

**Univerzita Karlova**

Přírodovědecká fakulta

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Jan Fišer

**DETEKCE SNĚHOVÉ POKRÝVKY Z WEBOVÝCH KAMER**

**SNOW COVER DETECTION FROM WEBCAM IMAGES**

*Diplomová práce*

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

Náchod 2019

**Vysoká škola:** Univerzita Karlova

**Fakulta:** Přírodovědecká

**Katedra:** Aplikované geoinformatiky a kartografie

**Akademický rok:** 2018/2019

# Zadání diplomové práce

**pro** Bc. Jana Fišera

**obor** Kartografie a geoinformatika

**Název tématu:** Detekce sněhové pokrývky z webových kamer

## Zásady pro vypracování

### Anotace

Cílem práce je navrhnout vhodnou metodu detekce sněhové pokrývky z volně dostupných webkamer a vytvořit prototyp pro ověření této metody. Metoda bude ověřena na datech z alespoň šesti webových kamer v různých geografických lokalitách (nížina, podhůří, horská oblast), a sběr těchto dat proběhne během alespoň jedné zimní sezóny. Výstupem bude informace o sněhové pokrývce v lokalitě webkamery s časovou známkou. Validace výsledků proběhne na základě nezávislých měření.

Díličmi cíli práce jsou:

- navržení metody automatizované detekce sněhové pokrývky na RGB snímcích z volně dostupných webkamer pomocí jednoduchého algoritmu prahování a strojového učení,
- zhodnocení vlivu velikosti referenčních dat pro parametrizaci modelu na celkovou přesnost detekce sněhové pokrývky,
- porovnání přesnosti detekce sněhové pokrývky s odbornou literaturou,
- ověření přenositelnosti vytvořeného modelu mezi webkamerami,
- výpočet sněhových frakcí a validace získaných výsledků.

**Rozsah grafických prací:** cca 5 stran

**Rozsah průvodní zprávy:** cca 60 stran

**Seznam odborné literatury:**

BRADLEY, E. S., CLARKE, K. C. (2013): Outdoor Webcams as Geospatial Sensor Networks: Challenges, Issues and Opportunities. *Cartography and Geographic Information Science*, 38, č. 1, s. 5–22.

DONG, CH. (2018): Remote sensing, hydrological modeling and in situ observations in snow cover research: A review. *Journal of Hydrology*, 561, s. 573–583.

FEDOROV, R., CAMERADA, A., FRATERNALI, P., TAGLIASACCHI, M. (2016): Estimating Snow Cover From Publicly Available Images. *IEEE Transactions on Multimedia*, 18, č. 6, s. 1187–1200.

FIERZ, C., ARMSTRONG, R. L., DURAND, Y., ETCHEVERS, P., GREENE, E., MCCLUNG, D. M., NISHIMURA, K., SATYAWALI, P. K., SOKRATOV, S. A. (2009): The International Classification for Seasonal Snow on the Ground. UNESCO-IHP, Paris, 80 s.

HINKLER, J., HANSEN, B. U. (2002): Automatic snow cover monitoring at high temporal and spatial resolution, using images taken by a standard digital camera. *International Journal of Remote Sensing*, 23, č. 21, s. 4669–4682.

LAFFLY, D., BERNARD, É., GRISELIN, M., TOLLE, F., FRIEDT, J.-M., MARTIN, G., MARLIN, C. (2012): High temporal resolution of snow cover using oblique view ground-based pictures. *Polar Record*, 48, č. 1, s. 11–16.

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

Konzultant diplomové práce:

Datum zadání diplomové práce: leden 2019

Termín odevzdání diplomové práce: červenec 2019

*Platnost tohoto zadání je po dobu jednoho akademického roku.*

.....

Vedoucí diplomové práce

.....

Garant studijního oboru

V Praze dne

**Prohlášení:**

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

V Náchodě, 29. 7. 2019

.....

Bc. Jan Fišer

**Poděkování:**

Děkuji vedoucímu práce Ing. Lukáši Brodskému, Ph.D. za odborné vedení, věnovaný čas a četné připomínky a doporučení k vypracování této práce. Děkuji své rodině a přátelům za podporu během studia a při zpracování diplomové práce.

## Abstrakt

Práce zkoumá možnosti využití webových kamer jakožto zdroje prostorových dat o výskytu sněhu. Cílem práce je navržení vhodné metody detekce sněhové pokrývky ze snímků webových kamer. Na vzorku snímků 6 webových kamer ČHMÚ je provedena detekce sněhové pokrývky metodami pixelové klasifikace. Je zkoumán vliv velikosti trénovacího souboru na přesnost klasifikace. Celková přesnost dosažená metodou SVM je 97,46 %. Dále je cílem navrhnout systém pro určení podílu sněhem pokrytého území. Vytvořený algoritmus se skládá z několika dílčích kroků: třídění a registrace snímků, detekce sněhu, zavedení souřadnicového systému, výpočtu velikosti zkoumané plochy a podílu sněhem pokrytého území. Navržený model je možné použít pro automatizované zpracování snímků různých webových kamer. Ze získaných denních hodnot podílu sněhem pokrytého území jsou vytvořeny křivky tání sněhové pokrývky. Výsledky jsou validovány pomocí dat vybraných stanic ČHMÚ.

Navržený a parametrizovaný model potvrzuje možnost úspěšně využít webové kamery jako doplněk pozemního měření meteorologických stanic a pro validaci produktů dálkového průzkumu Země.

**Klíčová slova:** sněhová pokrývka, zpracování obrazu, dálkový průzkum Země, in-situ, webkamera

## **Abstract**

This thesis deals with the possibility of using webcams as a source of spatial data for snow occurrence. The aim of this study is to propose a suitable method of snow cover detection from web camera images. From a sample of 6 webcams of the Czech Hydrometeorological Institute (CHMI) the snow cover is detected by pixel classification methods. The effect of training file size on the accuracy of classification is examined and the overall accuracy achieved by the SVM method was shown to be 97.46%. This study also aims to propose a system for determining the proportion of snow-covered areas. The algorithm consists of several sub-steps: filtering and registration of images, detection of snow, introduction of a coordinate system, calculation of the size of the surveyed area and the proportion of snow-covered area. The designed model can be used for automatic processing of images for various webcams. The melting curves of the snow cover are generated from the obtained daily values of the snow covered area. The results are validated using data from selected CHMI stations.

The proposed and parameterized model confirms the possibility of successful use of webcams as a complement to ground measurement of meteorological stations and for the validation of remote sensing products.

**Keywords:** snow cover, image processing, remote sensing, in-situ, webcam

## Obsah

Seznam zkratk	10
Seznam tabulek	10
Seznam obrázků	11
Seznam příloh	11
1. Úvod	12
2. Teoretická část	14
2.1 Sníh	14
2.2 Metody měření sněhové pokrývky	15
2.3 Webové kamery jako zdroj informací o sněhové pokrývce	16
2.4 Metody detekce sněhu na RGB snímcích	20
2.4.1 Metoda prahování	20
2.4.2 Metoda SVM	21
3. Data	24
3.1 Snímky webových kamer	24
3.2 Data pozemních meteorologických stanic	26
4. Metodika	27
4.1 Tvorba klasifikačního modelu	28
4.2 Model detekce sněhem pokrytého území	31
4.2.1 Zavedení webové kamery do systému detekce sněhem pokrytého území	31
4.2.2 Třídění snímků	32
4.2.3 Registrace snímků	33
4.2.4 Výpočet plochy a podílu sněhové pokrývky	34
4.3 Validace výsledků	34
5. Aplikace navrženého řešení	36
5.1 Detekce sněhové pokrývky	36
5.1.1 Testovací soubor	36
5.1.2 Metoda prahování	36
5.1.3 Metoda SVM	38
5.2 Vytvoření modelu odstranění snímků se špatnou viditelností	45
5.3 Systém pro určení podílu sněhem pokrytého území	47
5.3.1 Určení rozsahu sněhem pokrytého území	47
5.3.2 Vývoj sněhem pokrytého území v čase	49



5.3.3 Validace výsledků.....	52
<b>6. Diskuse .....</b>	<b>55</b>
6.1 Detekce sněhové pokrývky .....	55
6.2 Systém určení sněhem pokrytého území .....	57
<b>7. Závěr .....</b>	<b>63</b>
<b>Seznam použité literatury.....</b>	<b>65</b>
<b>Zdroje dat.....</b>	<b>68</b>
<b>Přílohy.....</b>	<b>69</b>

## Seznam zkratek

ČHMÚ	Český hydrometeorologický ústav
DN	Digital number
DPZ	Dálkový průzkum Země
GPS	Global Positioning System
NDSI	Normalized Difference Snow Index
NIR	Near Infrared Range
NOAA	National Oceanic and Atmospheric Administration
RGB	Red Green Blue
RGBNDSI	Red Green Blue Normalized Difference Snow Index
SCA	Snow covered area
SVM	Support-vector machine
THR	Threshold

## Seznam tabulek

<b>Tabulka 1:</b> Měřené veličiny sněhové pokrývky .....	15
<b>Tabulka 2:</b> Charakteristika použitých webových kamer .....	25
<b>Tabulka 3:</b> Soubor testovacích pixelů .....	36
<b>Tabulka 4:</b> Velikost území pro určení podílu sněhové pokrývky .....	48
<b>Tabulka 5:</b> Rozsah výskytu sněhové pokrývky ve zkoumaných obdobích let 2017 a 2019 .....	52
<b>Tabulka 6:</b> Přesnost detekce mezních hodnot výskytu sněhové pokrývky .....	52

## Seznam obrázků

<b>Obrázek 1:</b> Průběh spektrální křivky sněhu .....	16
<b>Obrázek 2:</b> Prahová hodnota pro bimodální histogram .....	20
<b>Obrázek 3:</b> Lineární SVM.....	21
<b>Obrázek 4:</b> Webové kamery výrobce HDcam s.r.o. ....	24
<b>Obrázek 5:</b> Rozmístění použitých webových kamer .....	25
<b>Obrázek 6:</b> Postup praktické části diplomové práce .....	27
<b>Obrázek 7:</b> Histogram modrého pásma 20 snímků kamery Luční a Olomouc .....	29
<b>Obrázek 8:</b> Nízká preciznost, nízká přesnost.....	30
<b>Obrázek 9:</b> Vysoká preciznost, nízká přesnost.....	30
<b>Obrázek 10:</b> Ukázka snímků s naznačenou maskou .....	31
<b>Obrázek 11:</b> Ukázka propojení klíčových bodů.....	34
<b>Obrázek 12:</b> Histogram modrého pásma 60 trénovacích snímků kamer Luční, Olomouc, Nové Hradky .....	37
<b>Obrázek 13:</b> Přesnost detekce sněhu metodou prahování .....	38
<b>Obrázek 14:</b> Přesnost výsledného modelu prahování.....	38
<b>Obrázek 15:</b> Přesnost detekce sněhu metodou SVM při 60 trénovacích pixelech z jedné kamery .....	39
<b>Obrázek 16:</b> Přesnost detekce sněhu metodou SVM při 20 trénovacích snímcích z jedné kamery .....	40
<b>Obrázek 17:</b> Přesnost detekce sněhu metodou SVM při 12 trénovacích snímcích z jedné kamery .....	40
<b>Obrázek 18:</b> Přesnost detekce sněhu metodou SVM při 12 trénovacích snímcích ze 2 kamer .	41
<b>Obrázek 19:</b> Celková přesnost a rozptyl modelů SVM.....	43
<b>Obrázek 20:</b> Celková přesnost modelů SVM pro validační a testovací sadu .....	43
<b>Obrázek 21:</b> Celková přesnost modelů SVM na validačních kamerách.....	43
<b>Obrázek 22:</b> Přesnost výsledného modelu SVM.....	44
<b>Obrázek 23:</b> Snímek kamery Luční ze dne 14. 5. 2017 .....	44
<b>Obrázek 24:</b> Celková přesnost modelů prahování a SVM.....	45
<b>Obrázek 25:</b> Aplikace Cannyho hranového detektoru.....	46
<b>Obrázek 26:</b> Cannyho hranový detektor.....	46
<b>Obrázek 27:</b> Sněhem pokryté území 2017.....	50
<b>Obrázek 28:</b> Sněhem pokryté území 2019.....	51
<b>Obrázek 29:</b> Luční 2017 .....	54
<b>Obrázek 30:</b> Jizerka 2017 .....	54
<b>Obrázek 31:</b> Luční 2019 .....	54
<b>Obrázek 32:</b> Jizerka 2019 .....	54
<b>Obrázek 33:</b> Snímek kamery Luční ze dne 19. 2. 2019 .....	58
<b>Obrázek 34:</b> Snímek kamery Luční ze dne 10. 5. 2017 .....	61

## Seznam příloh

**Příloha 1:** Ukázka snímků použitých webkamer – referenční snímky pro sezonu 2019

**Příloha 2:** Sněhem pokryté území – webová kamera Jizerka, duben 2017

## 1. Úvod

Sníh je běžnou součástí života nejen obyvatel Česka. Jeho význam nespočívá pouze v rekreačním využití, ale může se snadno stát i zdrojem ohrožení, ať už se týká lavinového nebezpečí nebo jarních povodní. Nedostatek sněhových srážek je rovněž důležitým faktorem pro vznik sucha. Proto je důležitá dostupnost aktuálních a přesných údajů o výskytu sněhové pokrývky. Základním způsobem monitoringu sněhové pokrývky jsou pozemní měření meteorologických stanic. Takto naměřená data jsou přesná, nicméně pouze lokálního (bodového) charakteru. Mezilehlé hodnoty jsou dopočítávány pomocí metod prostorové interpolace. Zdrojem plošných dat o sněhové pokrývce jsou snímky dálkového průzkumu Země. Metody jejich zpracování se musí vyrovnat s vlivem oblačnosti a s nižším časovým rozlišením snímků.

Základní myšlenkou diplomové práce je využití volně dostupných snímků webových kamer jakožto doplňujícího zdroje prostorových dat o stavu sněhové pokrývky. Webové kamery představují zdroj dat s vysokým časovým a prostorovým rozlišením, a to při zachování nízkých finančních nákladů. Snímky webových kamer provozovaných za různými účely jsou volně dostupné v prostředí internetu. Cílem práce je navržení metody detekce sněhové pokrývky ze snímků webových kamer. Pro detekci sněhu budou využity vybrané metody pixelové klasifikace.

Dílní cíle diplomové práce byly stanoveny takto:

- 1) Navržení metody automatizované detekce sněhové pokrývky na RGB snímcích z volně dostupných webkamer pomocí jednoduchého algoritmu prahování a strojového učení.
- 2) Zhodnocení vlivu velikosti referenčních dat pro parametrizaci modelu na celkovou přesnost detekce sněhové pokrývky.
- 3) Porovnání přesnosti detekce sněhové pokrývky s odbornou literaturou.
- 4) Ověření přenositelnosti vytvořeného modelu mezi webkamerami.
- 5) Výpočet sněhových frakcí a validace získaných výsledků.

Navržený model zpracování snímků webkamer bude implementován v programovacím jazyce Python. Bude kladen důraz na možnost automatizovaného zpracování online dostupných snímků. Získaná data by mělo být možné využít jako doplněk staničních meteorologických měření. Pro práci je zásadní využití volně

dostupných webkamer, snímajících pouze ve viditelné části spektra RGB. Nejedná se tedy o použití digitální kamery jakožto součásti automatické meteorologické stanice.

Obsahem rešeršní části práce je představení sněhu a měřených veličin sněhové pokrývky, zjištění současných pozemních i dálkových přístupů ke sběru dat o stavu sněhové pokrývky a jejich zhodnocení, dosavadní výzkumy využívající webové kamery jakožto zdroje prostorových informací o sněhové pokrývce a představení metod detekce sněhu na snímcích RGB. Vlastní řešení diplomové práce obsahuje zejména algoritmus pro automatickou detekci sněhové pokrývky na snímcích webových kamer. Důraz je kladen na možnost přenášení navrženého modelu mezi kamerami. Výsledný model by měl být schopen vypořádat se s různými světelnými podmínkami, povětrnostními vlivy, odlišným prostorovým rozlišením kamer apod. Dosažené výsledky budou validovány pomocí hodnot měření meteorologických stanic ČHMÚ. Výsledky budou dále podrobeny důkladné diskusi a srovnání s příslušnou literaturou. Také bude diskutován jejich možný přínos pro zpracování snímků dálkového průzkumu Země.

## 2. Teoretická část

Kapitola obsahuje představení tématu práce v širším výzkumném kontextu včetně dostupných metod výzkumu sněhu s využitím webových kamer. Dále jsou představeny metody klasifikace obrazu, které budou využity pro detekci sněhu v praktické části práce. Jedná s o metodu prahování a o metodu podpůrných vektorů (dále také SVM), která v práci reprezentuje metody strojového učení.

### 2.1 Sníh

Sníh je definován jako specifická forma ledových krystalů vznikající za vhodných klimatických podmínek v atmosféře a procházející změnami na zemském povrchu (Hobbs 2010). Představuje předmět zájmu vícero vědních oborů (Fierz a kol. 2009). Vyjma vědy však mají jeho přítomnost a jevy s ním spojené rovněž významný dopad na běžný život obyvatelstva – např. doprava, povodně, rekreace, cestovní ruch. Ve své diplomové práci se budu zabývat detekcí sněhové pokrývky, která je důležitým klimatickým, hydrologickým a biologickým činitelem. Pod pojmem sněhová pokrývka rozumíme vrstvu sněhu nebo ledu, která přímo nebo nepřímo vznikla v důsledku pevných srážek (sníh, kroupy, sněhové krupky, sněhová zrna, zmrzlý déšť, námrazové krupky, náledí, zmrázky). Nepatří sem ledovka, která vzniká při dopadu kapalných srážek na zmrzlý povrch (Netopil 1984). Sněhová pokrývka, jakožto významná součást kryosféry, ovlivňuje energetickou bilanci země, je součástí hydrologického cyklu, a hraje tak důležitou roli v klimatickém systému Země (IPCC 2013). Hodnota vody obsažené ve sněhové pokrývce, je významným údajem pro management nakládání s vodními zdroji a modelování povodňových scénářů (Dong 2018).

Ustálená a revidovaná klasifikace veličin souvisejících s výskytem sněhu je obsažena v *International Classification for Seasonal Snow on the Ground* vytvořené mezinárodní pracovní skupinou pro klasifikaci sněhu pod hlavičkou Mezinárodní asociace věd o kryosféře (Fierz a kol. 2009). Výzkum sněhu a jeho jednotný rámec má však mnohem hlubší kořeny, a to v roce 1948 kdy Mezinárodní komise pro sníh a ledovce vyjádřila potřebu standardizovaného mezinárodního systému klasifikace sněhu. To vyústilo v publikaci *The International Classification for Snow – with special reference to snow on the ground* (Schaefer a kol. 1954). Klasifikace byla dále

upravována v roce 1990 (Colbeck a kol. 1990) a nejaktuálněji v roce 2009 (Fierz a kol. 2009) tak, aby odrážela změny ve vývoji znalostí, přístrojů a způsobů měření. Klasifikace veličin souvisejících se sněhem je navržena tak, aby odpovídala potřebám široké skupiny od vědců po lyžaře. Měřené charakteristiky sněhové pokrývky dle mezinárodní klasifikace jsou zachyceny v tabulce 1.

