



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA STAVEBNÍ

FACULTY OF CIVIL ENGINEERING

## ÚSTAV GEODÉZIE

INSTITUTE OF GEODESY

# VYTĚŽOVÁNÍ SNÍMKŮ Z PANORAMATICKÉ KAMERY MOBILNÍHO MAPOVÁNÍ

EXPLOITATION OF IMAGES FROM PANORAMATIC CAMERA OF MOBILE MAPPING SYSTEM

## DIPLOMOVÁ PRÁCE

DIPLOMA THESIS

## AUTOR PRÁCE

AUTHOR

Bc. Pavel Belanis

## VEDOUCÍ PRÁCE

SUPERVISOR

Ing. TOMÁŠ VOLAŘÍK, Ph.D.

BRNO 2019



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA STAVEBNÍ

<b>Studijní program</b>	N3646 Geodézie a kartografie
<b>Typ studijního programu</b>	Navazující magisterský studijní program s prezenční formou studia
<b>Studijní obor</b>	3646R003 Geodézie a kartografie (N)
<b>Pracoviště</b>	Ústav geodézie

## ZADÁNÍ DIPLOMOVÉ PRÁCE

<b>Student</b>	Bc. Pavel Belanis
<b>Název</b>	Vytěžování snímků z panoramatické kamery mobilního mapování
<b>Vedoucí práce</b>	Ing. Tomáš Volařík, Ph.D.
<b>Datum zadání</b>	30. 11. 2018
<b>Datum odevzdání</b>	24. 5. 2019

V Brně dne 30. 11. 2018

---

doc. Ing. Radovan Machotka, Ph.D.

Vedoucí ústavu

---

prof. Ing. Miroslav Bajer, CSc.

Děkan Fakulty stavební VUT

## PODKLADY A LITERATURA

NOVÁČKOVÁ, Soňa. Testování přesnosti mobilního mapovacího systému MOMAS. Brno, 2011. 47 s., 27 s. příl. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav geodézie. Vedoucí práce doc. Ing. Vlastimil Hanzl, CSc.

DEUTSCH, Jiří. Mobilní mapování v architektuře. Brno, 2013. 56 s., 15 s. příl., Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav geodézie. Vedoucí práce doc. Ing. Vlastimil Hanzl, CSc.

KLIMEŠOVÁ, K. Pasportizace komunikací mobilním mapovacím systémem. Brno, 2011. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav geodézie. Vedoucí práce doc. Ing. Vlastimil Hanzl, CSc.

Manuály knihovny opencv dostupné online

## ZÁSADY PRO VYPRACOVÁNÍ

Proveďte rešerši odborné literatury tuzemské i zahraniční v oblasti vyhledávání prvků zájmu na snímcích pomocí počítačového vidění. Datovou sadu snímků z panoramatické kamery Ladybug 5 rozřídte a vytvořte sadu pozitivních a negativních vzorů pro vybraný typ prvku (například svislé dopravní značení).

Zvolte vhodný nástroj (knihovnu) a ze sady pozitivních a negativních vzorů vytrénujte klasifikátor. Klasifikátor ověřte na nezávislé datové sadě a proveďte vyhodnocení jeho úspěšnosti, zejména počet falešných nálezů.

Dále zvolte vhodný metodický postup, jak vytvořit datovou vrstvu GIS automatizovaně s využitím klasifikátoru a datové sady snímků. Tento postup ověřte na pilotní lokalitě. Přílohou práce bude výsledná datová sada GIS (například shapefile nebo geodatabáze) obsahující vybrané prvky -například svislé dopravní značení- vytvořené automatizovaně z datové sady panoramatických snímků.

## STRUKTURA DIPLOMOVÉ PRÁCE

VŠKP vypracujte a rozčleňte podle dále uvedené struktury:

1. Textová část VŠKP zpracovaná podle Směrnice rektora "Úprava, odevzdávání, zveřejňování a uchování vysokoškolských kvalifikačních prací" a Směrnice děkana "Úprava, odevzdávání, zveřejňování a uchování vysokoškolských kvalifikačních prací na FAST VUT" (povinná součást VŠKP).

2. Přílohy textové části VŠKP zpracované podle Směrnice rektora "Úprava, odevzdávání, zveřejňování a uchování vysokoškolských kvalifikačních prací" a Směrnice děkana "Úprava, odevzdávání, zveřejňování a uchování vysokoškolských kvalifikačních prací na FAST VUT" (nepovinná součást VŠKP v případě, že přílohy nejsou součástí textové části VŠKP, ale textovou část doplňují).

