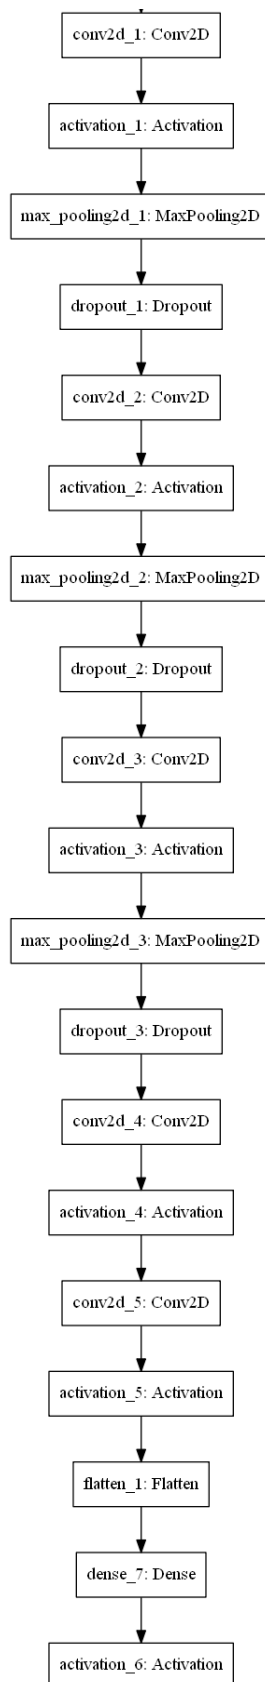
Tab č. 2: Zařazení vybraných snímků do kategorií po druhém natrénování sítě

snímky s lavinou			snímky bez laviny		
č. snímku	Je lavina [%]	Není lavina [%]	č. snímku	Je lavina [%]	Není lavina [%]
25	100	0	25	0	100
26	100	0	26	0	100
27	11	89	27	0	100
28	100	0	28	0	100
29	100	0	29	0	100
30	100	0	30	0	100
46	99	1	46	0	100
47	100	0	47	0	100
48	100	0	48	1	99
49	100	0	49	1	99
50	100	0	50	1	99
51	100	0	51	0	100
52	84	16	52	0	100
53	100	0	53	0	100
54	100	0	54	0	100
55	100	0	55	0	100
56	100	0	56	1	99
57	100	0	57	0	100
58	100	0	58	0	100
59	100	0	59	0	100
60	100	0	60	0	100
76	100	0	76	0	100
77	100	0	77	0	100
78	100	0	78	0	100
79	100	0	79	0	100
80	100	0	80	0,4	99,6

snímky s lavinou			snímky bez laviny		
č. snímku	Je lavina [%]	Není lavina [%]	č. snímku	Je lavina [%]	Není lavina [%]
81	100	0	81	0	100
82	100	0	82	0,2	99,8
83	100	0	83	0,3	99,7
84	81	19	84	0,2	99,8
85	100	0	85	0,3	99,7
86	100	0	86	0,3	99,7
87	82	18	87	0,3	99,7
88	100	0	88	0,17	99,83
89	100	0	89	0	100
90	100	0	90	0,3	99,7
106	100	0	106	0	100
107	100	0	107	0	100
108	100	0	108	0	100
109	100	0	109	1	99
110	100	0	110	1	99
111	100	0	111	0	100
112	90	10	112	0	100
113	87	13	113	0	100
114	100	0	114	0	100
115	100	0	115	0	100
116	100	0	116	1	99
117	100	0	117	0	99
118	100	0	118	0	100
119	100	0	119	0	100
120	100	0	120	0	100
136	100	0	136	0	100
137	100	0	137	0	100
138	100	0	138	0	100
139	100	0	139	0	100
140	100	0	140	1	99
141	100	0	141	0	100
142	100	0	142	0	100
143	100	0	143	0	100
144	81	19	144	0	100
145	100	0	145	0	100
146	100	0	146	0	100
147	82	18	147	0	100
148	100	0	148	0	100
149	100	0	149	0	100
150	100	0	150	0	100
166	100	0	166	0	100
167	100	0	167	0	100
168	100	0	168	0	100
169	100	0	169	1	99

snímky s lavinou			snímky bez laviny		
č. snímku	Je lavina [%]	Není lavina [%]	č. snímku	Je lavina [%]	Není lavina [%]
170	100	0	170	1	99
171	100	0	171	0	100
172	90	10	172	0	100
173	89	11	173	0	100
174	100	0	174	0	100
175	100	0	175	0	100
176	100	0	176	1	99
177	100	0	177	0	100
178	100	0	178	0	100
179	100	0	179	0	100
180	100	0	180	0	100
196	100	0	196	0	100
197	100	0	197	0	100
198	100	0	198	0	100
199	100	0	199	0	100
200	100	0	200	0	100
201	100	0	201	0	100
202	100	0	202	0	100
203	100	0	203	0	100
204	87	13	204	0	100
205	100	0	205	0	100
206	100	0	206	0	100
207	85	15	207	0	100
208	100	0	208	0	100
209	100	0	209	0	100
210	100	0	210	0	100
celkem	97,375	2,625	celkem	0,141	99,859

Příloha 2: Model neuronové sítě



Příloha 3: Obsah přiloženého CD

Přiložené CD obsahuje:

- 1) Text práce
- 2) Celý dataset obrázků
- 3) Skript
 - a) neuronova_sit.py
 - b) urcovani_lavin.py