Veličina	jednotky	značka
Výška (měřena ve vertikálním směru)	cm	<i>H</i>
Tloušťka (měřena kolmo k povrchu)	cm	<i>D</i>
Výška sněhové pokrývky	cm	<i>HS</i>
Výška nového sněhu	cm	<i>HN</i>
Vodní hodnota sněhu	mm w.e. *, kg m <sup>-2</sup>	<i>SWE</i>
Vodní ekvivalent sněžení	mm w.e. *, kg m <sup>-2</sup>	<i>HNW</i>
Síla sněhu (tlaková, tahová, stříhová)	Pa	$\Sigma$
Průchodnost sněhové pokrývky	cm	<i>P</i>
Povrchové prvky	(cm)	<i>SF</i>
Sněhem pokryté území	1, %	<i>SCA</i>
Úhel sklonu	°	$\psi$
Orientace svahu	°	<i>AS</i>
Čas	s, min, h, d, týden, měsíc, rok	<i>t</i>

**Tabulka 1:** Měřené veličiny sněhové pokrývky

Zdroj: Fierz a kol. (2009), upraveno

## 2.2 Metody měření sněhové pokrývky

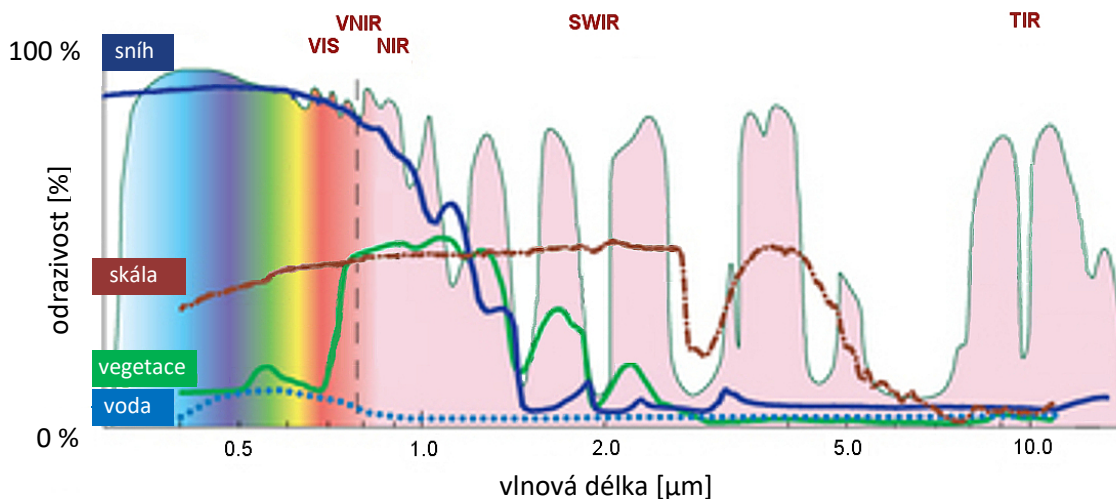
Sněhová pokrývky je monitorována typicky pomocí staničních meteorologických měření, která mají velmi dlouhou historii (Dong 2018) a poskytují vysoce přesnou bodovou informaci o vlastnostech sněhu. V případě potřeby plošné informace o sněhové pokrývce jsme pak odkázáni na využití metod prostorové interpolace (Foppa a kol. 2007). Přesnost takto získaných dat však klesá v případě horských oblastí s členitým reliéfem, vegetačními stupni nebo řídkou hustotou měřících stanic (Dong 2018). Počet pozemních měřících stanic je často nedostatečný (Fedorov 2016).

Alternativním zdrojem dat jsou technologie dálkového průzkumu Země (DPZ). Satelitní, letecké i bezpilotní snímkování umožňuje monitorování sněhové pokrývky v různém rozlišení dle rozsahu zkoumaného území a požadované přesnosti dat. Ke studiu sněhové pokrývky byla jako první využita družice NOAA a to v roce 1966

(Matson 1991). Prudký rozvoj metod DPZ v posledních desetiletích vedl k výraznému rozšíření jejich využití i na poli monitorování sněhu. Sněhová pokrývka je typicky detekována pomocí indexu NDSI (Normalized Difference Snow Index) – např. mapy sněhové pokrývky vycházející z dat MODIS o rozlišení 500 m (Hall 2002; Liang a kol. 2017). Princip použití NDSI využívá vysoké odrazivosti sněhu ve viditelné části spektra a naopak nízké odrazivosti v blízkém infračerveném pásmu (viz obrázek 1).

$$NDSI = \frac{Green - NIR}{Green + NIR}$$

Tím je umožněno odlišení sněhu od oblačnosti a dalších sněhem nepokrytých ploch. Pixel je klasifikován jako sníh, pokud je hodnota NDSI větší než 0,4. Družicové snímky nelze použít v případě oblačnosti nad zájmovým územím a během polární noci. Přesnost detekce sněhové pokrývky z dat MODIS může v případě jasné oblohy přesáhnout 90 % (Liang a kol. 2017). Problematika oblačnosti může být řešena například pomocí kompozitních snímků – tím však dochází ke snížení časového rozlišení. K zaplnění mezer v oblastech zakrytých oblaky, stejně jako pro zpřesnění a validaci dat, může být rovněž využito měření pozemních stanic (např. Huang a kol. 2018). Další metodou studia sněhové pokrývky je laserové skenování (Prokop 2008).



**Obrázek 1:** Průběh spektrální křivky sněhu  
Zdroj: Käab a kol. (2014), upraveno

### 2.3 Webové kamery jako zdroj informací o sněhové pokrývce

K získání informací o sněhové pokrývce mohou posloužit rovněž digitální kamery (např. Hinkler a kol. 2002; Salvatori a kol. 2011; Fedorov a kol. 2016). Nespornou výhodou pozemního snímání digitální kamerou je vysoké časové a



prostorové rozlišení ve srovnání se satelitním snímkováním i staničním měřením, a zároveň nízká cena. Může tak být vhodným rozšířením klasických metod měření. Pozemní snímání je také méně ovlivňováno oblačností (Hinkler a kol. 2002; Laffly a kol. 2012), je však třeba dbát na různé světelné podmínky a pohyby kamery v důsledku větru či změny teplot (Bradley, Clarke 2013).

Přístupy k využití snímků digitálních kamer a fotoaparátů pro detekci sněhové pokrývky se různí. Nejprve použili digitální kameru snímající ve viditelné části spektra pro monitoring sněhové pokrývky Hinkler a kol. (2002). Pro detekci sněhové pokrývky zde autoři vyvinuli normalizovaný index (RGBNDSI) pracující pouze s pásmy RGB. Vzniklý index je založen na stejných principech jako index NDSI, používaný například pro snímky družice Landsat, pro jehož výpočet je však zapotřebí hodnot odrazivosti v blízkém infračerveném pásmu (Hinkler a kol. 2002). Výstupem klasifikace je podíl území pokrytého sněhem v průběhu času. Získaná data jsou použita pro monitoring tání sezónní sněhové pokrývky na území o rozloze zhruba 17 km<sup>2</sup>.

Laffly a kol. (2012) používají kamery jako doplněk k satelitnímu snímání za zvýšení časového rozlišení. Na území okolo 10 km<sup>2</sup> bylo autory rozmístěno 10 digitálních kamer. Popisovaná metoda vyžaduje rozmístění oranžových vlajek o rozměrech 2 x 2 m v oblasti záběru kamery jakožto referenčních bodů pro slícování satelitních a pozemních snímků. Identifikace oblastí sněhové pokrývky byla provedena manuálně.

Lim a kol. (2006) a Kim a kol. (2007) se zabývají automatizovaným měřením výšky sněhové pokrývky prostřednictvím digitální kamery namířené na instalovanou sněhoměrnou lať.

Využitím snímků digitálních kamer pro monitoring sněhové pokrývky na dvou stanovištích v Italských alpách a v Apeninách se zabývají Salvatori a kol. (2011). V rámci tohoto výzkumu byl vyvinut software, který semi-automaticky detekuje rozšíření sněhové pokrývky. Vstupem programu je série snímků jedné scény pořízených v různých časech a uživatelem definované vrstvy homogenních ploch určených k detekci sněhové pokrývky. Následně jsou automaticky vyloučeny snímky nevhodné pro další zpracování (porucha kamery, hustý déšť, sněhové srážky, mlha). Vlastní sněhová pokrývky je poté klasifikována metodou prahování na základě průběhu křivky DN hodnot modrého pásma. Výstupem je podíl sněhem pokrytého území na zkoumané ploše v procentech, alternativně v metrech čtverečních. Postup byl testován

v omezených podmínkách na dvou autory instalovaných kamerách o známých parametrech. Umístění kamer v blízkosti meteorologických stanic umožnilo odhalení chyb a nedostatků v měření sněhu pomocí sněhoměrného polštáře.

Výše popisované metody vyžadují k provozu systému vlastní instalaci kamer, umístění specifického předmětu do záběru kamery, případně jinou formu kalibrace. Širší možnosti pro environmentální monitoring nabízí využití sítě webových kamer, jejichž snímky jsou volně dostupné v prostředí internetu. Tyto kamery snímají okolí za různým účelem jako je hustota dopravy, povětrnostní podmínky, studium života divokých zvířat apod. Jejich sekundárním využitím – například pro detekci sněhové pokrývky – nám odpadávají náklady na jejich instalaci a provoz. Jacobs a kol. (2009) člení využití těchto kamer pro výzkum do čtyř kroků – nalezení vhodných kamer, uložení snímků, zvolení vhodných snímků a vytvoření/aplikace algoritmu pro konkrétní účel. Při práci se snímky webových kamer je třeba rovněž dbát na ochranu soukromí (Bradley, Clarke 2013). Tato problematika se nemusí týkat pouze sociologických, ale i environmentálních výzkumů.

Detekci sněhové pokrývky z volně dostupných fotografií a webových kamer se ve své práci zabývají Fedorov a kol. (2016). Jako zdroje vstupních dat využívají volně dostupných fotografií sdílených prostřednictvím webového úložiště Flickr a snímků vybraných webových kamer. Fedorov a kol. (2016) pracují se snímky horské krajiny pořízenými za dobrých povětrnostních podmínek, což usnadňuje automatickou identifikaci horských vrcholů. Přiřazení snímaných objektů k terénu umožňuje autorům určit nadmořskou výšku sněžné čáry. Z důvodu špatné viditelnosti není možné použít 67 % snímků vytipovaných webkamer. Pro odfiltrování snímků se špatnou viditelností byl navržen algoritmus zkoumající, zda je na snímku viditelný horizont. Horizont je nalézán pomocí hranového detektoru. K detekci sněhové pokrývky je použito více postupů včetně přístupů Hinklera a kol. (2002) a Salvatori a kol. (2011) a dále klasifikace algoritmem učení s učitelem na pixelové úrovni. Byly použity a ohodnoceny klasifikátory Support Vector Machine, Random Forest a Logistic Regression. Nejlepších výsledků v tomto případě dosáhla metoda Random Forest – uvedené výsledky klasifikace se pohybují okolo 90 %. Srovnatelných výsledků bylo dosaženo pomocí algoritmu SVM. Fedorov a kol. (2016) poukazují na obtížnou přenositelnost řešení Hinklera a kol. (2002) i Salvatori a kol. (2011), což dokládají srovnáním procentuálních výsledků provedené klasifikace. Nicméně použitý dataset i účel použití (výška sněžné

čáry) se liší, a proto nelze přesnost klasifikace přímo porovnávat. Pro budoucí výzkum nabízí Fedorov a kol. (2016) odvození hodnoty objemu vody ve sněhu (Snow Water Equivalent) – významné pro řízení vodních zdrojů – z volně dostupných pozemních snímků. Autoři však nijak nespécifikují nástin možného řešení.

Výše představené práce se pouze velmi omezeně vyjadřují ke geometrickým a radiometrickým korekcím, jakožto základním předklasifikačním úpravám. Možný pohyb kamery a tím způsobenou změnu záběru neberou v potaz Hinkler a kol. (2002), ale naopak za účelem rektifikace snímků považují pozici kamery za absolutně fixní. Není zde přímo řešena ani radiometrická korekce dat, pouze navržený normalizovaný index RGBNDSI by měl kompenzovat různou úroveň osvětlení v důsledku přítomnosti mraků, stínů apod. Salvatori a kol. (2011) neřeší radiometrickou ani geometrickou korekci dat. To spolu s využitím vlastních kamer o známých parametrech činí jejich řešení obtížně reprodukovatelné. Jemný pohyb kamer považují za problém Fedorov a kol. (2016). Posun záběru je v jejich práci kompenzován vzhledem k referenčnímu snímku dle pozice detekovaného horizontu. Z prostorově zarovnaných snímků pořízených během jednoho dne je pak vytvořen denní kompozitní snímek. Tím dojde k potlačení vlivu stínů, odlesků a částečně i k odstranění objektů pohybujících se před kamerou. Už však nedochází k vyrovnání kompozitních snímků mezi sebou. Rovněž přístup Fedorova a kol. (2016) nepřesvědčil o snadné přenositelnosti použitého řešení, neboť testovací soubor je poměrně malý – 39 snímků ze třech webkamer a 20 snímků z Flickeru – avšak ze závěrů práce lze vyvodit, že použití algoritmů strojového učení může vést k dobrým výsledkům procesu rozpoznání sněhové pokrývky na snímcích různých webových kamer.

Rüfenacht a kol. (2014) se zabývají automatizovaným rozlišením snímků na dobré a bez obsahu informace o sněhové pokrývce. Snímky pořizované v hodinovém intervalu v horském prostředí často vznikají za různého osvětlení v důsledku proměnlivého počasí. Na základě průměrné hodnoty jasu jsou nejprve vyřazeny příliš tmavé snímky. Dále jsou vyřazeny snímky neostré (nejčastěji v důsledku mlhy) Pro vyřazení snímků neumožňujících detekci sněhu používají autoři vyhlazení obrazu pomocí Gaussova filtru. Na základě rozdílu mezi původním a vyhlazeným obrazem jsou určeny neostré snímky, které není možné použít pro klasifikaci.


Na půdě Přírodovědecké fakulty Univerzity Karlovy se detekcí sněhu z webové kamery zabýval Kowalski (2014). Ve své bakalářské práci sledoval s využitím webové

kamery rozlohu sněhového pole „Mapa republiky“ v Krkonoších. Soustředí se zejména na určení vysoké polohové přesnosti detekované sněhové pokrývky. Pro detekci sněhu používá metodu prahování a metodu upraveného NDSI dle Hinklera a kol. (2002).

## 2.4 Metody detekce sněhu na RGB snímcích

### 2.4.1 Metoda prahování

Metoda prahování – anglicky *thresholding* – je základní metodou zpracování obrazu. Používá se pro segmentaci nebo klasifikaci obrazu. Principem metody je nalezení prahové hodnoty jasu, pomocí které jsou pixely obrazu rozděleny do dvou tříd. Výstupem metody prahování je obvykle binární obraz. Prahová hodnota je určena nejčastěji na základě průběhu histogramu snímku (Luessi a kol. 2009). Přesného výsledku dosáhneme v případě bimodálního rozdělení histogramu, jako můžeme vidět na obrázku 2. Zkoumaný objekt je zde tvořen pixely s výrazně vyšším jasnem oproti



**Obrázek 2:** Prahová hodnota pro bimodální histogram  
Zdroj: Rogowska (2009), upraveno

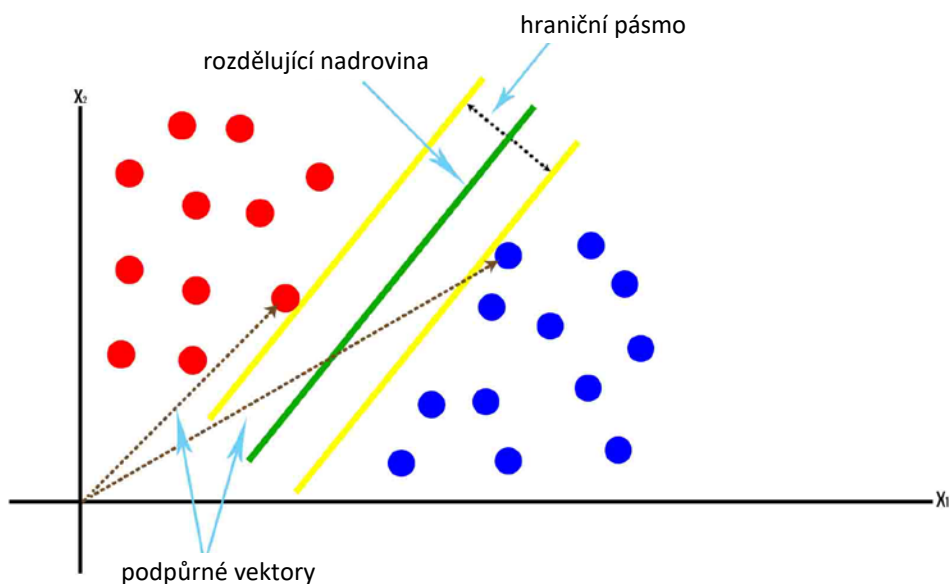
tmavému pozadí. Metoda je účinná v případě vysokého kontrastu obrazových prvků – například rozpoznávání černého textu na bílém papíře (Sezgin a Sankur 2004). V metodách dálkového průzkumu Země lze metodu prahování využít pro detekci vodních ploch, které mají v pásmu NIR výrazně nižší odrazivost než ostatní povrchy. Jednoduché metody globálního prahu jsou náchylné k chybám v případě šumu nebo nerovnoměrného osvětlení (Davies 2018). Při zpracování většího souboru snímků je možné prahovou hodnotu pevně stanovit, anebo ji upravovat na základě průběhu hodnot pixelů daného snímku (metoda dynamického prahování). Prahová hodnota

může být vypočtena na základě kombinace více pásem nebo spočítána pro každé pásmo zvlášť – např. RGB (Luessi a kol. 2009).

Metodu dynamického prahování s využitím hodnot modrého pásma pro detekci sněhu použili Salvatori a kol. (2011). Nejprve je snímek shlazen průměrovým filtrem přiřazujícím pixelům průměrnou DN hodnotu modré složky 5 nejbližších pixelů. Tím dojde k potlačení vlivu šumu. Na základě analýzy rozložení DN hodnot testovacích dat byla určena prahová hodnota pro výskyt sněhové pokrývky jako první lokální minimum nad  $x \geq 127$ . Pokud zde žádné lokální minimum není, je za prahovou hodnotu zvoleno  $DN = 127$ . Tato metoda spoléhá na bimodální rozdělení histogramu snímků se sněhem a je jí možné úspěšně využít v případě sady snímků jediné webové kamery. Fedorov a kol. (2016) upozorňují na problematické použití v případě proměnlivých nebo nerovnoměrných světelných podmínek. K použití modré složky snímků Salvatori a kol. (2011) uvádí, že při použití ostatních pásem bylo dosaženo výsledků s velmi malou odchylkou. Kowalski (2015), který také využil pro metodu prahování hodnoty modrého pásma k tomu dodává, že modrá barva má z pásem RGB nejvýraznější poměr odrazivosti sněhu a dalších přírodních povrchů jako jsou skály nebo vegetace.