## **ABSTRAKT**

Tato diplomová práce se zabývá automatizovaným detekováním svislého dopravního značení ve snímcích z panoramatické kamery Ladybug5. Z detekovaného značení s pomocí klasifikátoru je vytvořena automatizovaným způsobem datová sada GIS, použitelná například k pasportizaci dopravního značení. V první části práce je popsán teoretický základ potřebný k pochopení zadané problematiky. Druhá část práce je věnována konkrétnímu postupu vedoucímu ke spolehlivému klasifikátoru, jeho testováním na nezávislé sadě snímků a automatizovaným vytvořením datové sady GIS. Výstupem práce jsou vytrénované klasifikátory a datové sady GIS obsahující svislé dopravní značení.

## **KLÍČOVÁ SLOVA**

mobilní mapování, pasportizace, detekce objektů, počítačové vidění, OpenCV, svislé dopravní značení

## **ABSTRACT**

This diploma thesis deals with an automated detection of vertical traffic signs in images from the panoramic camera Ladybug5. From the detected signs with help of a classifier, a GIS data set is automatically created, usable for example to passportisation of traffic signs. The first part of the thesis describes a theoretical basis needed to understand the given problematics. The second part is devoted to a specific procedure leading to the reliable classifier, its testing on an independent set of images and automated creation of the GIS data set. The output of the work are the trained classifiers and the GIS data sets containing vertical traffic signs.

## **KEYWORDS**

mobile mapping, passportisation, object detection, computer vision, OpenCV, vertical traffic signs

## **BIBLIOGRAFICKÁ CITACE VŠKP**

Bc. Pavel Belanis *Vytěžování snímků z panoramatické kamery mobilního mapování*. Brno, 2019. 54 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav geodézie. Vedoucí práce Ing. Tomáš Volařík, Ph.D.

## **PROHLÁŠENÍ O PŮVODNOSTI ZÁVĚREČNÉ PRÁCE**

Prohlašuji, že jsem diplomovou práci s názvem *Vytěžování snímků z panoramatické kamery mobilního mapování* zpracoval(a) samostatně a že jsem uvedl(a) všechny použité informační zdroje.

V Brně dne 21. 5. 2019

---

Bc. Pavel Belanis

autor práce

## **PODĚKOVÁNÍ**

Rád bych poděkoval vedoucímu své diplomové práce Ing. Tomášovi Volaříkovi, Ph.D. za poskytnuté podklady a rady v průběhu tvorby této práce. Dále bych chtěl poděkovat vyučujícím za získané informace a zkušenosti. V neposlední řadě bych rád poděkoval rodině a přítelkyni za podporu v průběhu celého studia.

Tato práce byla vytvořena v rámci aktivit a s podporou projektu TA ČR Centrum kompetence TE02000077 s názvem „Inteligentní Regiony – Informační modelování budov a sídel, technologie a infrastruktura pro udržitelný rozvoj“.

## OBSAH

1	ÚVOD .....	10
2	TEORETICKÁ ČÁST .....	11
2.1	Počítačové vidění .....	11
2.2	Zpracování obrazu.....	11
2.3	Vyhledání objektů zájmu v obraze.....	12
2.4	OpenCV .....	14
2.4.1	HAAR .....	15
2.4.2	LBP .....	15
2.4.3	HOG.....	16
2.4.4	AdaBoost.....	16
2.4.5	Kaskáda klasifikátorů.....	16
2.4.6	Trénování zesílené kaskády slabých klasifikátorů .....	17
2.5	Pasportizace dopravního značení na pozemních komunikacích .....	22
2.5.1	Pasportizace.....	22
2.5.2	Dopravní značení na pozemních komunikacích.....	23
3	PRAKTICKÁ ČÁST.....	25
3.1	Použité vybavení .....	25
3.1.1	Mobilní mapovací systém RIEGL VMX - 450.....	25
3.1.1.1	Komponenty systému.....	26
3.1.2	Cascade Trainer GUI.....	29
3.2	Příprava trénovacích dat.....	31
3.3	Trénování kaskády klasifikátorů .....	32
3.3.1	Experimentální pokusy volby parametrů tréninku .....	33
3.4	Testování spolehlivosti klasifikátoru .....	38
3.4.1	Sběr dat .....	38
3.4.2	Testování klasifikátoru.....	39