### 2.4.2 Metoda SVM

Support-vector machine, také zvaná jako metoda podpůrných vektorů, je řízená metoda strojového učení publikovaná v upravené formě v roce 1995 (Cortes, Vapnik 1995). Snahou metody je nalezení optimální nadroviny oddělující od sebe dvě třídy trénovacích dat. K tomu využívá transformaci dat pomocí zvoleného jádra



**Obrázek 3:** Lineární SVM

Zdroj: Codershood.info, upraveno

do vícerozměrného prostoru, což následně umožňuje lineární separaci tříd. Optimální nadrovina je hledána s ohledem na co největší vzdálenost od trénovacích dat. Nadrovina je popsána pomocí bodů ležících na okrajích hraničního pásma (margin) – podpůrnými vektory (Cortes, Vapnik 1995). Znázornění modelu SVM je zachyceno na obrázku 3. Mezi základní parametry klasifikátoru SVM patří typ jádrové funkce použité pro transformaci, hodnota C upravující váhu chyb dosažených při trénování modelu a parametr gama určující váhu jednotlivých trénovacích prvků (Hsu, Chang, Lin 2016; Keerthi, Lin 2003). V případě nevhodně zvolené jádrové funkce nebo dalších vstupních parametrů může dojít k přetrénování modelu. To znamená situaci, kdy jsou trénovací data klasifikována s vysokou přesností, ale při aplikaci modelu na jiných datech dochází k chybám. Možným řešením je validace modelu na části referenčních dat, která nebyla použita pro trénování.

Nevýhodou metody SVM je časová a paměťová náročnost jejího trénování a náročnost volby vstupních parametrů (Nalepa, Kawulok 2018). Mather a Koch (2011) popisují problematiku trénovacích dat jako komplexní a bez jednoduchého řešení. Obecné heuristické metody doporučují použití alespoň 30 trénovacích pixelů na každou klasifikovanou třídu a pásmo (Mather, Koch 2011). Oproti tomu Foody a kol. (2006) dokazují, že v případě klasifikace jediné třídy metodou SVM, je možné velikost trénovací sady dále zmenšit. Není třeba velkého množství pixelů, protože SVM pracuje pouze s pixely s hodnotami na okraji klasifikované třídy. Foody a kol. (2006) kladou důraz na nutnost zastoupení vzorků všech tříd objektů, které se mohou vyskytnout v zájmovém území, přestože nejsou předmětem našeho zájmu. Způsoby trénování SVM se zabývají Nalepa a Kawulok (2018). Ve své práci člení přístupy k výběru trénovací množiny do několika skupin – například aktivní učení nebo metody náhodného výběru. Metody náhodného výběru dosahují optimálního modelu klasifikátoru pomocí opakování náhodného výběru vstupních prvků. Výhodou těchto metod je jejich jednoduchost a snadná implementace (Nalepa, Kawulok 2018). Trénováním modelů SVM s využitím náhodného výběru trénovacích dat se zabývají například Balcázar a kol. (2001) nebo Atienza a kol. (2006).

Metody SVM nachází široké uplatnění v úlohách dálkového průzkumu Země. Jsou využívány pro řešení problémů fyzické i sociální geografie a to při využití vstupních dat o různém prostorovém a spektrálním rozlišení (Mountrakis a kol. 2011). Zkoumání výskytu sněhové pokrývky na snímcích webových kamer představuje problematiku

binární klasifikace, pro jejíž řešení byl klasifikátor SVM původně určen. Algoritmus SVM pro detekci sněhu ze snímků RGB úspěšně použili Fedorov a kol. (2016). Autoři však vůbec neuvádí nastavení parametrů klasifikátorů ani vliv těchto nastavení na výsledky klasifikace.

### 3. Data

#### 3.1 Snímky webových kamer

Pro účely práce byly využity snímky webových kamer provozovaných ČHMÚ. ČHMÚ spolupracuje na provozu webkamer s firmou HDcam s.r.o., která se zabývá vývojem webových kamer s vysokým rozlišením. Technologie webkamer je založena na kompaktních fotoaparátech firmy Canon (viz obrázek 4). Webové kamery pořizují



**Obrázek 4:** Webové kamery výrobce HDcam s.r.o.  
Zdroj: Ronge, HDcam

lokálně ukládané snímky v pravidelném intervalu jedné minuty. Snímky jsou ukládány ve formátu jpeg s barevnou hloubkou 8bit. Zpravidla v 5 minutovém intervalu jsou pak snímky odesílány na server ČHMÚ (Ronge, HDcam). Aktuální snímky kamer s přibližně třídní historií jsou veřejně dostupné na webových stránkách ČHMÚ ([portal.chmi.cz](http://portal.chmi.cz)). Pro zpracování v diplomové práci bylo zvoleno 6 webových kamer. Základním předpokladem pro možné využití webkamery byla přítomnost plochy vhodné pro ukládání sněžové pokrývky v oblasti snímání. Dalším parametrem pro volbu webových kamer byla nadmořská výška - snahou bylo pokrýt co nejširší spektrum oblastí od nížin po hory. Přehled použitých webkamer se nachází v tabulce 2. Jejich rozmístění na mapě Česka pak na obrázku 5.



Název kamery	Poloha	Nadmořská výška	Směr záběru (orientace)	Typ kamery	Počet snímků 2017 / 2019
Luční bouda	50,7347 SZŠ 15,6974 VZD	1413 m n. m.	V	HDCam 9.0Mpx	106 / 3080
Olomouc	49,5759 SZŠ 17,2834 VZD	210 m n. m.	J	HDCam 9.0Mpx	106 / 3080
Praha-Libuš	50,0075 SZŠ 14,4453 VZD	340 m n. m.	VSV	HDCam 9.0Mpx	106 / 3081
Jizerka	50,8188 SZŠ 15,3464 VZD	858 m n. m.	V	HDCam 9.0Mpx	106 / 3081
Nové Hrady	48,7908 SZŠ 14,7826 VZD	546 m n. m.	JZ	HDcam v2 - 9.0 Mpix	106 / 3080
Turnov	50,5897 SZŠ 15,1545 VZD	252 m n. m.	S	Canon PowerShot SX110 IS	106 / 3080

**Tabulka 2:** Charakteristika použitých webových kamer  
Zdroj: Autor; ČHMÚ



**Obrázek 5:** Rozmístění použitých webových kamer  
Zdroj: Autor; ArcČR 500 v3.2

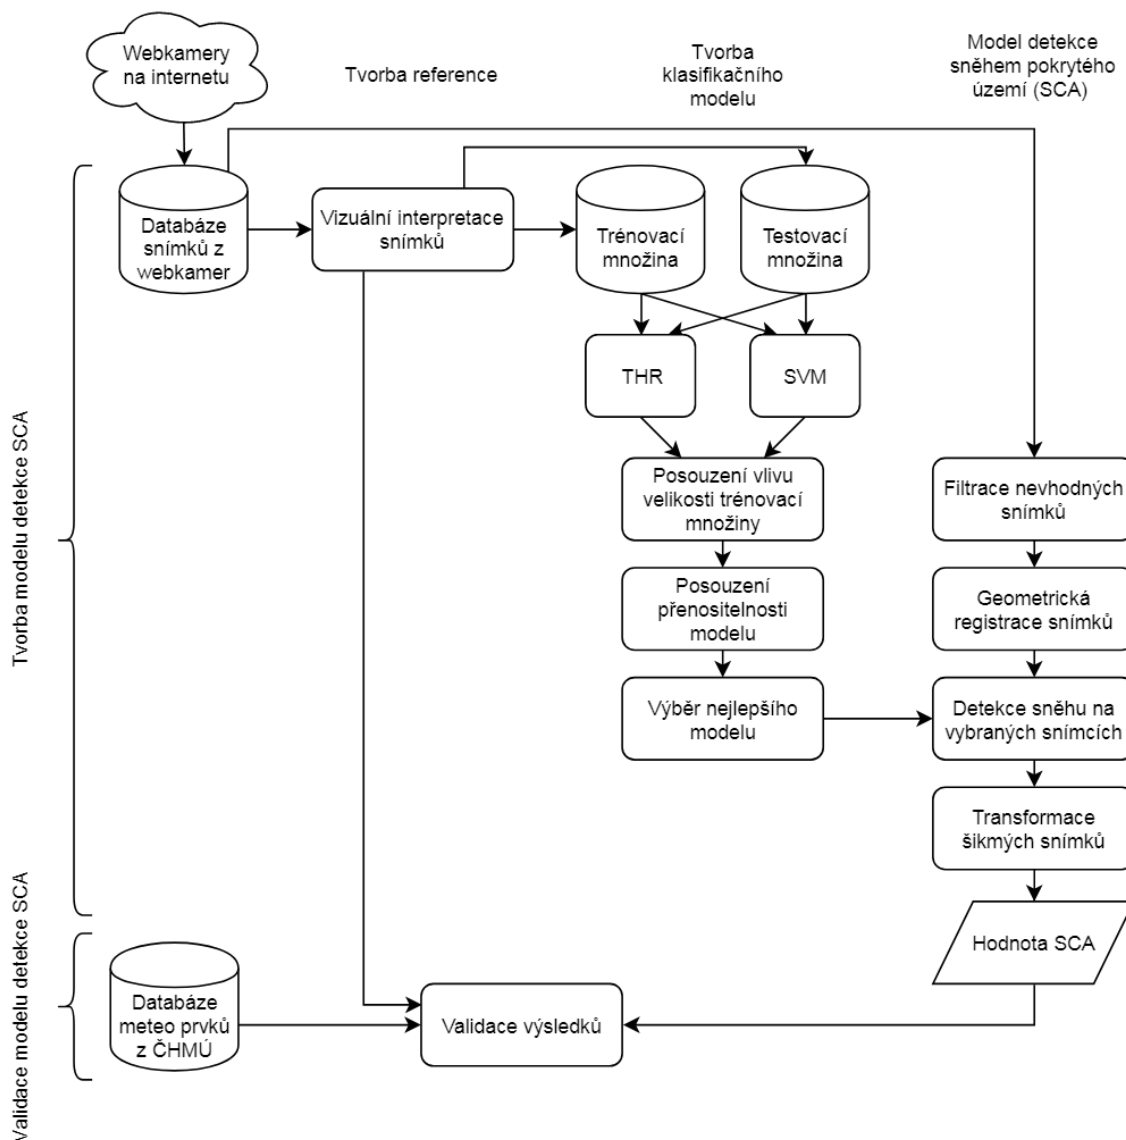
Jelikož snímky nejsou k dispozici zpětně, bylo nezbytné zajistit jejich pravidelné stahování. Pro tento účel byl vytvořen skript v jazyce PHP. Ke zpracování byly zvoleny dvě sezony pokrývající období výskytu a tání sněhové pokrývky. Jedná se o únor až květen 2017 a leden až květen 2019. V sezoně 2017 byly snímky ukládány s jednodenní periodicitou, v sezoně 2019 pak v hodinovém intervalu. Celkem bylo získáno 636 snímků z roku 2017 a 18 482 snímků z roku 2019. Všechny snímky mají jednotné rozlišení 1600 x 1200 pixelů. Prostorové rozlišení šikmého záběru však kolísá v závislosti na vzdálenosti kamery ke snímané ploše. Příklady snímků použitých webových kamer můžete vidět v příloze 1. Webové kamery ČHMÚ byly zvoleny rovněž s ohledem na blízké umístění meteorologických stanic.

### 3.2 Data pozemních meteorologických stanic

Pro účely validace výstupů diplomové práce budou použita staniční data ČHMÚ. Snahou bylo získat data ze stanic v blízkosti webových kamer, nicméně jako problém vyvstala vysoká cena dat, a to i pro studijní využití. Proto byl snížen objem požadovaných dat na dvě stanice. Protože nejvyšší počet snímků s nesouvislou sněhovou pokrývkou byl zaznamenán na horských kamerách Luční bouda a Jizerka, byly zvoleny stanice Kořenov, Jizerka (P2KORE01) a Luční bouda (H1LUCB01). Dalším problémem je časové rozlišení staničních dat. Stanice Jizerka je provozována v bezobslužném režimu a sněhová pokrývka je zde sledována pouze v týdenním intervalu, což je pro potřeby této práce nedostatečné. Proto byla zvolena stanice Desná, Souš (P2DESN01), která se nachází ve vzdálenosti zhruba 3,5 km vzdušnou čarou, v nadmořské výšce 772 m. Jelikož je stanice položena o téměř sto výškových metrů níže než webkamera, byla pro sezonu 2019 přibrána ještě data z automatického sněhoměru Josefův Důl, Rozmezí (P4JDRO01). Tato stanice se nachází v nadmořské výšce 993 m, 8 km západně od kamery Jizerka. Výška sněhu pro stanici Jizerka byla určena pomocí lineární interpolace hodnot stanic Desná, Souš a Josefův důl, Rozmezí dle nadmořské výšky.

## 4. Metodika

Na základě rešeršní části bude ambicí diplomové práce získat ze snímků webových kamer informaci o sněhem pokrytém území – Snow Covered Area (dále také SCA). Sněhem pokryté území je definováno jako plošný podíl sněhem pokrytého povrchu na zkoumané ploše [%] a je mezinárodně ustálenou veličinou (Fierz a kol. 2009) – viz tabulka 1 na straně 15. Jednotlivé kroky praktické části diplomové práce jsou znázorněny na diagramu (obrázek 6). Postup zpracování se skládá ze dvou hlavních částí – tvorby klasifikačního modelu a tvorby modelu detekce SCA. K vytvoření klasifikačního modelu budou využity metody pixelové klasifikace – prahování (THR) a SVM. Nejvhodnější model bude následně součástí algoritmu automatizovaného určení podílu SCA (na diagramu vpravo). Navrženým modelem budou zpracovány všechny snímky uložené v databázi vytvořené pro účely této práce. Výsledné hodnoty



**Obrázek 6:** Postup praktické části diplomové práce  
Zdroj: Autor


SCA vztažené k lokalitě webkamery a ke dni pořízení snímků budou následně validovány. Navržený způsob řešení bude implementován v programovacím jazyce Python s využitím knihoven scikit-learn (Pedregosa a kol. 2011) a OpenCV (Bradski 2000).

#### 4.1 Tvorba klasifikačního modelu

Základním procesem pro získání informace o stavu sněhové pokrývky ze snímků webových kamer je klasifikace obrazu. Její navržení a ověření představuje klíčovou součást diplomové práce. Při práci s družicovými snímky se obvykle využívá etablovaného indexu NDSI (představený výše v kapitole 2.2). V případě snímků běžných webových kamer si však musíme vystačit pouze s viditelnou částí spektra (pásma RGB). Jelikož výstupem zpracování snímku má být informace o podílu sněhem pokrytého území, bylo navrženo použití masky vymezující část snímku určenou pro detekci sněhové pokrývky. Typicky se jedná o rovinaté území vhodné pro ukládání sněhové pokrývky. Zkoumaná část snímku bude vymezena maskou ve tvaru obdélníku, jejíž výhodou je snadné vytvoření pomocí souřadnic 4 bodů. Masku bude třeba vymezit pro každou kameru zvlášť. Klasifikace tedy nebude probíhat na celém snímku, ale pouze v jeho části. To má za cíl odfiltrování objektů zvyšujících složitost klasifikace (obloha, zástavba, vodní plochy) a rovněž snížení výpočetní náročnosti. Nebude potřeba řešit otázku rozlišení sněhu a oblaků, jejichž spektrální chování se v kanálech RGB nemusí příliš odlišovat. Použití masky rovněž zjednodušuje problematiku geometrie šikmého snímku. Pokud by se v klasifikované části obrazu nacházel z boku snímaný objekt jako je například strom, dům nebo dopravní značka, došlo by ke snížení prostorové přesnosti detekce. Dále budou pomocí masky eliminovány antropogenně ovlivněné plochy nevhodné pro studium sněhové pokrývky – například silnice.


Při volbě vhodného klasifikačního modelu bude kladen důraz zejména na možnost přenášení vytvořeného modelu mezi různými kamerami. Bude použita metoda prahování s pevným prahem. Pro metodu prahování budou stejně jako v případě Salvatori a kol. (2011) a Kowalskiho (2014) použity hodnoty modrého pásma. Z trénovacích pixelů sněhu a ostatních ploch bude vytvořen histogram s předpokládaným bimodálním rozdělením. Jak je vidět na histogramu níže, rozložení hodnot pixelů snímků dvou zkoumaných kamer neumožňuje úplnou lineární separaci pixelů sněhu a povrchu bez sněhové pokrývky. Obě třídy pixelů v histogramu budou

proloženy křivkou Gaussovy funkce. V místě průniku funkcí bude zvolena prahová hodnota (Huang, Chau 2008).



**Obrázek 7:** Histogram modrého pásma 20 snímků kamery Luční a Olomouc  
Zdroj: Autor, ČHMÚ

Další způsob detekce představují metody strojového učení. Bude použita metoda SVM, jejíž princip byl představen v kapitole 2.4. Její výhodou je využití všech tří pásem RGB. V důsledku práce Fedorova a kol. (2016) bude očekáváno dosažení vyšší přesnosti oproti metodě prahování. Nejprve bude zjišťován vliv velikosti a variability trénovacího souboru (počet trénovacích kamer, pixelů) na výslednou přesnost klasifikace. Hodnota vhodné velikosti trénovací množiny bude použita jako parametr trénování klasifikátoru pomocí metody náhodného výběru trénovacích pixelů. Opakováním náhodného výběru bude vytvořeno sto klasifikačních modelů. Nejlepší model bude zvolen na základě hodnot přesnosti (accuracy) a preciznosti (precision) dosažených pro jednotlivé testovací kamery. Přesnost měření je definována jako „těsnost shody mezi naměřenou hodnotou veličiny a pravou hodnotou měřené veličiny“ (JCGM 2008, s. 55). Oproti tomu preciznost je definována jako „těsnost shody mezi indikacemi nebo naměřenými hodnotami veličiny získanými opakovanými měřeními na stejném objektu nebo na podobných objektech za specifikovaných podmínek“ (JCGM 2008, s. 56). Preciznost měření se obvykle vyjadřuje mírami nepřeciznosti jako jsou například směrodatná odchylka nebo rozptyl (JCGM 2008). Preciznost měření nemá žádný vztah ke správné hodnotě (viz obrázek 8 a 9). Hodnota preciznosti stanovuje opakovatelnost a reprodukovatelnost provedeného měření (JCGM 2008). Reprodukovatelnost udává preciznost měření za změněných podmínek – různými měřidly, personálem, na jiném místě či v různém čase (JCGM 2008).



**Obrázek 8:** Nízká  
preciznost, nízká přesnost  
Zdroj: Wikimedia Commons



**Obrázek 9:** Vysoká  
preciznost, nízká přesnost  
Zdroj: Wikimedia Commons

Představené definice přesnosti a preciznosti měření budou v této práci aplikovány na přesnost a preciznost klasifikace. Změněné podmínky v případě této práce znamenají použití klasifikačního modelu na různých webových kamerách. Webové kamery se od sebe liší například vzdáleností snímaného území, typem snímaného krajinného pokryvu nebo orientací kamery. Pro každou testovací kameru bude určena celková přesnost dosažená pomocí použitého modelu. Na základě rozptylu (míra nepřeciznosti) přesností mezi jednotlivými testovacími kamerami bude vyjádřena preciznost modelu. Pomocí těchto hodnot bude hodnocena přenositelnost modelu. Tento postup by měl eliminovat možné přetrénování modelu. Cílem je nalézt model, který při aplikaci dosáhne vysoké hodnoty přesnosti i preciznosti (malého rozptylu přesnosti mezi kamerami). Metoda klasifikace SVM je obsažena v knihovně scikit-learn. Implementace vychází z široce používané knihovny LIBSVM napsané v jazyce C++ (Chang, Lin 2013).

Pro podrobnější určení přesnosti modelů prahování a SVM budou pro jednotlivé kamery spočteny hodnoty zpracovatelské a uživatelské přesnosti. Zpracovatelská přesnost vyjadřuje pravděpodobnost, s jakou jsou pixely sněhu správně klasifikovány jako sníh. Uživatelská přesnost udává pravděpodobnost, s jakou jsou pixely klasifikované jako sníh ve skutečnosti opravdu sněhem (na základě referenčních dat).

## 4.2 Model detekce sněhem pokrytého území

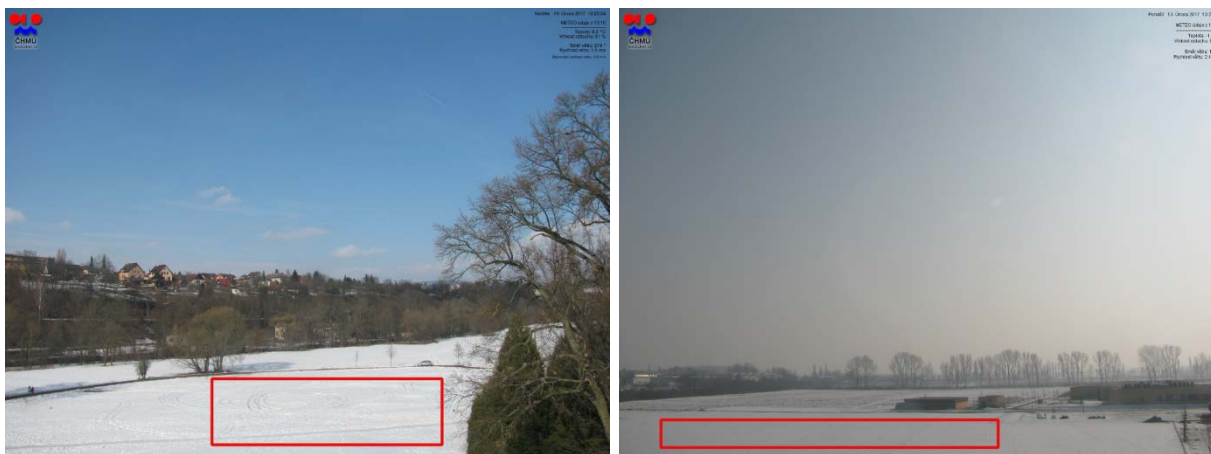
Následuje popis systému navrženého pro automatizované určení podílu sněhem pokrytého území v záběru webové kamery. Postup se skládá z několika kroků:

1. Vyřazení snímků nevhodných pro klasifikaci
2. Registrace snímků
3. Detekce sněhu
4. Transformace šikmých snímků a výpočet SCA

Schéma algoritmu je rovněž znázorněno v pravé části diagramu na obrázku 6. Pro detekci sněhu bude využit model vytvořený na základě předchozí kapitoly, který bude výstupem části diagramu označené jako „Tvorba klasifikačního modelu“. V následujících podkapitolách jsou popsány jednorázové úkony nezbytné pro zařazení webové kamery do systému, registrace snímků vyrovnávající náhodný pohyb kamery a výpočet plochy sněhem pokrytého území na šikmém snímku webové kamery.

### 4.2.1 Zavedení webové kamery do systému detekce sněhem pokrytého území

Pro zařazení webové kamery do systému bude třeba nejprve provést několik jednorázových úkonů. Pro každou kameru je nutné zvolit referenční snímek – bez sněhové pokrývky a ideálně bez zvýšené oblačnosti. Referenční snímek bude použit pro registraci a georeferencování snímků. Na referenčním snímku bude pomocí masky vymezeno území pro určení podílu sněhové pokrývky – relativně rovná plocha bez výskytu objektů narušujících proces získání přesné a reprezentativní informace. Ukázka vymezení zkoumaného území je znázorněna na obrázku 10. Dále bude třeba zvolit



**Obrázek 10:** Ukázka snímků s naznačenou maskou; vlevo kamera Turnov, vpravo kamera Olomouc  
Zdroj: ČHMÚ, upraveno

minimálně 4 vlíčovací body jednoznačně rozpoznatelné na referenčním snímku a ortofotu. Vlíčovací body se musí nacházet v rovině zkoumané plochy. Odečtením ze snímku budou vlíčovacím bodům přiřazeny obrazové souřadnice. Ze snímků ortofota pak budou odečteny souřadnice v rovině zvoleného souřadnicového systému. Alternativně by bylo možné určit souřadnice v terénu pomocí přístroje GPS, což by přineslo řádově větší polohovou přesnost. Navržený postup umožňuje obejít použití parametrů orientace kamery, které jsou neznámé. Ze vztahu obrazových a geografických souřadnic bude poté odvozena projektivní transformační matice. Projektivní transformace umožňuje převést rovinu zkoumaného území do zvoleného souřadnicového systému. Tvary reliéfu jsou zanedbány. Ostatní části snímku mimo zájmové území jsou silně zkresleny.

#### 4.2.2 Třídění snímků

Prvním krokem předklasifikační fáze bude odstranění snímků nevhodných pro klasifikaci. Stejně jako při použití metod dálkového průzkumu Země, není ani v případě webových kamer možné využít všechny dostupné snímky. Podmínka bezoblačnosti však není tak striktní, neboť webové kamery snímající v blízkosti povrchu umožňují zpracování i snímků pořízených za vysoké oblačnosti.

Důležitým faktorem ovlivňujícím výsledek klasifikace je výška slunce nad obzorem, proto budou vyřazeny snímky pořízené před desátou hodinou ranní a po třetí hodině odpolední. Následovat bude vyloučení poškozených snímků. Poslední překážku pro korektní klasifikaci představují snímky pořízené za zhoršených viditelnostních podmínek – mlha, srážky přichycené na objektivu kamery. Tyto snímky budou detekovány s využitím Cannyho hranového detektoru (Canny 1986). Cannyho detektor je metoda zpracování obrazu skládající se z několika kroků:

- 1) Odstranění šumu Gaussovým filtrem
- 2) Určení velikosti a směru gradientu
  - Tedy standardní detekce hran. Může být použit Sobelův operátor, který vrací velikost gradientu v horizontálním a vertikálním směru. Z toho je poté vypočtena velikost a směr hrany.
- 3) Ztenčení hran
  - Dojde k odstranění pixelů hran mimo lokální maxima.




#### 4) Dvojité prahování

- Z obrazu je nyní třeba vypustit nevýznamné hrany.
- K tomu jsou použity 2 prahové hodnoty velikosti gradientu. Pokud se hodnota gradientu daného pixelu nachází nad větším prahem, je pixel uznán jako hranový. Pokud hodnota gradientu nachází mezi oběma prahy, je pixel označen jako hranový pouze v případě, že sousedí s pixelem, který byl jako hrana označen již dříve.

Výstupem algoritmu bude binární obraz znázorňující průběh hran na snímku. Snímky s malým počtem detekovaných pixelů hran značí špatnou viditelnost a budou vyloučeny z dalšího zpracování. Jako snímky se špatnou viditelností jsou označeny snímky, na kterých by nebylo možné provést detekci sněhové pokrývky ani pomocí vizuální interpretace. Cannyho detektor je implementován v knihovně OpenCV (Bradski 2000).

### 4.2.3 Registrace snímků

Webové kamery jsou vystaveny povětrnostním vlivům, které způsobují drobné odchylky směru snímání. Aby nedocházelo k posunu zkoumaného území v záběru kamery, bude přikročeno k prostorové registraci snímků. Registrace bude provedena pomocí metody Speeded-Up Robust Features (SURF) (Bay a kol. 2008). Průběh algoritmu lze rozdělit na dvě části. Nejprve jsou na snímku detekovány klíčové body (detekce). V druhém kroku (deskripce) jsou klíčové body popsány na základě svého okolí. Detekce klíčových bodů je založena na využití integrálních obrazů a výpočtu determinantu Hessovy matice (Bay a kol. 2008). Detekované a popsané body v referenčním a registrovaném snímku jsou následně propojeny. K propojení bodů je možné použít metody tzv. hrubé síly (Enqvist a kol. 2011; Seçkin a kol. 2018). Propojené dvojice bodů jsou znázorněny na obrázku 11. V případě dostatečného množství propojených bodů je přikročeno k výpočtu matice afinní transformace. Popsané metody jsou implementovány v knihovně OpenCV (Bradski 2000).



**Obrázek 11:** Ukázka propojení klíčových bodů  
Zdroj: Autor, ČHMÚ

#### 4.2.4 Výpočet plochy a podílu sněhové pokrývky

Registrované snímky budou následně podrobeny klasifikaci pomocí vytvořeného modelu. Z binárních snímků klasifikovaných do tříd 1 – sníh a 0 – nesníh bude třeba určit plochu, respektive podíl sněhem pokrytého území. Z důvodu šikmého snímání webových kamer není možné pomocí jednoduchého měřítka přepočítat pixely sněhu na plochu. Pixel zachycující plochu blíže ke kameře znázorňuje menší území a naopak. Jelikož po provedení registrace bude zpracováváný snímek zarovnaný se snímkem referenčním, je možné pomocí referenční transformační matice převést zkoumanou část snímku do roviny zvoleného souřadnicového systému. Poté budou mít všechny pixely shodnou velikost, a proto bude snadné určit podíl sněhem pokrytého území. Pokud bychom požadovali plošnou informaci v  $m^2$ , aplikujeme stejnou transformaci na obrazové souřadnice vrcholů zkoumaného území. Z pravoúhlých souřadnic vrcholů lze snadno dopočítat plochu polygonu představujícího zájmové území.

#### 4.3 Validace výsledků

Získaná data bude nutné validovat. Pro kamery snímající větší území by bylo možné srovnání se satelitními snímky, které však mají omezené prostorové i časové rozlišení. Nejpřesnějším způsobem validace by bylo bezpochyby terénní měření

rozsahu sněhových frakcí s přístrojem GPS, avšak takový počín není v časových možnostech této práce. Data pro validaci budou částečně vytvořena vizuální interpretací vstupních snímků. Jelikož výstupní hodnotou systému je denní hodnota SCA, budou snímky nejprve sloučeny do složek podle dne vzniku. Zkoumané dny budou poté rozděleny do kategorií dle rozsahu sněhové pokrývky na všech snímcích téhož dne (0 %, 1-99 %, 100 %). Třídy 0 a 100 % budou použity pro validaci. Třída 1-99 % značí výskyt nesouvislé sněhové pokrývky. Pro tyto dny nelze pomocí vizuální interpretace snímků přesně určit rozsah sněhem pokrytého území. Proto byla pro doplnění validace zvolena staniční data ČHMÚ zachycující výšku sněhové pokrývky. Metodika měření výšky sněhu ČHMÚ uvádí, že pokud je půda na pozemku stanice a v nejbližším okolí alespoň z poloviny pokryta vrstvou sněhu o výšce nejméně 1 cm, považuje se sněhová pokrývka za souvislou (Tolasz a kol. 2007), a tedy je prováděno měření. Z toho vyplývá, že v čase, kdy je výška sněhu na stanici již nula, hodnota SCA by měla být stále okolo 50 %. Srovnání výšky a podílu sněhové pokrývky provedli také Hinkler a kol. (2002) a Salvatori a kol. (2011).

## 5. Aplikace navrženého řešení

### 5.1 Detekce sněhové pokrývky

Pro trénování, validaci a testování modelů detekce sněhové pokrývky byly zvoleny snímky ze sezony 2017. Pro klasifikaci snímků byly použity metody prahování a SVM. První trénování klasifikátorů bylo provedeno na snímcích webové kamery umístěné na Luční boudě v Krkonoších. Soubor snímků této webkamery zachycuje největší variabilitu počasí a chování sněhové pokrývky. Rovněž je zde k dispozici největší zkoumatelná plocha a nejvíce snímků s výskytem sněhu.

#### 5.1.1 Testovací soubor

Výběr testovacích snímků byl částečně stratifikován tak, aby byly zastoupeny snímky se sněhem, částečnou sněhovou pokrývkou i beze sněhu. Velikost testovacích souborů byla v případě kamer Praha-Libuš a Nové Hrady omezena nízkým počtem snímků se souvislou sněhovou pokrývkou. Pro kameru Praha-Libuš nebyl k dispozici takový snímek ani jeden. Na každém testovacím snímku bylo poté náhodně zvoleno 30 pixelů, kterým byla přiřazena referenční hodnota. Velikosti testovacích souborů pro jednotlivé webkamery můžete vidět v tabulce 3. Celkem bylo pro testování použito 2640 pixelů. Snímky použité pro vytvoření testovacího souboru byly vyjmuty z následného trénování modelů.


Název kamery	Počet snímků	Počet pixelů		
		sníh	nesníh	celkem
Luční bouda	15	301	149	450
Olomouc	19	253	317	570
Praha-Libuš	10	11	289	300
Jizerka	17	246	264	510
Nové Hrady	11	77	253	330
Turnov	16	279	201	480

**Tabulka 3:** Soubor testovacích pixelů  
Zdroj: Autor

#### 5.1.2 Metoda prahování

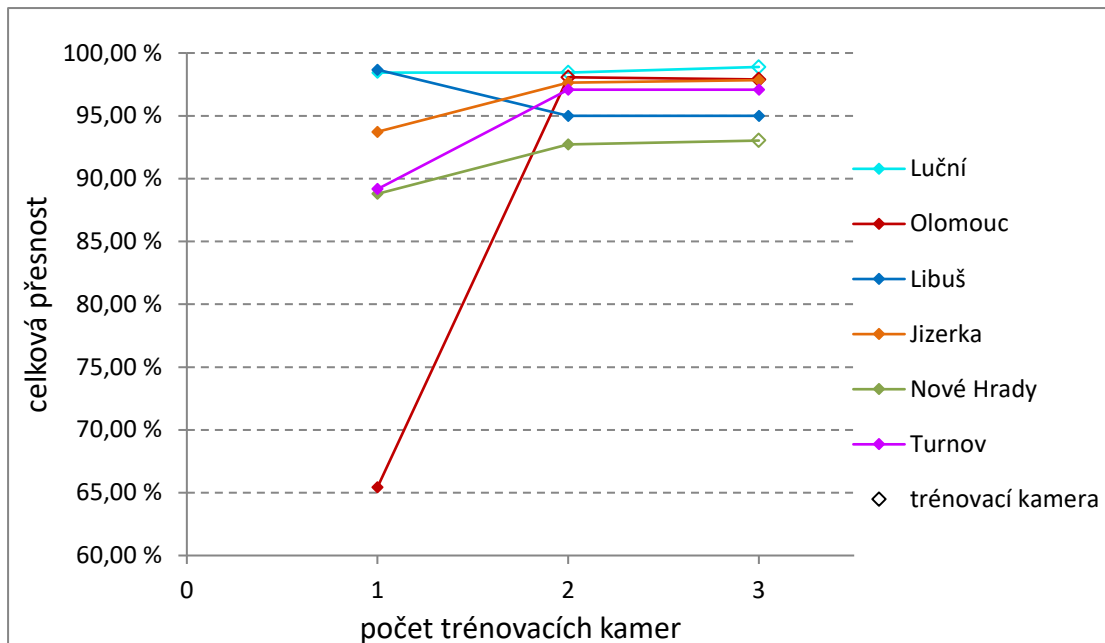
Pro vytvoření modelu bylo využito průběhu hodnot modré části spektra. Nejprve byl model vytvořen na základě snímků jediné kamery z Luční boudy. Použití modelu na testovacím souboru však poukázalo na obtížnou přenositelnost takto

navrženého modelu. Kamery s nejnižší mírou celkové přesnosti (Olomouc a Nové Hradý) byly proto použity pro další trénování modelu. Z každé trénovací kamery bylo náhodně zvoleno deset snímků se sněhem a deset bez. Byly použity pouze pixely omezené maskou vymezující plochu určenou pro detekci sněhové pokrývky. Průběh histogramu snímků z kamer Luční bouda, Olomouc a Nové Hradý je zobrazen na obrázku 12. Každá třída referenčních pixelů (sníh / nesníh) byla proložena




**Obrázek 12:** Histogram modrého pásma 60 trénovacích snímků kamer Luční, Olomouc, Nové Hradý modře pixely sněhu, zeleně ostatní  
Zdroj: Autor, ČHMÚ

Gaussovou funkcí. V místě průniku křivek pak byla určena prahová hodnota 130 (viz obrázek 12). Pomocí této pevné prahové hodnoty bylo pro celý testovací soubor dosaženo celkové přesnosti 96,62 %. Použití snímků více kamer mělo výrazný vliv na prahovou hodnotu, která z původní hodnoty jasu modrého pásma 157 (pro snímky kamery Luční) poklesla na zmíněných 130. Celkovou přesnost detekce v závislosti na počtu kamer použitých pro tvorbu modelu můžete vidět na obrázku 13. Přesnost detekce sněhu výsledného modelu prahování pro jednotlivé kamery je znázorněna na obrázku 14.



**Obrázek 13:** Přesnost detekce sněhu metodou prahování

Zdroj: Autor, ČHMÚ



**Obrázek 14:** Přesnost výsledného modelu prahování

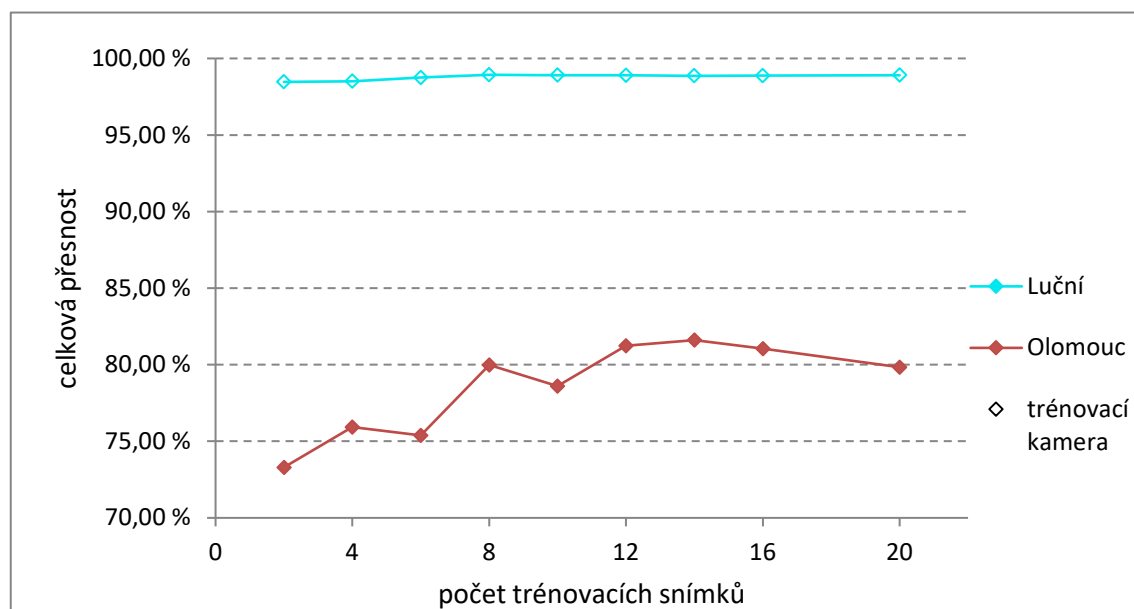
Zdroj: Autor, ČHMÚ

### 5.1.3 Metoda SVM

Stěžejní metodou detekce použitou v této práci je metoda SVM přiblížená v kapitole 2.4.2. Předpokladem bylo dosažení vyšší přesnosti detekce sněhové pokrývky oproti jednoduché metodě prahování. Trénování klasifikátoru probíhalo s využitím stejných kamer jako v případě prahování – tedy Luční bouda, Olomouc a Nové Hrady. Rovněž testovací soubor zůstal beze změn. Trénování probíhalo prostřednictvím dvojic binárních snímků (výskyt sněhu 0 nebo 100 %), které byly


určeny pomocí vizuální interpretace. To znamená tytéž referenční hodnoty (0 / 1) v rámci celého snímku. Počet trénovacích pixelů tak mohl být libovolně navyšován bez nutnosti ručního určení hodnoty každého pixelu. Trénovací pixely byly zvoleny náhodně v rámci oblasti vymezené pro klasifikaci, přičemž každý pixel nese hodnoty tří pásem – RGB. Hodnoty celkové, uživatelské a zpracovatelské přesnosti jsou vždy výsledkem průměru hodnot dosažených padesáti modely trénovanými na náhodném souboru pixelů.