3.4.3	Návrh zlepšení spolehlivosti klasifikátorů .....	41
3.5	Tvorba datové vrstvy GIS .....	42
3.5.1	Úprava vstupních snímků.....	43
3.5.2	Postup práce v programu QGIS .....	44
3.6	Zhodnocení výsledků práce.....	46
4	ZÁVĚR .....	47
	SEZNAM POUŽITÉ LITERATURY .....	48
	SEZNAM POUŽITÝCH ZKRATEK .....	51
	SEZNAM OBRÁZKŮ A TABULEK .....	52
	SEZNAM ELEKTRONICKÝCH PŘÍLOH .....	54

# 1 ÚVOD

Snahou neustálého vývoje zařízení a softwaru v oblasti informačních technologiích je nahradit lidský faktor automatizovanou činností prováděnou počítačem. Nejvíce se tomu blíží vývoj v oblasti počítačového vidění, jehož hlavní snahou je pomocí technických prostředků nahradit lidský zrak. Cílem počítačového vidění je získat co největší objem informací obsažených v pořízeném snímku. V praxi se můžeme setkat s detekcí a sledováním objektů v obraze, tvorbou modelů na základě snímků a mnoho dalších.

Počítačové vidění má vysoké využití v nejrůznějších odvětvích. V průmyslu jej lze využít při kontrole geometrických parametrů výrobků. Z bezpečnostního hlediska ho lze využít při rozpoznání obličejů, rozpoznání registračních značek automobilů nebo k řízení autonomních vozidel.

Z geodetického hlediska se práce zabývá využitím mobilních mapovacích systémů ke sběru dat a následnému automatizovanému zpracování pro účely pasportizace. Výstupem mobilního mapování je velký objem dat, který je při ručním zpracování vysoce časově náročný. Snahou je vymyslet postup, který by propojil mobilní mapování s počítačovým viděním, a tím minimalizoval zpracování dat člověkem a snížil časovou náročnost.

Cílem diplomové práce je vytvoření spolehlivého klasifikátoru schopného detekovat ze snímků pořízených mobilním mapovacím systémem svislé dopravní značení. Z detekovaného značení dále vytvořit datovou sadu Geografického informačního systému (dále jen GIS) použitelnou k pasportizaci svislého dopravního značení.

Práci lze rozdělit do dvou částí. První část se věnuje teoretickému popisu problematiky vyhledání objektů zájmu v obraze. Jsou zde popsány poznatky týkající se počítačového vidění, knihovny Open source computer vision library (dále jen OpenCV), teoretického postupu trénování klasifikátoru a problematiky pasportizace. Druhá část je věnována praktickému postupu naplnění cíle této práce. Prvním krokem je pečlivě roztřídit snímky z panoramatické kamery Ladybug5 (výrobce PointGrey, potom FLIR) a vytvořit sady pozitivních a negativních vzorů. Na základě sad vzorů vytrénovat spolehlivý klasifikátor použitelný pro další zpracování. Druhá část praktické kapitoly je věnována testování spolehlivosti vytvořeného detektoru a jeho použití při automatizovaném vytvoření datové vrstvy GIS.

## 2 TEORETICKÁ ČÁST

Tato kapitola práce popisuje teoretický základ k pochopení problematiky diplomové práce. V první části je přiblížena oblast počítačového vidění s vyhledáním objektů zájmu v obraze. Dále je teoreticky popsán postup tréninku kaskády klasifikátorů s využitím knihovny OpenCV. V závěru této kapitoly jsou teoretické poznatky problematiky pasportizace a dopravního značení.

### 2.1 Počítačové vidění

Počítačové vidění lze chápat jako vědní disciplínu, která se pomocí technických prostředků a znalostí, snaží co nejlépe napodobit lidské vidění. Pro člověka je vnímání okolního světa přirozenou činností, jak získávat informace pomocí smyslů. Vyhodnocení takových informací závisí na inteligenci konkrétního jedince a na předchozích zkušenostech. Počítač však tyto přirozené schopnosti nemá a je závislý na principech, které ho naučíme. Tímto počítačovým učením se zabývá výzkum v oblasti počítačového vidění [1].