Nejprve byly pro trénování klasifikátoru použity snímky kamery na Luční boudě. Trénování na jediné kameře posloužilo k určení vhodné velikosti trénovacího souboru. Byla zkoumána závislost přesnosti klasifikace na variabilitě a množství trénovacích dat - počet trénovacích snímků a pixelů. V grafu na obrázku 15 je zachycen průběh celkové přesnosti v závislosti na rostoucím počtu trénovacích snímků, přičemž celkový počet



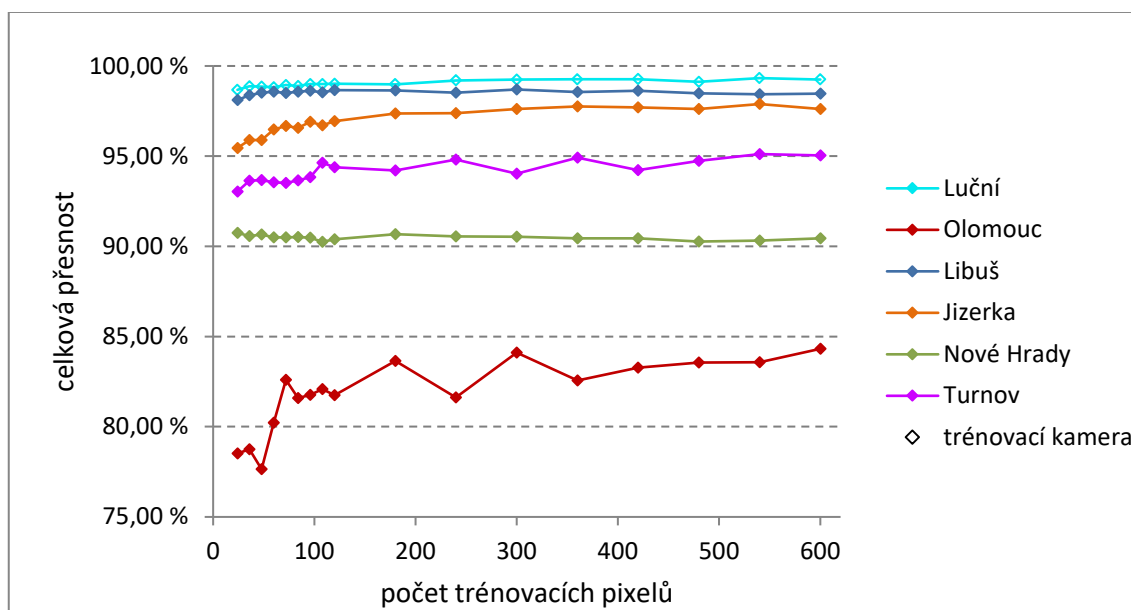
**Obrázek 15:** Přesnost detekce sněhu metodou SVM při 60 trénovacích pixelech z jedné kamery  
Zdroj: Autor, ČHMÚ

pixelů zůstává nezměněn na hodnotě 60. Na základě křivky pro kameru Olomouc bylo jako optimum určeno 12 trénovacích snímků (6 se sněhem a 6 bez sněhu). Při dalším zvyšování počtu trénovacích snímků již přesnost neroste. Na témže grafu je možné vidět výrazný pokles přesnosti detekce v případě přenesení modelu trénovaného na kameře Luční na kameru Olomouc. V grafu na obrázku 16 můžeme vidět průběh přesnosti v závislosti na rostoucím počtu trénovacích pixelů při zachování počtu snímků (20). Po počátečním nasycení modelu již další zvyšování počtu pixelů růst přesnosti



**Obrázek 16:** Přesnost detekce sněhu metodou SVM při 20 trénovacích snímcích z jedné kamery  
Zdroj: Autor, ČHMÚ

nepřinášejí. Vhodný počet trénovacích pixelů byl stanoven na 180. Tomu odpovídá i graf na obrázku 17, který zobrazuje – pro všechny zkoumané webové kamery – závislost průběhu celkové přesnosti na rostoucím počtu pixelů v trénovacím souboru.

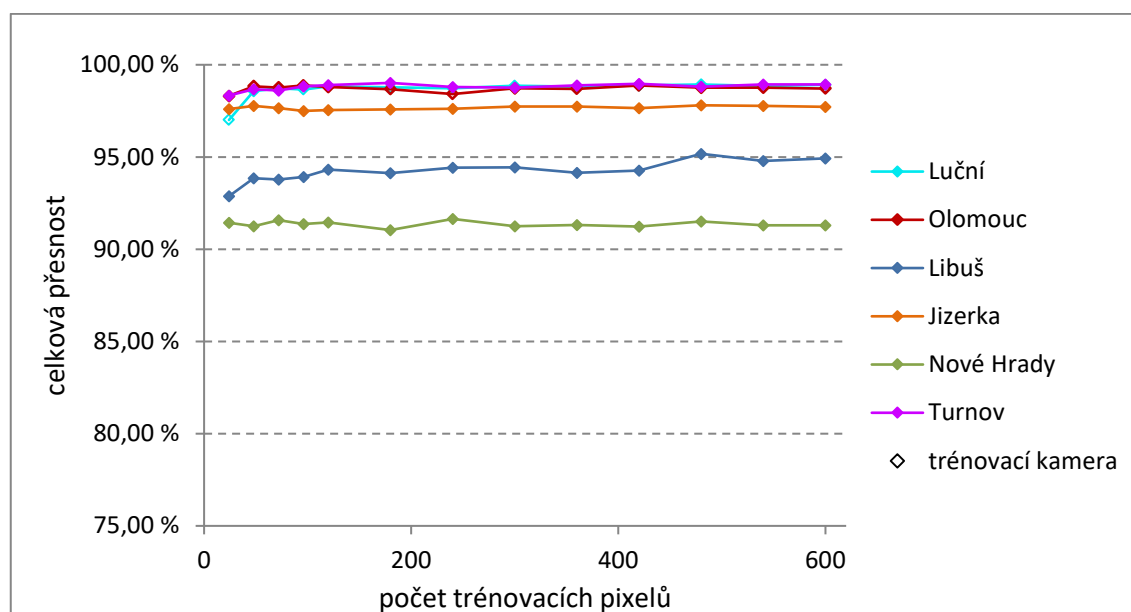


**Obrázek 17:** Přesnost detekce sněhu metodou SVM při 12 trénovacích snímcích z jedné kamery  
Zdroj: Autor, ČHMÚ

Vyšší přesnost detekce přineslo zvýšení počtu trénovacích kamer. Zahrnutí kamery Olomouc mezi trénovací kamery mělo za následek výrazný nárůst přesnosti detekce u této kamery (83,65 % → 98,68 %) zatímco pokles u kamery Luční byl pouze nepatrný (98,98 % → 98,77 %). Původně nízká přesnost detekce na snímcích kamery u Olomouce je způsobena pravděpodobně jiným typem povrchu (orná půda) oproti



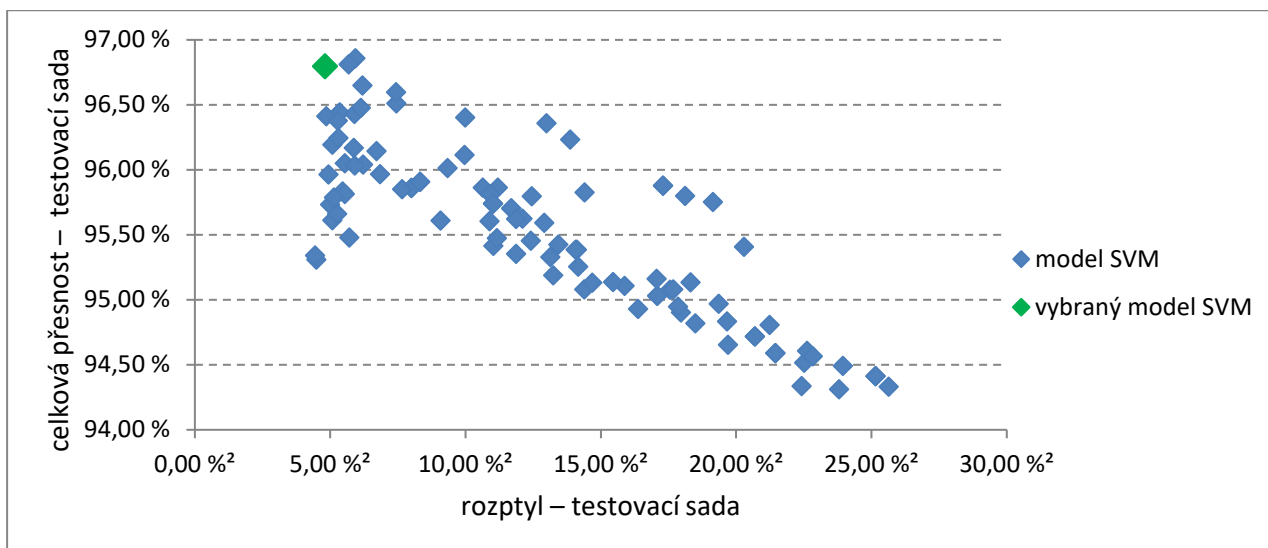
trénovací kameře (Luční bouda). Foody a kol. (2006) k tomu uvádí, že pro trénování je nutné zastoupení vzorků všech tříd objektů, které se mohou vyskytnout v zájmovém území, přestože nejsou předmětem našeho zájmu – v našem případě třeba orná půda a suchá tráva. Ostatní testovací kamery s výjimkou kamery Praha-Libuš zaznamenaly zvýšení přesnosti v rozsahu jednotek procent (viz obrázek 18). Použití tří trénovacích kamer (Luční, Olomouc, Nové Hrady) již další zvýšení přesnosti detekce nepřineslo.



**Obrázek 18:** Přesnost detekce sněhu metodou SVM při 12 trénovacích snímcích ze 2 kamer  
Zdroj: Autor, ČHMÚ

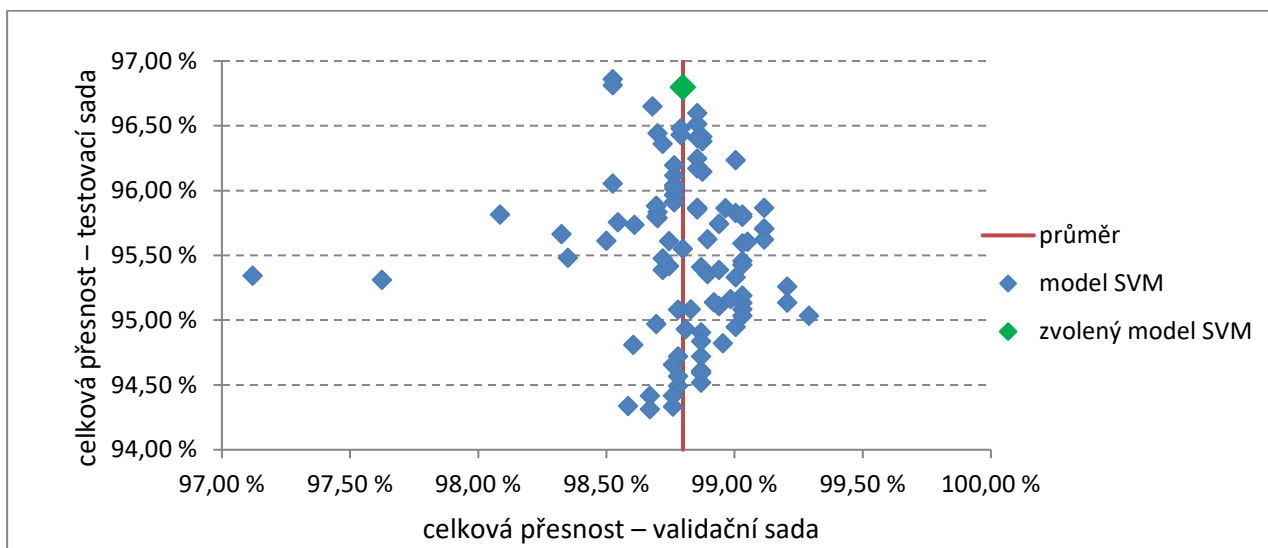
Jako vhodná velikost trénovacího souboru se tedy ukázalo použití 12 snímků (sníh/nesníh) ze dvou trénovacích kamer s celkovým počtem 180 pixelů. Tyto parametry byly dále použity pro natrénování ideálního modelu SVM. K tomu bylo využito generování náhodných množin trénovacích dat. Nejprve bylo náhodně vybráno 12 trénovacích snímků – pro každou ze dvou kamer byly vybrány 3 snímky se sněhem a tři beze sněhu, čímž byl výběr stratifikován. Z každého snímku bylo poté zvoleno 15 náhodných pixelů. Opakováním tohoto postupu došlo k vytvoření sta nezávislých modelů. Nejlepší model byl zvolen na základě kombinace vysoké přesnosti spolu s vysokou hodnotou preciznosti v rámci testovací sady dat (kamery nepoužité pro trénování modelu – Libuš, Jizerka, Nové Hrady, Turnov). Přesnost byla určena jako průměr celkové přesnosti dosažené pro jednotlivé kamery. Hodnota preciznosti byla vyjádřena pomocí rozptylu celkových přesností. Vztah přesnosti a preciznosti vytvořených klasifikačních modelů můžete vidět v grafu na obrázku 19. Rovněž je zde vyznačen zvolený model. Srovnání dosažených přesností pro testovací a trénovací

kamery se nachází v grafu na obrázku 20. Na tomto grafu můžeme vidět, že model vybraný na základě testovací sady dat dosahuje na validačních datech zhruba průměrné míry celkové přesnosti sta modelů. Při vynesení modelů na graf závislosti celkových přesností pro trénovací kamery Luční a Olomouc (obrázek 21) můžeme vidět, že se vítězný model nachází v blízkosti lineární regresní křivky. Na tomto grafu je také patrná silná záporná korelace (-0,56) mezi výsledky obou trénovacích kamer – pokud úpravou trénovací množiny zvyšujeme přesnost detekce pro kameru na Luční boudě, dochází ke snižování přesnosti pro kameru v Olomouci a naopak.



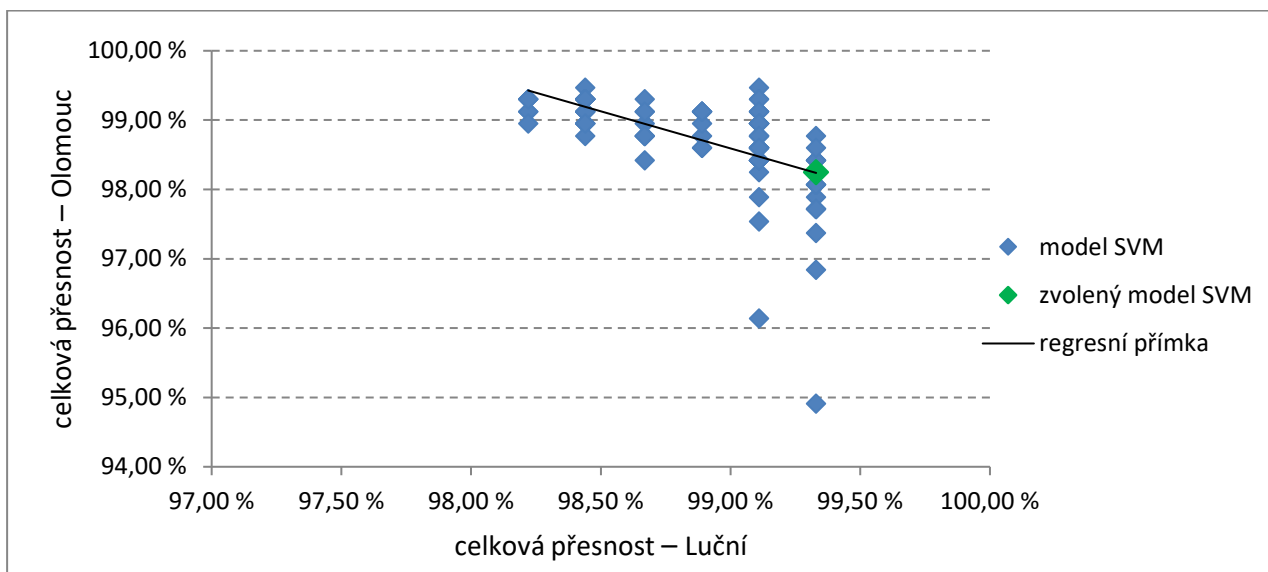
**Obrázek 19:** Celková přesnost a rozptyl modelů SVM

Zdroj: Autor, ČHMÚ



**Obrázek 20:** Celková přesnost modelů SVM pro validační a testovací sadu


Zdroj: Autor, ČHMÚ



**Obrázek 21:** Celková přesnost modelů SVM na validačních kamerách


Zdroj: Autor, ČHMÚ

Celková přesnost výsledného modelu pro všech 6 kamer činí 97,46 %, přičemž na validačním souboru ze dvou trénovacích kamer bylo dosaženo přesnosti detekce 98,79 % a na ostatních čtyřech kamerách – které nebyly použity pro trénování modelu – 96,80 %. Hodnoty celkové, uživatelské a zpracovatelské přesnosti pro jednotlivé kamery jsou zobrazeny na obrázku 22. Ukázka klasifikace snímku výsledným modelem SVM je na obrázku 23.



**Obrázek 22:** Přesnost výsledného modelu SVM

Zdroj: Autor, ČHMÚ




**Obrázek 23:** Snímek kamery Luční ze dne 14. 5. 2017; vlevo před klasifikací s naznačenou maskou zájmového území, vpravo po klasifikaci – modře sníh, zeleně ostatní

Zdroj: Autor, ČHMÚ

Takto vytvořený model byl poté použit v rámci systému určení podílu sněhem pokrytého území. Srovnání celkové přesnosti metod prahování a SVM můžete vidět na následujícím grafu. V případě modelu SVM byla zaznamenána rovněž vyšší míra

preciznosti vyjádřená hodnotou směrodatné odchylky 1,84 % vypočtené z přesností šesti použitých kamer. Směrodatná odchylka metody prahování byla 2,00 %, tedy lehce nižší preciznost.



**Obrázek 24:** Celková přesnost modelů prahování a SVM

Zdroj: Autor, ČHMÚ


## 5.2 Vytvoření modelu odstranění snímků se špatnou viditelností

Detekce snímků se špatnou viditelností probíhala s využitím Cannyho hranového detektoru. Pro tvorbu a testování modelu schopného rozlišit snímky s dostatečnou a nedostatečnou viditelností byly použity snímky kamery umístěné na Luční boudě. Byly použity snímky ze sezony 2019 pořízené mezi desátou hodinou ránní a po třetí hodině odpolední. Snímky kamery Luční byly zvoleny z důvodu subjektivně malého počtu hran v záběru kamery i v případě dobrého počasí a také z důvodu častých mlh přítomných v této lokalitě. Pro implementaci Cannyho detektoru byla použita funkce `cv.Canny()` obsažená v knihovně OpenCV (Bradski 2000, Huamán 2012). Vstupními parametry této funkce jsou hodnoty dolního a horního prahu, které byly nastaveny na hodnoty 60 a 120. Pro správnou detekci snímků se sníženou viditelností bylo nezbytné odmaskovat logo a textové údaje ČHMÚ nacházející se v horních rozích snímků, které byly chybně považovány za hrany. Ukázkou snímku před a po použití Cannyho hranového detektoru můžete vidět na obrázku 25.



**Obrázek 25:** Aplikace Cannyho hranového detektoru; vlevo před aplikací; vpravo po aplikaci – bílé pixely hran  
Zdroj: Autor, ČHMÚ

Pro každý snímek použitého souboru byl spočítán počet detekovaných pixelů hran. Rozložení počtu pixelů hran na snímcích je znázorněno na následujícím histogramu. V levé části histogramu jsou obsaženy snímky s nulovou a sníženou viditelností. Na základě tohoto histogramu byla zvolena prahová hodnota vymežující snímky s nedostatečnou viditelností v případě méně než 1500 pixelů hran detekovaných na snímku. Při rozlišení snímku 1600 x 1200, to znamená podíl pixelů hran alespoň 0,08 %. Protože všechny v práci použité snímky měly stejné rozlišení, bylo možné aplikovat navržený model i na ostatních kamerách. Navržený model bude ověřen v rámci systému detekce sněhem pokrytého území.



**Obrázek 26:** Cannyho hranový detektor  
Zdroj: Autor, ČHMÚ

### 5.3 Systém pro určení podílu sněhem pokrytého území

Funkčnost navrženého modelu byla ověřena na souboru snímků ze sezon 2017 a 2019. Průběh zpracování snímků z roku 2019 pořízených s hodinovým intervalem je podrobně popsán v následující podkapitole.

#### 5.3.1 Určení rozsahu sněhem pokrytého území

Před vlastním zpracováním snímků bylo třeba pro každou ze šesti webkamer určit referenční snímek (viz příloha 1). Na referenčních snímcích bylo pomocí masky vymezeno území pro určení podílu sněhové pokrývky. Pro snazší zpracování byla zvolena maska jednoduchého obdélníkového tvaru. Řešení by bylo možné upravit pro použití masky tvaru libovolného, případně i pro použití více masek v záběru jedné kamery. Na referenčních snímcích byly dále nalezeny vlíčovací body jednoznačně identifikovatelné na snímku i na ortofotu. Ze vztahu obrazových a geografických souřadnic vlíčovacích bodů byla pro každou kameru vypočtena referenční transformační matice projektivní transformace.

Nyní bylo možné přistoupit k automatizovanému zpracování snímků pomocí modelu detekce SCA znázorněného na pravé části diagramu na obrázku 6. Celkem bylo zpracováno 18 482 snímků z ledna až května 2019. V první fázi třídění snímků bylo vyřazeno 13 729 snímků pořízených v nočních, ranních a večerních hodinách. Dále bylo vyřazeno 9 poškozených snímků (prázdný soubor, bílá plocha), které nebylo možné načíst nebo neobsahovaly metadata EXIF typická pro fotografie. Z důvodu špatných viditelnostních podmínek – detekovaných pomocí navrženého modelu – bylo z dalšího zpracování vyloučeno 284 snímků. Problém s viditelností se týkal především horských kamer Luční a Jizerka. Nejčastější příčinou byla mlha a dále také srážky přichycené na objektivu kamery (ať už sněhové nebo dešťové). Dále se jednalo o kombinaci oblačnosti s pozicí slunce v záběru kamery. Tento jev je specifický pro webkameru Olomouc, která je jako jediná orientována na jih. Zhruba 5 % snímků detekovaných jako nevhodné pro klasifikaci by bylo možné dále využít, nicméně v případě dostupnosti snímků s hodinovým intervalem toto nepředstavuje žádný problém.

Další krok – prostorová registrace – se tedy týkal 4460 snímků. Snímky byly registrovány primárně k referenčnímu snímku. Vzhledem k tomu, že soubor snímků pokrýval měsíce leden až květen, byl referenční snímek bez sněhové pokrývky zvolen

ze závěru tohoto období. Z tohoto důvodu bylo při registraci snímků postupováno retrospektivně. Nejprve byl snímek registrován k referenčnímu snímku, v případě neúspěšné registrace (nedostatečný počet identifikovaných shodných bodů) byl snímek zarovnáván k poslednímu úspěšně registrovanému snímku. Snímky, které se nepodařilo registrovat, byly vyřazeny z dalšího zpracování. Při registraci docházelo k posunu bodů na snímku o jednotky až malé desítky pixelů ve směru os x a y, což potvrzuje, že se nejedná o zanedbatelný problém. Pomocí metody představené výše bylo úspěšně registrováno 4299 snímků. S výjimkou kamery na Luční boudě probíhalo lícování snímků spolehlivě. V případě Luční se totiž v záběru kamery nenachází dostatek objektů, které by bylo možné pro zarovnání snímků použít, tím spíše pokud je krajina pokryta vrstvou sněhu. Aby nebyly ve výstupních datech příliš velké mezery, bylo pro další zpracování ponecháno 92 snímků této kamery bez prostorové registrace. Pro úspěšnější registraci snímků webkamery na Luční boudě by bylo třeba použít robustnější metodu, která by kromě významných bodů uměla pracovat například s linií horizontu.

Nyní byly snímky podrobeny detekci sněhové pokrývky pomocí modelu SVM vytvořeného v předchozí kapitole. Snímky klasifikované do tříd sních / nesních byly pomocí referenční transformační matice transformovány do souřadného systému ETRS89. Díky tomu bylo možné určit plochu zkoumaného území v metrech čtverečních a dále podíl sněhem pokrytého území. Rozlohy území vymezených pro zkoumání výskytu sněhové pokrývky v obrazových pixelech a v metrech čtverečních se nachází v tabulce 4. V tabulce rovněž vidíme průměrnou hodnotu prostorového rozlišení kamer. Tato hodnota není odvislá od vlastního rozlišení kamer, které bylo pro použité kamery shodné, nýbrž od vzdálenosti snímaného území. Prostorové rozlišení webkamer je o několik řádů vyšší než v případě satelitních snímků.

Název kamery	Rozloha zkoumaného území		Průměrné prostorové rozlišení
	[pixely snímku]	[m <sup>2</sup> ]	
Luční bouda	197 400	19818	0,32
Olomouc	73 720	4030	0,23
Praha-Libuš	17 600	684	0,20
Jizerka	96 600	194	0,04
Nové Hrady	19 500	1088	0,24
Turnov	108 000	1428	0,11


**Tabulka 4:** Velikost území pro určení podílu sněhové pokrývky

Zdroj: Autor




### 5.3.2 Vývoj sněhem pokrytého území v čase

Jelikož se vývoj sněhové pokrývky sleduje zpravidla s jednodenní periodou, byla z hodnot pro snímky z roku 2019 (interval jedna hodina) odvozena denní hodnota podílu sněhem pokrytého území. Denní hodnota byla určena jako průměr hodnot téhož dne. V případě, že byl dostupný podíl sněhem pokrytého území z více než tří snímků pořízených během jednoho dne, byly před vypočtením průměru vypuštěny krajní hodnoty (minimum a maximum). To by mělo přispět k eliminaci vlivu objektů dočasně se vyskytujících v zájmovém území. Výsledkem jsou grafy vývoje podílu sněhem pokrytého území v období únor – květen 2017 a leden – květen 2019 (obrázky 27 a 28). Na grafech můžeme vidět kolísání výskytu sněhu a průběh závěrečné části tání sněhové pokrývky. Nejdéle se sních vyskytuje v záběru kamery na Luční boudě, kde roztává až v druhé polovině května roku 2017 i 2019. Proces tání sněhu od souvislé sněhové pokrývky po její kompletní roztátí – výskyt sněhových frakcí – zde trvá zhruba 10 dní. Naopak nejméně dní s výskytem sněhu bylo zaznamenáno pro lokalitu Praha-Libuš. Zajímavý průběh podílu sněhem pokrytého území byl zachycen kamerou Jizerka během dubna roku 2017. Po úplném roztátí sněhové pokrývky mezi daty 29. března a 6. dubna je v grafu (obrázek 27) zaneseno pět vrcholů znázorňujících prudký a krátkodobý nárůst podílu sněhem pokrytého území. To, že se ani v jednom z případů nejedná o chybu, je znázorněno v příloze 2, kde jsou porovnány systémem zjištěné hodnoty se snímky sloužícími jako vstupní data. Jak je možno vidět, rozsah sněhové pokrývky se mění doslova z hodiny na hodinu, což nahrává využití vysokého časového rozlišení webových kamer.



Obrázek 27: Sněhem pokryté území 2017

Zdroj: Autor, ČHMÚ



**Obrázek 28:** Sněhem pokryté území 2019  
 Zdroj: Autor, ČHMÚ

### 5.3.3 Validace výsledků

Pro účely validace byly dny z let 2017 a 2019 – pro které byla modelem určena hodnota sněhem pokrytého území – rozděleny na základě vizuální interpretace do dvou kategorií s krajním případem výskytu sněhové pokrývky 0 a 100 %, třetí kategorii tvořily snímky s výskytem nesouvislé sněhové pokrývky – sněhových frakcí. Toto rozdělení bylo provedeno na základě vizuální interpretace snímků. Rozdělení do těchto tříd můžete vidět v tabulce 5. V případě mezních hodnot výskytu sněhové

Název kamery	Sněhová pokrývka [dny]			Výskyt sněhových frakcí	
	0 %	1 – 99 %	100 %	2017	2019
Luční bouda	9	78	84	28.3. – 24.5.	25.4. – 1.6.
Olomouc	213	12	14	20.2. – 22.2.	23.1 – 27.1.; 10.2. – 13.2.
Praha-Libuš	224	14	4	13.2. – 17.2.	18.–21.1.; 24.–26.1.; 10.–11.2.
Jizerka	73	53	113	25.3. – 27.4.	5.4. – 22.4.; 5.5.; 15.5.
Nové Hrady	203	33	8	13.2. – 20.2.	18.–25.1.; 2.–19.2.
Turnov	204	27	13	20.2. – 23.2.	18.–25.1.; 2.–16.2.

**Tabulka 5:** Rozsah výskytu sněhové pokrývky ve zkoumaných obdobích let 2017 a 2019

Zdroj: Autor

pokrývky byla přesnost detekce stanovena jako velikost odchylky systémem určené hodnoty sněhem pokrytého území od referenční hodnoty sta respektive nula procent. Přesnost detekce sněhem pokrytého území je zobrazena v tabulce 6.

Název kamery	Přesnost detekce sněhem pokrytého území [%]	
	Referenční hodnota 0 %	Referenční hodnota 100 %
Luční bouda	99,95	99,99
Olomouc	99,99	99,94
Praha-Libuš	99,98	99,98
Jizerka	99,96	99,86
Nové Hrady	99,98	99,99
Turnov	99,90	100,00


**Tabulka 6:** Přesnost detekce mezních hodnot výskytu sněhové pokrývky

Zdroj: Autor

Bylo zaznamenáno celkem 14 dnů, kdy byla přesnost detekce nižší než 99 %. V případě očekávaného 100% rozsahu sněhové pokrývky souvisela nižší přesnost s výskytem lyžařů v záběru kamery (Jizerka). Naopak pokud měl být detekován 0% výskyt sněhu, způsobila chybu například produkce cirkusu, která probíhala 15. – 20. května 2019 na louce před webkamerou Turnov. Nejnižší hodnota přesnosti detekce sněhem pokrytého území 96,25 %, dosažená totožnou kamerou 20. 4. 2019, pro změnu souvisela s pořádáním závodů horských kol. Zmíněné chyby jsou patrné

také v grafu (obrázek 28). Použitý algoritmus se tedy dobře vyrovnal s různými světelnými podmínkami.


Pro dny s výskytem nesouvislé sněhové pokrývky však způsob validace pomocí vizuální interpretace nebylo možné použít. Jak je vidět v tabulce 5 výše, nejedná se o ojedinělou situaci. Nejvíce snímků sněhových frakcí bylo během dvou období tání zachyceno horskými kamerami Luční (78) a Jizerka (53). Pro lokality těchto webkamer byly z ČHMÚ získány hodnoty výšky sněhové pokrývky. Na obrázcích 29 – 32 je znázorněno srovnání průběhu vypočteného podílu sněhem pokrytého území a výšky sněhu v době výskytu sněhových frakcí. Přestože srovnáváme dvě odlišné fyzikální veličiny, je na grafech jasně patrné, že pokles výšky sněhu je následován poklesem podílu sněhem pokrytého území. Nejlépe je tento vztah vidět při tání sněhu v oblasti Luční boudy v květnu 2019 (obrázek 31). Výrazné zpoždění hodnot SCA oproti výšce sněhu bylo zaznamenáno na stanici Luční v roce 2017. Tento jev bude diskutován v následující kapitole. Výška sněhu nemůže postihnout krátkodobé výkyvy rozsahu sněhové pokrývky v důsledku jarních sněhových srážek, které byly zachyceny webkamerou Jizerka v dubnu 2017 (příloha 18; srov. příloha 16). Ještě je třeba zmínit rozdílnou výšku sněhu v počátečním čase výskytu sněhových frakcí pro stanice Luční a Jizerka. K zachycení nesouvislé sněhové pokrývky v oblasti Úpského rašeliniště dochází ve chvíli, kdy odtávající sníh odhalí vršky porostů kleče. Tou dobou je výška sněhu na meteorologické stanici Luční bouda stále více než půl metru. Oproti tomu trávník před kamerou Jizerka umožňuje výskyt souvislé bílé plochy i při výšce sněhu do 20 centimetrů.



Obrázek 29: Luční 2017


Zdroj: Autor, ČHMÚ

■ sněhem pokryté území    ◆ výška sněhu




Obrázek 31: Luční 2019

Zdroj: Autor, ČHMÚ



Obrázek 30: Jizerka 2017

Zdroj: Autor, ČHMÚ



Obrázek 32: Jizerka 2019

Zdroj: Autor, ČHMÚ

## 6. Diskuse

Cílem diplomové práce bylo navržení a ověření systému pro určení sněhem pokrytého území (SCA [%]) pomocí záběrů webových kamer. Hlavní součástí navrženého systému je model detekce sněhu ze snímků RGB.

### 6.1 Detekce sněhové pokrývky

Pro klasifikaci snímků byla nejprve použita jednoduchá metoda prahování. Na základě průběhu hodnot snímků trénovacích kamer byla pro modrou část spektra vypočtena pevná prahová hodnota 130. Salvatori a kol. (2011) došli ve své práci k základní prahové hodnotě 127 (kterou dále pro každý snímek dynamicky upravují), což odpovídá hodnotě dosažené v této práci. Oproti tomu Kowalski (2015) detekující sních na úbočí Luční hory používá prahovou hodnotu 210 – metoda s pevným prahem – respektive 190 pro metodu dynamického prahování. Rozložení histogramu se pro snímky různých kamer liší, proto je obtížné takto navržený model s pevnou prahovou hodnotou přenášet mezi kamerami. Metoda dynamického prahování upravuje prahovou hodnotu individuálně pro každý snímek. Nevýhodou tohoto přístupu je nutnost bimodálního rozdělení histogramu, což je problematické v případě souvislé sněhové pokrývky nebo naopak u snímků beze sněhu.

Je třeba si uvědomit, že průběh hodnot pixelů na snímcích různých webkamer je výrazně ovlivněn typem snímaného povrchu. Pro kameru na Luční boudě snímající horskou louku byla vypočtena optimální prahová hodnota jasu 157, oproti tomu pro kameru v Olomouci, která zabírá ornou půdu, to bylo pouze 110. Z tohoto důvodu Kowalski (2015) pracující se snímky pouze jediné webkamery došel k vyšší prahové hodnotě, neboť jím zkoumané povrchy – skály a vegetace alpského stupně – mají v pásmech RGB vyšší hodnotu odrazivosti. Rozdíly v histogramech kamer vycházejí také z různé orientace webové kamery v závislosti na denním chodu slunce.

Jednoduchou metodou prahování bylo pro šest použitých kamer dosaženo celkové přesnosti 96,62 %. Salvatori a kol. (2011) dosahují hodnoty přesnosti přes 99 %, nicméně pracují pouze se dvěma pro účely výzkumu instalovanými kamerami. Na nedostatečné testování v rámci neměnných světelných poměrů a krátké vzdálenosti ke snímané ploše poukazuje také Fedorov a kol. (2016). Kowalski (2015) celkovou přesnost detekce neuvádí.