### 2.2 Zpracování obrazu

Ke zpracování obrazu s případným rozpoznáním objektů potřebuje počítač obrazovou informaci, kterou nejčastěji získá z kamery. Rozlišují se dvě úrovně zpracování obrazu, které spolu navzájem souvisejí. Nižší úroveň je chápáno jednoduché zpracování obrazu pomocí základních operací s obrazem, např. na základě barvy, jasu a šumu. Cílem nižší úrovně je analýza obrazových dat a získání potřebných informací pro vyšší úroveň. Vyšší úroveň je proces porozumění obsahu obrazu. Je to finální produkt počítačového vidění, který předpokládá určitou znalost problematiky a využití umělé inteligence.

#### **Základní kroky zpracování obrazu:**

1. Pořízení snímku a převedení do počítače
2. Předzpracování obrazu
3. Rozpoznání objektů v obraze a jejich segmentace
4. Popis rozpoznaných objektů
5. Porozumění obsahu obrazu (klasifikace objektů)

K pořízení snímků lze využít libovolný přístroj se snímačem obrazových prvků. Mezi nejpoužívanější jsou řazeny snímače Charge-Coupled Device (dále jen CCD) a Complementary metal-oxide semiconductor (zkratka CMOS). V principu jde o převedení optické veličiny na elektrický signál. Tento signál se dále digitalizuje a ve formě 0 a 1 v matici se uloží do paměti počítače. Obraz může být v jednom nebo více spektrálních pásmech. Pro barevné obrazy se používá model červená, zelená, modrá (dále jen RGB).

Procesem předzpracování se potlačuje šum a zkreslení vzniklé při digitalizaci snímku. Mezi metody lze zařadit vyhlazování, prahování, rozmazání, detekci hran, převedení obrazu na stupně šedi (dále jen GRAY) nebo jednoduchou úpravu jasu a kontrastu obrazu. Čím je obraz větší a čím více barev obsahuje, tím větší je jeho obrazová informace a doba zpracování.

Ve třetím kroku je obraz rozčleněn na jednotlivé objekty. Z rozčleněných objektů jsou vybrány ty, které jsou z pohledu dalšího zpracování zajímavé. Z pohledu počítačového vidění jde o nejsložitější část zpracování obrazu.

Popis objektů je vyjádření kvantitativní nebo kvalitativní charakteristiky, na základě kterých lze jednotlivé objekty identifikovat. Mezi jednoduchý popis objektů jsou řazeny údaje o velikosti, barvě a jasu. U složitějšího popisu jsou uvažovány vzájemné vztahy mezi objekty.

Posledním krokem a zároveň cílem zpracování obrazu je porozumění jeho obsahu. Nejjednodušší formou je rozdělení objektů podle velikostí. Další vhodnou metodou je klasifikace objektů do předem stanovených tříd. Každá třída je podmnožinou objektů, které spojují společné rysy [1].

## **2.3 Vyhledání objektů zájmu v obraze**

Rozpoznání a následná klasifikace objektů v obrazech je náročný úkol, kterým se neustále zabývá výzkum v oblasti počítačového vidění. V praxi se setkáváme s nejrůznějšími typy detektorů, počínaje detekcí jednoduchých předmětů až po detektory, které jsou schopny rozpoznat v obraze složité a proměnlivé objekty, např. lidské tváře. Cílem vývoje je vytvořit spolehlivý a finančně nenáročný klasifikátor. Tato kapitola popisuje současný stav v oblasti vyhledání objektů a příklady publikovaných detektorů.

Nejznámějším detektorem je detektor obličejů publikovaný v roce 2001. Jeho autory jsou P. Viola a M. Jones. Detektor Viola – Jones, uváděný i jako Haarův klasifikátor, byl v oblasti detekce průlomový pro zavedení 3 klíčových principů: zavedení nové obrazové reprezentace „Integrální obraz“, použití algoritmu Adaptive Boosting (dále jen AdaBoost) a postupné skládání

jednotlivých slabých klasifikátorů do kaskády. Těmito principy se výrazně zkracuje čas zpracování a detekce objektů v obraze. Detektor byl vytrénován ve 38 stupních kaskády, bylo použito 9 832 pozitivních vzorů o rozměrech 24x24 pixelů a 10 000 negativních vzorů o stejných rozměrech. Použité vzory byly ve stupních šedi. Vyhodnocení obrazu velikosti 384x288 pixelů trvá 0,067 sekundy, což je 15 snímků za sekundu (použitý procesor Pentium III, 700 Mhz). Nezávislý test byl proveden na 130 obrazech obsahujících 507 tváří. Výsledkem je přesnost detekce 95 % [2].