Pro detekci sněhu byla dále použita metoda SVM s využitím všech tří pásem RGB. Výsledek klasifikace metodou SVM je odvislý od nastavení vstupních parametrů. Bylo použito lineární jádro, které představuje speciální případ použití jádra rbf – tzn., že při určitém nastavení parametrů  $C$  a  $\gamma$  dosáhneme stejného výsledku (Keerthi, Lin 2003). Použitím lineárního jádra se vyhneme hledání parametru  $\gamma$  (Hsu, Chang, Lin 2016). Parametr  $C$  byl ponechán na výchozí hodnotě (1,0), čímž je kladen důraz na správnou klasifikaci trénovacích pixelů. Byl zkoumán vliv velikosti a variability trénovacího souboru (počet trénovacích kamer, snímků a pixelů) na výslednou přesnost a možnosti přenášení modelu mezi kamerami. Ze souboru snímků trénovacích kamer byly vybrány snímky s podílem sněhové pokrývky 0 a 100 %. Pixelům těchto snímků pak mohly být hromadně přiděleny referenční hodnoty (sníh vs. ostatní). Opakováním náhodného výběru byla nejprve hledána optimální velikost podmnožiny trénovacích dat. Bylo zjištěno, že model SVM dosáhne maxima přesnosti už při malém množství trénovacích prvků, a další růst velikosti (počet pixelů) nebo variability (počet snímků) trénovacího souboru již zvýšení přesnosti klasifikace nepřináší (viz obrázky 15 – 18). Jako vhodné množství trénovacích dat se ukázalo využití 12 snímků (6 se sněhem a 6 beze sněhu) ze dvou trénovacích kamer s celkovým počtem 180 pixelů. Opakováním náhodného výběru o dané velikosti trénovacího souboru byl hledán ideální model SVM. Důraz byl kladen na vysokou přesnost a preciznost klasifikace, čímž by mělo být dosaženo dobré přenositelnosti vytvořeného modelu mezi kamerami (JCGM 2008). Graf vztahu přesnosti a preciznosti – vyjádřené hodnotou rozptylu – se nachází na obrázku 19. Celková přesnost detekce sněhové pokrývky výsledného modelu SVM je 97,46 %, přičemž na validační sadě (snímky dvou trénovacích kamer) bylo dosaženo přesnosti detekce 98,79 % a na testovacích datech (snímky ostatních čtyř kamer) 96,80 %. Hodnota přesnosti docílené na kamerách, které nebyly použity pro trénování modelu, je uspokojivá. Dosažená hodnota směrodatné odchylky pro 6 webkamer 1,84 % značí vysokou preciznost. Tím byla ověřena dobrá přenositelnost modelu. Dalšího sblížení přesnosti detekce pro validační a testovací sadu by bylo pravděpodobně možné dosáhnout snížením hodnoty parametru  $C$  (Géron 2017). Pro podrobnější zkoumání přenositelnosti vytvořeného modelu by bylo třeba aplikovat model na více než 6 webových kamer. Také je třeba vzít v úvahu kvalitu testovacího souboru. Vizuální interpretace pixelů na okrajích sněhových polí nemusí být zcela jednoznačná, což způsobuje jistou míru nejistoty v určení referenční hodnoty



testovacích dat. Nedostatek snímků se souvislou sněhovou pokrývkou z kamery Praha-Libuš má za následek částečnou nereprezentativnost testovacího vzorku této kamery – pouze 11 testovacích pixelů sněhu. To se projevilo nízkou hodnotou uživatelské přesnosti (viz obrázek 22).

Pokud se zaměříme na srovnání výsledků metody pevného prahu s metodou SVM, zjistíme, že velmi dobrého výsledku klasifikace bylo dosaženo již jednoduchou metodou prahování. Metoda podpurných vektorů přinesla zvýšení celkové přesnosti o méně než jedno procento. Vysoká přesnost obou metod souvisí s dobrou, byť ne úplnou, lineární separabilitou pixelů sněhu. Relativně nízký nárůst přesnosti v případě metody SVM lze vysvětlit silnou pozitivní korelací spektrálního chování sněhu v pásmech RGB. Zjednodušeně řečeno sníh má vysokou odrazivost ve všech pásmech viditelné části spektra a proto jejich kombinace nepřináší výrazný rozdíl oproti použití pouze jednoho pásma. Alternativně by bylo možné uvažovat o vylepšení metody prahování využitím kombinace všech tří pásem RGB například pomocí rozhodovacího stromu. Tento přístup by nevyžadoval bimodální rozložení histogramu, jako je tomu v případě metody dynamického prahování.

Metodu SVM pro detekci sněhové pokrývky úspěšně použil Fedorov (2016) při dosažení přesnosti přes 90 %. Nižší přesnost je zapříčiněna hledáním odlišné výstupní informace, kterou je výška sněžné čáry. Fedorovem a kol. (2016) zpracovávané snímky zachycují relativně vzdálené horské masivy, zatímco v této práci jsou klasifikovány plochy často v těsné blízkosti webových kamer, navíc vymezené maskou, která na snímcích zachovává pouze oblasti vhodné pro přirozené ukládání sněhové pokrývky (typicky louka) a zakrývá prvky, jako jsou zástavba, stromy, vodní plochy apod. Tím je problematika klasifikace značně zjednodušena. Vytvořený model detekce sněhové pokrývky leží na pomezí prací Fedorova a kol. (2016) a Salvatori a kol. (2011). Ačkoliv je přesnost dosažená v diplomové práci nižší než v případě Salvatori a kol. (2011), výsledky zahrnují možnost použití modelu na rozdílných webových kamerách a v různých světelných podmínkách.

## **6.2 Systém určení sněhem pokrytého území**

Cílem práce bylo ověřit možnost využití snímků webových kamer pro doplnění měření meteorologických stanic. Pro práci byly využity volně dostupné snímky bez

jakýchkoliv zásahů do kamerou snímaného území nebo nastavení a pozice webkamery. Sledovanou veličinou, která byla výstupní hodnotou systému, byla denní hodnota sněhem pokrytého území (snow covered area [%]). Aby bylo možné tuto informaci ze snímků získat, bylo nezbytné vyřešit několik dílčích problémů. Jedná se zejména o výskyt zhoršených viditelnostních podmínek, posun záběru kamery v důsledku povětrnostních vlivů a šikmé snímání. Systém zpracování dat webových kamer byl rozdělen do kroků třídění snímků, registrace snímků, detekce sněhu a výpočet podílu sněhem pokrytého území. Třídění snímků mělo za cíl automatizovaně odstranit snímky nevhodné pro další zpracování. Nejčastěji se jednalo o mlhu nebo srážky přichycené na kameře. Tyto jevy, typické pro horské kamery Luční a Jizerka, byly úspěšně detekovány pomocí Cannyho hranového detektoru. Snímky byly dále podrobeny registraci. Pro každou kameru byl zvolen referenční snímek bez sněhové pokrývky, vůči



**Obrázek 33:** Snímek kamery Luční ze dne 19. 2. 2019  
Zdroj: ČHMÚ

kterému byly ostatní snímky zarovnány. Registrace snímků umožňuje sledování shodného území, což přispívá ke kontinuitě zjišťovaných dat, jelikož sníh netaje zcela rovnoměrně. Použitá metoda SURF pracovala spolehlivě pro všechny webkamery s výjimkou kamery na Luční boudě. Záběr této kamery snímající oblast Úpského rašeliniště neposkytuje po napadení sněhu dostatečné množství klíčových bodů, které by mohl algoritmus detekovat a využít pro registraci – viz následující snímek. Pro lepší registraci snímků této kamery by bylo třeba použít algoritmus umožňující lícování na základě průběhu hran v obraze. Tento způsob využívají Fedorov a kol. (2016), kteří

registrují snímky pomocí linie horizontu. Nevýhodou přístupu Fedorova a kol. (2016) je nutnost dobré viditelnosti, tak aby bylo možné horizont rozpoznat. To je problematické zejména v horském prostředí, kdy nízká oblačnost často neumožňuje rozeznat vzdálenější objekty v záběru kamery, zatímco oblast v popředí pro detekci sněhu využít lze. Z toho důvodu by byla vhodná kombinace obou metod.

Na úspěšně registrovaných snímcích byla následně provedena detekce sněhové pokrývky. Způsob detekce založený na pixelové klasifikaci obrazu metodou SVM již byl diskutován výše. Binárně klasifikovanou plochu zachycenou šikmým pohledem webové kamery bylo nyní třeba převést do roviny tak, aby došlo k vyrovnání prostorového rozlišení pixelů a bylo možné určit podíl sněhem pokrytého území. Jelikož jsou nyní snímky vůči sobě zarovnané, je možné pro snímky téže kamery použít jednotnou transformační matici. Tato matice byla pro každou kameru vypočtena na základě souřadnic vlíčovacích bodů určených na referenčním snímku a na ortofotu v systému ETRS89. To, že je referenční snímek bez sněhové pokrývky, umožňuje využití více vlíčovacích bodů než v případě snímku zimního. Vlícovací body bylo nezbytné určit v rovině zkoumané plochy, neboť použitím rovinné projektivní transformace došlo k potlačení tvarů reliéfu. Vzhledem k tomu, že pro zkoumání stavu sněhové pokrývky byly voleny rovinaté části snímků, je tímto způsobené zkreslení zanedbatelné. Další chyby vznikají nepřesným přiřazením souřadnic vlíčovacích bodů pomocí ortofota. Vyšší přesnost by mohlo přinést určení těchto bodů na základě digitálního modelu povrchu. Alternativně také GPS měření (Hinkler a kol. 2002), což je ale časově a finančně náročné. Kowalski (2014) uvádí, že největší vliv na přesnost určení polohy ze snímku webové kamery má distorze objektivu, která je závislá na typu fotoaparátu. Ve své práci využívá snímky webové kamery pro určení rozlohy sněhového pole a přesností se snaží přiblížit k metodě měření GPS. Protože námi sledovanou veličinou je podíl a nikoliv přesná rozloha sněhové pokrývky, byla distorze objektivu zanedbána. Jelikož systém ETRS89, do kterého byly zájmové oblasti snímků transformovány, používá pravouhlé souřadnice, bylo dále možné snadno vypočítat podíl sněhem pokrytého území.

Dalším krokem bylo odvodit z dosažených výsledků denní hodnotu sněhem pokrytého území. To bylo velmi jednoduché pro sadu dat z roku 2017, která byla tvořena pouze jedním snímkem za 24 hodin. Oproti tomu snímky z roku 2019 ukládané v hodinovém intervalu umožňovaly při příznivých povětrnostních a jiných podmínkách

získat až 6 údajů z jediného dne. Pokud bylo pro jeden den dostupných 3 a méně hodnot, byl pro určení denní hodnoty použit jednoduchý průměr. V případě více dostupných údajů byl použit průměr oproštěný o krajní hodnoty (maximum a minimum). To mělo za cíl snížit vliv případných náhodných objektů (typicky lidé) vyskytujících se na některém ze snímků. Lepší variantou by bylo postklasifikační složení snímků daného dne do jednoho obrazu. Hodnota každého pixelu by byla určena například jako modus binárních hodnot sních / nesních dosažených téhož dne. Tím by se odstranil vliv dočasných objektů vyskytujících se během dne na různých místech snímků. Rovněž by to eliminovalo případné sluneční odlesky, které se během dne pohybují. Tento problém řeší také Fedorov a kol. (2016), který vytváří denní kompozitní snímky.

Pro validaci výsledných hodnot byly použity dva rozdílné přístupy. Zkoumané dny byly rozděleny do skupin dle výskytu sněhu: souvislá pokrývka, nesouvislá pokrývka a bez sněhové pokrývky. Nejprve byly validovány výstupy pro dny se souvislou a žádnou sněhovou pokrývkou, kterým byla přiřazena referenční hodnota 100 respektive 0 %. Dosažená shoda mezi referenční a vypočtenou hodnotou sněhem pokrytého území se blížila 100 %. V tom jsou zahrnuty významnější chyby (přesnost pod 99 %), které byly zaznamenány výhradně v důsledku výskytu cizích objektů. To prokazuje, že navržený systém se byl schopný vypořádat s různými světelnými podmínkami, na čemž má zásluhu zejména automatický režim kamer s proměnlivou délkou expozice a vyvážením bílé. Tato část validace však nemůže posoudit kvalitu detekce sněhu v období tání, se kterým souvisí jevy jako zašpinění sněhu nebo okraje sněhových polí. Dny s výskytem nesouvislé sněhové pokrývky byly validovány pomocí hodnot výšky sněhu získaných ze stanic ČHMÚ. Vztah výšky sněhu a sněhem pokrytého území v období tání pro lokality Luční bouda a Jizerka můžete vidět na grafech (obrázky 29 – 32). Hinkler a kol. (2002) a Salvatori a kol. (2011), kteří srovnání výšky a podílu sněhové pokrývky provedli také, došli k závěru, že v čase kdy staniční měření již ukazuje výšku sněhu 0 cm, je podíl sněhu zachycený kamerou stále okolo 50 %. Tomu odpovídá i metodika měření výšky sněhu ČHMÚ (Tolasz a kol. 2007), dle které se provádí měření výšky sněhu, pokud je půda alespoň z poloviny pokryta sněhovou vrstvou. Z výsledků práce se tomuto stavu nejvíce blíží průběh tání na Jizerce v roce 2017 (obrázek 30) a u Luční boudy v roce 2019 (obrázek 31). Naopak velké zpoždění průběhu hodnot podílu sněhové pokrývky oproti výšce sněhu bylo

zaznamenáno pro stanici Luční bouda v roce 2017 (obrázek 29). Tento nesoulad lze vysvětlit pravděpodobnou chybou měření na straně ČHMÚ, na což poukazuje snímek webové kamery Luční (obrázek 34) pořízený v době, kdy data ČHMÚ již vykazují nulovou výšku sněhu. Dle vyjádření ČHMÚ vyhodnotil pozorovatel sněhovou pokrývku



**Obrázek 34:** Snímek kamery Luční ze dne 10. 5. 2017  
Zdroj: ČHMÚ

na stanici Luční v období 8.5. – 17.5. jako nesouvislou (Lenka Stašová). ČHMÚ kromě výšky sněhu eviduje také nesouvislou sněhovou pokrývku (sníh pokrývá méně než polovinu povrchu) a poprašek (výška sněhu menší než 0,5 cm). Tato data nebyla ČHMÚ poskytnuta.

Salvatori a kol. (2011) detekují podíl sněhové pokrývky i v době, kdy je jeho výška – v tomto případě měřená sněhoměrným polštářem – již nulová. Také zaznamenali případ prudkého nárůstu sněhem pokrytého území z nuly na 85 % a zpět na nulu během 24 hodin. Tomu odpovídá vývoj sněhové pokrývky na Jizerce v dubnu roku 2017.

Celkem byly systémem zpracovány snímky 6 webových kamer ze 107 dní roku 2017 a ze 138 dní roku 2019. V 93,3 % zkoumaných dní roku 2017 a v 93,6 % dní roku 2019 byla výstupem všech kamer hodnota sněhem pokrytého území. V ostatních dnech – zhruba 6,5 % – nebylo možné podíl sněhu pomocí snímků webkamer určit. Podíl dnů s dosaženou výstupní hodnotou výrazně snižovala kamera na Luční boudě (2017: 63,6 %, 2019: 74,6 %). Důvodem byl častý výskyt celodenní mlhy a také 12 denní porucha v roce 2017, kdy nebylo možné sněhovou pokrývku detekovat. Tato kamera

byla dále problematická i s ohledem na registraci snímků. Na druhou stranu právě na snímcích této kamery bylo určeno zkoumané území o největší rozloze – téměř 20 000 m<sup>2</sup>. To je pro představu zhruba plocha, kterou zachytí 22 pixelů družice Landsat 8 s prostorovým rozlišením 30 m. To podporuje hypotézu, že snímky webových kamer je možné použít pro validaci produktů DPZ. Mather a Koch (2011) uvádí, že použití pozemních dat je nezbytné k testování výstupu klasifikace dat DPZ.

Základní podmínkou pro možné rozšíření navrženého systému detekce sněhové pokrývky na další webkamery je přítomnost plochy vhodné pro ukládání sněhu v záběru kamery. Například z 95 webkamer aktuálně spravovaných ČHMÚ by jich bylo možné využít 43. Toto relativně nízké číslo je způsobené primárním účelem meteorologických webových kamer, kvůli kterému zabírají především oblohu. Další zdroj možných dat představují dopravní kamery, které často snímají nejen silnici, ale i její blízké okolí.

Slabinou představeného systému je nutnost manuálního odečtu souřadnic vlíčovacích bodů. Tato činnost je zdrojem určitých prostorových nepřesností a také je jí nutné v případě výrazného posunu záběru kamery opakovat. K tomu došlo mezi roky 2017 a 2019 u kamer Praha-Libuš a Olomouc. Autor si dokáže představit algoritmus, který bude provádět prostorové umístění snímku na základě známé pozice kamery a okolního digitálního modelu povrchu (za využití detekce hran).

## 7. Závěr

Monitoring sněhové pokrývky je důležitým zdrojem informací pro vytváření hydrologických prognóz včetně předpovědí extrémních jevů jako jsou povodně nebo sucho. Standardní metodou monitorování sněhové pokrývky jsou měření meteorologických stanic. Takto získaná data jsou přesná, ale jedná se pouze o bodová měření. Hustota stanic je často nedostatečná, v některých oblastech zcela chybí. Proto se jako další zdroj dat využívá metod dálkového průzkumu Země poskytujících plošnou informaci o výskytu sněhové pokrývky. Alternativní způsob monitoringu sněhu představuje snímání webových kamer. Cílem diplomové práce bylo navržení metody detekce sněhové pokrývky ze snímků webových kamer. Důraz byl kladen na vysokou míru přenositelnosti navrženého řešení mezi různými webovými kamerami a na automatizovaný průběh zpracování snímků. Sledovanou veličinou bylo zvoleno sněhem pokryté území (snow covered area) udávané v procentech.

Pro detekci sněhu se osvědčila pixelová klasifikace metodou lineárního SVM. Hodnota celkové přesnosti dosažené v práci je 97,46 %. To je pouze o 0,85 % více, než bylo dosaženo pomocí jednoduché metody prahování. To poukazuje na dobrou lineární separovatelnost pixelů sněhu od ostatních klasifikovaných povrchů. Byl zkoumán vliv velikosti a variability trénovacího souboru na výslednou přesnost detekce. Jako vhodná velikost trénovacího souboru se ukázalo použití 12 snímků ze dvou trénovacích kamer s celkovým počtem 180 pixelů. Více pixelů či trénovacích kamer již vyšší přesnost nepřinášelo. Výsledný model, trénovaný na snímcích kamer Luční a Olomouc, byl zvolen s ohledem na dobrou přenositelnost, tedy těsnost shody přesnosti detekce mezi jednotlivými testovacími kamerami. Přenositelnost byla kromě celkové přesnosti hodnocena také mírou preciznosti modelu. Dosažená vysoká preciznost vyjádřená hodnotou směrodatné odchylky pouze 1,84 % potvrdila dobrou přenositelnost vytvořeného modelu SVM. Klasifikace obrazu se netýkala celých snímků webových kamer, ale pouze ploch vhodných pro ukládání sněhové pokrývky. Tato území byla vymezena pomocí masky. Přesnost detekce zvyšuje rovněž použitá metoda třídění snímků, která s využitím Cannyho hranového detektoru automatizovaně detekuje snímky s výskytem mlhy, námrazy na objektivu apod. Tyto snímky není možné využít pro detekci sněhové pokrývky a jsou vyřazeny z dalšího zpracování. Vliv náhodného pohybu kamer byl potlačen registrací snímků s využitím metody SURF. Dále došlo k

vyrovnání šikmého snímání transformací obrazu pomocí vlíčovacích bodů. Postup práce byl implementován v programovacím jazyce Python.

System detekce sněhem pokrytého území byl testován na snímcích šesti webových kamer ze zimy a jara let 2017 a 2019. Pro práci byly využity snímky volně dostupné v prostředí internetu, přičemž nebylo nijak zasahováno do nastavení kamer ani do území v záběru kamery. Zpracováním snímků byla získána denní hodnota sněhem pokrytého území. Z těchto údajů byly následně vytvořeny křivky výskytu a tání sněhové pokrývky. Výsledky byly podrobeny validaci a diskusi včetně srovnání s dostupnou literaturou. Navržený systém by bylo možné aplikovat na zpracování aktuálních snímků webových kamer v reálném čase, například v prostředí webové aplikace.

Bylo potvrzeno, že webové kamery lze využít pro úspěšnou detekci výskytu sněhové pokrývky, přestože to není primárním účelem jejich provozu. Sledovaná informace byla získána ve více než 93 % zkoumaných dnů. Nižší radiometrické rozlišení snímků webkamer (pouze pásma RGB) je kompenzováno vysokým časovým a prostorovým rozlišením v porovnání s daty leteckého a satelitního snímání. Webové kamery jsou oproti metodám dálkového průzkumu mnohem méně ovlivňovány oblačností. Výstupy navrženého systému je možné využít jako doplněk měření meteorologických stanic a pro validaci produktů DPZ.



## Seznam použité literatury

ALONSO-ATIENZA, F., ROJO-ÁLVAREZ, J. L., CAMPS-VALLS, G., ROSADO, A., GARCÍA-ALBEROLA, A. (2006): Bootstrap feature selection in support vector machines for ventricular fibrillation detection.

BALCÁZAR, J., DAI, Y., WATANABE, O. (2001): A Random Sampling Technique for Training Support Vector Machines. Springer Berlin Heidelberg, Berlin, Heidelberg, s. 119–134.

BAY, H., ESS, A., TUYTELAARS, T., GOOL, L. V. (2008): Speeded-Up Robust Features (SURF). *Computer Vision and Image Understanding*, 3, 110, s. 346–359.

BRADLEY, E. S., CLARKE, K. C. (2013): Outdoor Webcams as Geospatial Sensor Networks: Challenges, Issues and Opportunities. *Cartography and Geographic Information Science*, 38, č. 1, s. 5–22.

BRADSKI, G. (2000): The OpenCV Library. *Dr. Dobb's Journal of Software Tools*, 120, 122–125.

BURGES, C. J. C. (1998): A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2, 2, s. 121–167.

CANNY, J. (1986): A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6, PAMI-8, s. 679–698.

COLBECK, S. C., AKITAYA, E., ARMSTRONG, R. L., GUBLER, H., LAFEUILLE, J., LIED, K., MCCLUNG, D. M., MORRIS, E. M. (1990): The International Classification for Seasonal Snow on the Ground. University of Colorado, Boulder, 23 s.

CORTES, C., VAPNIK, V. (1995): Support-Vector Networks. *Machine Learning*, 3, 20, 273–297.

DAVIES, E. R. (2018): Chapter 4 - The role of thresholding. Academic Press, s. 93–118.

DONG, CH. (2018): Remote sensing, hydrological modeling and in situ observations in snowcover research: A review. *Journal of Hydrology*, 561, s. 573–583.

ENQVIST, O., JIANG, F., KAHL, F. (2011): A brute-force algorithm for reconstructing a scene from two projections. *CVPR 2011*, Colorado Springs, CO, USA, s. 2961–2968.

FEDOROV, R., CAMERADA, A., FRATERNALI, P., TAGLIASACCHI, M. (2016): Estimating Snow Cover From Publicly Available Images. *IEEE Transactions on Multimedia*, 18, č. 6, s. 1187–1200.

FIERZ, C., ARMSTRONG, R. L., DURAND, Y., ETCHEVERS, P., GREENE, E., MCCLUNG, D. M., NISHIMURA, K., SATYAWALI, P. K., SOKRATOV, S. A. (2009): The International Classification for Seasonal Snow on the Ground. UNESCO-IHP, Paris, 80 s.

FOODY, G. M. (2009): Sample size determination for image classification accuracy assessment and comparison. *International Journal of Remote Sensing*, 20, 30, s. 5273–5291.

FOPPA, N., STOFFEL, A., MEISTER, R. (2007): Synergy of in situ and space borne observation for snow depth mapping in the Swiss Alps. *International Journal of Applied Earth Observation and Geoinformation*, 9, č. 3, s. 294–310.

GÉRON, A. (2017): *Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, Boston.

HALL, D. K., RIGGS, G. A., SALOMONSON, V. V., DIGIROLAMO, N. E., BAYR, K. J. (2002): MODIS snow cover products. *Remote Sensing of Environment*, 83, s. 181–194.

HINKLER, J., HANSEN, B. U. (2002): Automatic snow cover monitoring at high temporal and spatial resolution, using images taken by a standard digital camera. *International Journal of Remote Sensing*, 23, č. 21, s. 4669–4682.

HOBBS, P. V. (2010): *Ice Physics*. Oxford University Press, Don Mills, 856 s.

HUAMÁN, A. (2012): Image Processing: Canny Edge Detector. In: *OpenCV: Open Source Computer Vision*. [cit. 2019-20-07], URL: [https://docs.opencv.org/3.4/da/d5c/tutorial\\_canny\\_detector.html](https://docs.opencv.org/3.4/da/d5c/tutorial_canny_detector.html)

HUANG, Z. -K., CHAU, K. -W. (2008): A new image thresholding method based on Gaussian mixture model. *Applied Mathematics and Computation*, 2, 205, s. 899–907.

HUANG, Y., LIU, H., YU, B., WU, J., KANG, E. L., XU, M., WANG, S., KLEIN, A., CHEN Y. (2018): Improving MODIS snow products with a HMRF-based spatio-temporal modeling technique in the Upper Rio Grande Basin. *Remote Sensing of Environment*, 204, s. 568–582.

CHIH-CHUNG CHANG, CHIH-JEN LIN (2013): *LIBSVM: A Library for Support Vector Machines*. Taipei, Taiwan.

CHIH-WEI HSU, CHIH-CHUNG CHANG, CHIH-JEN LIN (2016): *A Practical Guide to Support Vector Classification*. Taipei 106, Taiwan.

IPCC (2013): *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge a New York, 1535 s.

JACOBS, N. a kol. (2009): *The Global Network of Outdoor Webcams: Properties and Applications*. ACM GIS '09.

JCGM 200 (2012): *International vocabulary of metrology — Basic and general concepts and associated terms (VIM)*, Joint Committee for Guides in Metrology. Český překlad:

Terminologie z oblasti metrologie. Úřad pro technickou normalizaci, metrologii a státní zkušebnictví, Praha.

KÄÄB, A., BOLCH, T., CASEY, K., HEID, T., KARGEL, J., J LEONARD, G., PAUL, F., RAUP, B. (2014): Glacier mapping and monitoring based on spectral data. In: Global land ice measurements from space. New York, Springer.

KEERTHI, S. S., LIN, C. -J. (2003): Asymptotic Behaviors of Support Vector Machines with Gaussian Kernel. *Neural Computation*, 7, 15, s. 1667–1689.

KIM, G.-H., RHIM, S., LEE, S.-G. (2007): Automated Visual Snow-Cover Measurement Using SRG and VMS. *International Journal of Computer Science*, 34, č. 1.

KOCH, M. (2011): Computer processing of remotely-sensed images. Wiley-Blackwell, Hoboken, NJ.

KOWALSKI, M. (2015): Dynamika vývoje sněhového pole „ Mapa republiky“ z neměřičských snímků. Bakalářská práce. Praha.

LAFFLY, D., BERNARD, É., GRISELIN, M., TOLLE, F., FRIEDT, J-M., MARTIN, G., MARLIN, C. (2012): High temporal resolution of snow cover using oblique view ground-based pictures. *Polar Record*, 48, č. 1, s. 11–16.

LIANG S., (2017): *Comprehensive Remote Sensing*. Elsevier, 3134 s.

LIM, S. H., KIM, G. H, LEE, S. G., RHIM, S. (2006): Internet-Based Visual Snow-Cover Monitoring and Measuring Systém. *SICE-ICASE International Joint Conference*, s. 3887–3890.

LUESSI, M., EICHMANN, M., SCHUSTER, G. M., KATSAGGELOS, A. (2009): Framework for efficient optimal multilevel image thresholding. *Journal of Electronic Imaging*, 18.

MATSON, M. (1991): NOAA satellite snow cover data. *Global and Planetary Change*, 4, č. 1–3, s. 213–218.

MOUNTRAKIS, G., IM, J., OGOLE, C. (2011): Support vector machines in remote sensing: A review: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, s. 247–259.

NALEPA, J., KAWULOK, M. (2019): Selecting training sets for support vector machines: a review: a review. *Artificial Intelligence Review*, 2, 52, s. 857–900.

NETOPIL, R. (1984): *Fyzická geografie*. Státní pedagogické nakladatelství, Praha, 272 s.

PEDREGOSA (2011): Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.

PROKOP, A. (2008): Assessing the applicability of terrestrial laser scanning for spatial snow depth measurements. *Cold Regions Sci. Technol.*, 54, č. 3, s. 155–163.

ROGOWSKA, J. (2009): Chapter 5 - Overview and Fundamentals of Medical Image Segmentation. Academic Press, Burlington, s. 73–90.

RONGE, L. Historie, současnost a budoucnost webových kamer ČHMÚ a jinde. [cit. 2019-20-07], URL:

[http://www.cmes.cz/sites/default/files/03\\_Ronge\\_Webov%C3%A9%20kamery.pdf](http://www.cmes.cz/sites/default/files/03_Ronge_Webov%C3%A9%20kamery.pdf)

RÜFENACHT, D., BROWN, M., BEUTEL, J., SÜSSTRUNK, S. (2014): Temporally consistent snow cover estimation from noisy, irregularly sampled measurements. In: 2014 International Conference on Computer Vision Theory and Applications (VISAPP), s. 275–283.

SALVATORI, R., PLINI, P., GIUSTO, M., VALT, M., SALZANO, R., MONTAGNOLI, M., CAGNATI, A., CREPAZ, G., SIGISMONDI, D. (2011): Snow cover monitoring with images from digital camera systems. Italian Journal of Remote Sensing, 43.

SEÇKIN, A. Ç., KARPUZ, C., ÖZEK, A. (2018): Feature matching based positioning algorithm for swarm robotics. Computers & Electrical Engineering, 67, s. 807–818.

SEZGIN, M., SANKUR, B. (2004): Survey over image thresholding techniques and quantitative performance evaluation. Journal of Electronic Imaging, 13, s. 146–168.

SHI, J., DOZIER, J., ROTT, H. (1994): Snow mapping in alpine regions with synthetic aperture radar. IEEE Trans. Geosci. Remote Sensing, 32, č. 1, s. 152–158.

SCHAEFER, V. J., KLEIN, G. J., DE QUERVAIN, M. R. (1954): The International Classification for Snow: With Special Reference to Snow on the Ground. Associate Committee on Soil and Snow Mechanics, National Research Council.

TOLASZ, R. (2007): Atlas podnebí Česka. Český hydrometeorologický ústav, Olomouc, Praha.

WENG, Q. (2011): Advances in Environmental Remote Sensing: Sensors, Algorithms, and Applications: Sensors, Algorithms, and Applications.

## Zdroje dat

ČHMÚ: Mapa webových kamer. [cit. 2019-20-07], URL:

<http://portal.chmi.cz/files/portal/docs/meteo/kam/>

Geoportál ČÚZK: Prohlížeč služba WMS – Ortofoto. [cit. 2019-20-07], URL:

[https://geoportal.cuzk.cz/\(S\(mwck2humdzgq3wx54bgml301\)\)/Default.aspx?mode=TextMeta&side=wms.verejne&metadataID=CZ-CUZK-WMS-ORTOFOTO-P&metadataXSL=metadata.sluzba&head\\_tab=sekce-03-gp&menu=3121](https://geoportal.cuzk.cz/(S(mwck2humdzgq3wx54bgml301))/Default.aspx?mode=TextMeta&side=wms.verejne&metadataID=CZ-CUZK-WMS-ORTOFOTO-P&metadataXSL=metadata.sluzba&head_tab=sekce-03-gp&menu=3121)

ArcČR 500 verze 3.2 [cit. 2016-03-27].

URL: [http://download.arcdata.cz/data/ArcCR\\_500-3.2-windows-installer.exe](http://download.arcdata.cz/data/ArcCR_500-3.2-windows-installer.exe)

## Přílohy

**Příloha 1:** Ukázka snímků použitých webkamer – referenční snímky pro sezonu 2019



Luční



Olomouc



Libuš



Jizerka



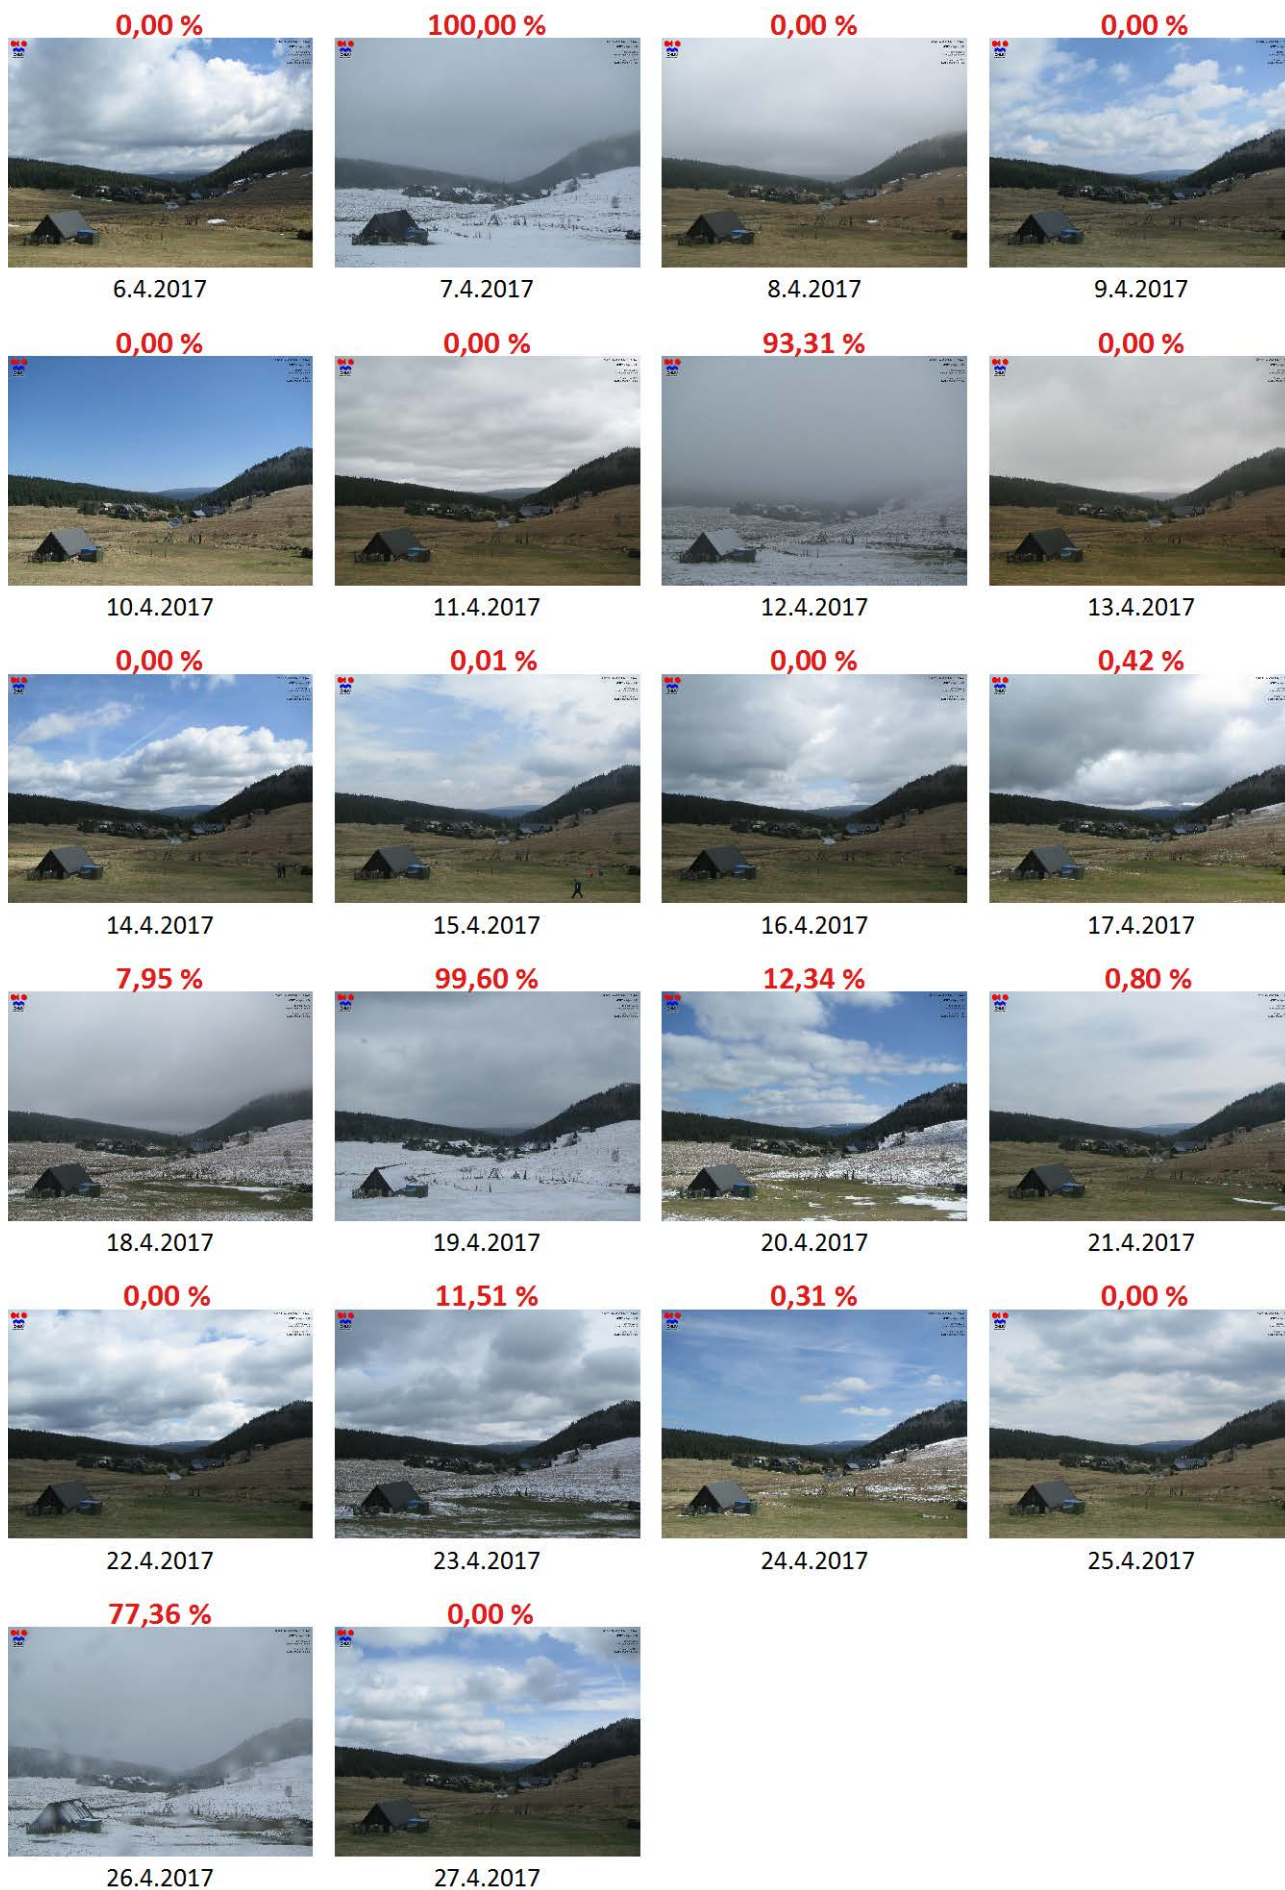
Nové Hrady



Turnov

Zdroj: ČHMÚ

**Příloha 2: Sněhem pokryté území – webová kamera Jizerka, duben 2017**



Zdroj: Autor, ČHMÚ