Další detektor, tentokrát k vyhledání lidských postav, byl publikován v roce 2005 N. Dalalem a B. Triggsem. Při tvorbě klasifikátoru byly poprvé použity příznaky histogramů orientovaných gradientů. V testovací sadě bylo obsaženo 2 478 vzorů chodců v nejrůznějších polohách a s proměnlivým pozadím. Negativních vzorů bylo 12 180. Byla dosažena míra přesnosti detekce 95 % a sníženy falešně pozitivní nálezy oproti Viola-Jones klasifikátoru [3].

P. Wilson a Dr. J. Fernandez publikovali v roce 2006 detektor založený na Viola – Jones detektoru lidských tváří, kde dále klasifikovali jednotlivé části obličeje. Ve své práci poprvé použili knihovnu OpenCV. Pro každou část tváře bylo použito 1 500 pozitivních vzorů a 5 000 negativních vzorů. Byla prokázána míra přesnosti detekce 73 % pro oči, 100 % pro nos a 67 % pro ústa a poměrně vysoká míra falešně pozitivních nálezů v průměru 28 % [4].

V diplomové práci od M. Šebely je popsán postup detekce objektů ve videosekvencích. Práce se zabývá zpracováním obrazu, rozpoznáním objektů v obraze pomocí detekce hran prahováním a optickým rozpoznáváním znaků. Výsledkem práce je rozpoznání státních poznávacích značek v obraze s následným vyhodnocením jednotlivých znaků. Úspěšnost správné detekce registrační značky je 88 %. Detektor je primárně určen pro správu vjezdu do objektů [5].

Detekcí a rozpoznáním objektů v obraze a videosekvencích se zabývá česká firma Eyedea Recognition s. r. o. Mezi nejzajímavější produkty firmy lze zařadit detekci a rozpoznání lidského obličeje v obraze s následným vyhodnocením doplňujících charakteristik jako pohlaví a věk, nebo detekci vozidel s rozpoznáním typu, modelu a výrobce vozidla. Dalším zajímavým produktem společnosti je Anonymizer obrazových dat, který umí detekovat lidské obličeje a registrační značky na fotografiích a následně je rozmazat. Tato anonymizace je viditelná zejména na mapových portálech, které prezentují panoramatické snímky. Ve snímcích se z důvodu ochrany soukromí nesmí vyskytovat tyto citlivé údaje. Jako poslední stojící za zmínku je software ke čtení registračních značek využitelný pro mýtné systémy, úsekové měření rychlosti, kontrolu dodržování dopravních pravidel, a také sledování vjezdu do městských zón [6].

## 2.4 OpenCV

OpenCV je volně šiřitelná knihovna pod licencí Berkeley Software Distribution (dále jen BSD) napsaná v programovacím jazyku C a C++. BSD je licence pro svobodný software, což dělá z knihovny jednu z nejrozšířenějších i pro její použitelnost na operačních systémech Linux, Windows i Mac OS. Knihovna obsahuje několik stovek algoritmů pro zpracování obrazu a jiné aplikace z oblasti počítačového vidění. Knihovna má modulární strukturu obsahující několik sdílených nebo statických knihoven.

### Základní části knihovny:

- Core – modul definující základní datové struktury a základní funkce
- Image processing – modul pro zpracování obrazu (filtrace, transformace, histogramy, barevné modely)
- Video – modul pro analýzu videa a algoritmy sledování objektů
- Calib3d – modul s algoritmy pro prostorovou geometrii, kalibraci kamer
- Features2d – modul s detektory
- Objdetect – modul pro detekci objektů v obraze na základě předdefinovaných tříd
- Highgui – modul popisující uživatelské rozhraní
- Video I/O – modul pro video kodeky
- GPU – akcelerované algoritmy pro rychlejší práci grafického procesoru

Mezi další výhody knihovny řadíme možnost extrakce příznaků objektu pomocí příznakových detektorů a využití algoritmu AdaBoost k sestavení kaskády klasifikátorů. Příznaky objektu lze chápat jako měřitelné fyzikální veličiny spojené s daným objektem. Mezi základní příznaky lze zařadit hranu, roh a oblouk. Algoritmus AdaBoost je blíže popsán v kapitole 2. 4. 4. Souhrn jmenovaných vlastností a algoritmů dělá z knihovny OpenCV účinný nástroj ke zpracování obrazu a detekci objektů v obraze.

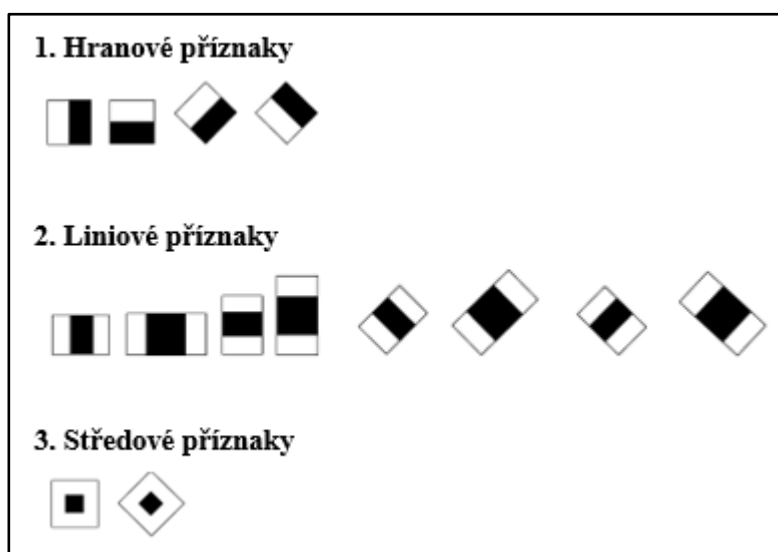
### Základní příznakové detektory:

- Haarovy příznaky (dále jen HAAR)
- Lokální binární vzory (dále jen LBP)
- Histogramy orientovaných gradientů (dále jen HOG)

Knihovna OpenCv byla vybrána pro její bezplatnou dostupnost, propracovanou dokumentaci a velký počet návodů, jak s knihovnou pracovat [7].

## 2.4.1 HAAR

Haarovy příznaky jsou základním prvkem k vytvoření Harrova klasifikátoru. Princip je založen na změnách hodnot kontrastu sousedních obdélníkových oblastí namísto klasického přístupu změny hodnot intenzit jednotlivých pixelů. Příznak vznikne složením dvou a více obdélníkových oblastí. Z rozdílů kontrastu mezi obdélníky lze snadno rozeznat světlé a tmavé oblasti v obraze. Tím je výrazně snížena doba potřebná k rozpoznání objektu. Výhodou je také variabilita velikostí a natočení příznaků a s tím spojená detekce objektů různých velikostí [4].



Obr. 1 Haarovy příznaky [4]

Nejčastěji je použita velikost detekčního okna 24x24 pixelů. V obraze této velikosti lze nalézt 180 000 příznaků. Příznaky se generují na základě posunu detekčního okna po obraze v horizontálním nebo vertikálním směru. Pokud detekční okno projde celý obraz, zvětší se jeho velikost a postup se opakuje, dokud není velikost okna větší než velikost obrazu. Ke snížení doby odezvy příznaku se používá mezilehlá reprezentace původního obrazu (Integrální obraz), který je definovaný jako součet pixelů oblastí ve směrech nahoru a doleva od aktuální pozice [4].

## 2.4.2 LBP

LBP je jednoduchý a velice účinný klasifikátor pracující s texturou obrazu. Při zpracování textury označí prahováním všechny sousedy vybraných pixelů a převede je na binární číslo, což považuje za výsledek. Výhodami detektoru jsou jednoduché analýzy textur obrazu, nenáročné výpočty a jeho robustnost vůči špatným světelným podmínkám v obraze. Tyto vlastnosti dělají z LBP často používaný klasifikátor i pro jeho nízkou časovou náročnost [8].

### 2.4.3 HOG

Příznakový detektor HOG je založen na vyhodnocení normalizovaných lokálních histogramů orientace gradientů. Charakterizuje vzhled a tvar objektu v jednotlivých částech obrazu pomocí lokálních gradientů intenzity a směrů hran. Postup je založený na rozdělení obrazu na malé oblasti, kde každá oblast je reprezentována jednorozměrným histogramem nebo směrem hran procházejících jednotlivými pixely. Jde tedy o zobrazení největší změny intenzity v malých oblastech. V dalším kroku je obraz překryt hustou mřížkou příznaků v kombinaci s hranami. Důležité je použít barevné spektrum bez korekce a vyhlazení [3].

### 2.4.4 AdaBoost

AdaBoost je založený na výběru malého počtu důležitých příznaků. V obraze se může vyskytnout daleko větší počet příznaků než je jednotlivých pixelů. K zajištění rychlé a efektivní klasifikace vyloučí algoritmus většinu extrahovaných příznaků a zaměří se pouze na malou sadu kritických. Tím je vytvořen silný příznak, který je složen z několika slabých. AdaBoost zaručuje vázanost slabého klasifikátoru pouze na jeden prvek [2].

### 2.4.5 Kaskáda klasifikátorů

Hlavní výhodou postupného skládání slabých klasifikátorů do kaskády je zvýšení rychlosti detekce. To je realizováno na základě zaměření detekce a komplexnějšího zpracování pouze v pozitivní oblasti obrazu, kde se předpokládá výskyt hledaného objektu. Klasifikátory jsou v kaskádě skládány do několika stupňů vždy od nejjednoduššího po nejsložitější. Výběr pozitivní oblasti funguje na principu rozhodovacího stromu, kdy je obraz zpracován prvním stupněm kaskády a je rozhodnuto, zda se jedná o pozitivní nebo negativní oblast. Podokno s negativní oblastí je okamžitě vyřazeno z dalšího zpracování. V dalších krocích je na oblast aplikován vyšší stupeň, až po nejvyšší stupeň kaskády. Struktura kaskády předpokládá, že většina podoken v obraze je negativních, proto je snahou odmítnout co nejvíce negativních oblastí hned na začátku. Jako hledané objekty jsou vyhodnoceny oblasti, které projdou celou kaskádou bez vyřazení [2].



## 2.4.6 Trénování zesílené kaskády slabých klasifikátorů

Postup k vytrénování kaskády klasifikátorů se dá rozdělit do dvou hlavních částí: trénování a detekce. K trénování a následné detekci lze použít jeden z modelů extrakce příznaků HAAR, LBP nebo HOG. Z časového hlediska je výhodné použít model LBP, kdy trénování i detekce je několikrát rychlejší než u zbylých dvou modelů. Kvalitativně je na tom nejlépe model HAAR. Model HOG není v praxi tak často používán. Kvalita a spolehlivost kaskády závisí především na trénovacích datech a zvolených parametrech tréninku [9]. Obecně při použití vyššího počtu vzorů se zvýší spolehlivost detekce a sníží riziko počtu falešně pozitivních nálezů. S takto vzrůstajícím počtem vzorů však vzrůstá i výpočetní čas tréninku. Najít kompromis mezi počtem vzorů a rychlostí tréninku je i v dnešní době obtížný úkol [2].

### **Postup trénování se skládá z následujících částí:**

- Příprava tréninkových dat
- Vytvoření sady negativních a pozitivních vzorů
- Trénování kaskády
- Ověření kaskády a detekce

Data pro trénování zesílené kaskády slabých klasifikátorů musí být rozdělena do dvou skupin. První skupinu tvoří pozitivní vzory obsahující všechny objekty, které mají být detekovány. Druhou skupinu tvoří negativní vzory, které obsahují všechny ostatní objekty, kromě těch pozitivních. Je velice důležité, aby negativní sada neobsahovala žádný pozitivní vzor. Sada negativních vzorů musí být vytvořena ručně, pozitivní vzory se mohou vytvořit pomocí aplikace `opencv_createsamples`.

Negativní vzory mohou být různé velikosti. Jejich relativní nebo absolutní cesty jsou jednotlivými řádky textového souboru `bg.txt`. Pro negativní vzory je doporučena stejná nebo větší velikost, než je velikost pozitivních vzorů.

K vytvoření sady pozitivních vzorů jsou dvě možnosti: vytvořit sadu z jednoho obrazu nebo vytvořit vlastní sadu různých obrazů. K vytrénování kvalitní kaskády je doporučeno vytvoření vlastní sady skládající se z různých obrazů. K vytvoření sady podle první možnosti lze využít aplikaci `opencv_createsamples`, ve které lze jednoduchými úpravami vstupního obrazu vytvořit tisíce pozitivních vzorů. Mezi tyto úpravy patří rotace kolem všech tří os  $x$ ,  $y$ ,  $z$ , změna intenzity obrazu nebo přidání pozadí pod obraz [9].

```

Usage: opencv_createsamples
[-info <collection_file_name>]
[-img <image_file_name>]
[-vec <vec_file_name>]
[-bg <background_file_name>]
[-num <number_of_samples = 1000>]
[-bgcolor <background_color = 0>]
[-inv] [-randinv] [-bgthresh <background_color_threshold = 80>]
[-maxidev <max_intensity_deviation = 40>]
[-maxxangle <max_x_rotation_angle = 1.100000>]
[-maxyangle <max_y_rotation_angle = 1.100000>]
[-maxzangle <max_z_rotation_angle = 0.500000>]
[-show [<scale = 4.000000>]]
[-w <sample_width = 24>]
[-h <sample_height = 24>]
[-maxscale <max sample scale = -1.000000>]
[-rngseed <rng seed = 12345>]

```

Obr. 2 Parametry aplikace `opencv_createsamples` [vlastní tvorba]

Tab. 1 Stručný popis parametrů aplikace `opencv_createsamples` [vlastní tvorba]

<code>-info &lt;název_souboru&gt;</code>	název vstupního souboru s vytvořenou sadou pozitivních vzorů
<code>-img &lt;název_souboru&gt;</code>	název zdrojového obrazu k vytvoření pozitivních vzorů
<code>-vec &lt;název_souboru&gt;</code>	název výstupního vektorového souboru s pozitivními vzory
<code>-bg &lt;název_souboru&gt;</code>	název vstupního souboru s negativními vzory
<code>-num &lt;počet = 1000&gt;</code>	počet pozitivních vzorů, které mají být vytvořeny
<code>-bgcolor &lt;barva = 0&gt;</code>	barva pozadí
<code>-bgthresh &lt;hodnota = 80&gt;</code>	práh barvy pozadí
<code>-inv &lt;barva&gt;</code>	zadané barvy budou invertovány
<code>-randinv</code>	náhodné barvy budou invertovány
<code>-maxidev &lt;hodnota = 40&gt;</code>	maximální intenzita pixelů ve vzorech popředí
<code>-maxxangle &lt;hodnota = 1,1&gt;</code>	maximální úhel natočení vzoru kolem osy x v radiánech
<code>-maxyangle &lt;hodnota = 1,1&gt;</code>	maximální úhel natočení vzoru kolem osy y v radiánech
<code>-maxzangle &lt;hodnota = 0,5&gt;</code>	maximální úhel natočení vzoru kolem osy z v radiánech
<code>-show &lt;měřítko = 4&gt;</code>	zobrazení jednotlivého vzoru v měřítku
<code>-w &lt;velikost = 24&gt;</code>	šířka výstupních vzorů v pixelech
<code>-h &lt;velikost = 24&gt;</code>	výška výstupních vzorů v pixelech
<code>-maxscale &lt;hodnota = -1&gt;</code>	maximální měřítko
<code>-rngseed &lt;hodnota = 12345&gt;</code>	číslo použité ke generování pseudonáhodných čísel

Poznámka k tabulce: hodnoty uvedené v závorkách jsou výchozím nastavením aplikace

Druhou možností vytvoření vektorového souboru (`.vec`) s pozitivními vzory je vytvoření sady pozitivních vzorů na základě různých obrazů. Cesty k obrazům jsou uloženy v textovém souboru `info.dat`. K vytvoření sady pozitivních vzorů na základě tohoto souboru je třeba v aplikaci

nahradit parametr *-img* parametrem *-info*. V tomto postupu jsou ignorovány parametry *-bg*, *-bgcolor*, *-maxangle*, *-inv*, *-bgthresh*. Aplikace pouze vyřizne hledaný vzor podle ohraničujícího obrazce a změní velikost šířky a výšky podle zadaných parametrů *-w*, *-h*. Struktura jednotlivých řádků v souboru je následující:

```
img/1.png 1 10 10 24 24
img/2.png 1 30 20 24 24
```

kde *img/1.png* je relativní cesta k obrazu, první hodnota je počet výskytů pozitivního vzoru v obraze, druhá a třetí hodnota jsou souřadnice levého dolního rohu čtverce nebo obdélníku a čtvrtá a pátá hodnota je v tomto případě šířka a výška čtverce ohraničující pozitivní vzor.

Další užitečnou aplikací knihovny OpenCV je *opencv\_annotation*. Tento nástroj slouží pro generování textového souboru *annotation.txt* pomocí grafického rozhraní, ve kterém uživatel prochází jednotlivé obrazy a vybírá hledané vzory. Vzory jsou vybírány pomocí výběrové množiny realizované kurzorem myši. Anotace je potvrzena a zapsána do textového souboru po stisknutí klávesy *C*. Klávesou *D* dojde k vymazání poslední uložené anotace. K přechodu na další obraz slouží klávesa *N*. Opustit tvorbu anotací lze klávesou *ESC*. Výsledkem je textový soubor *annotation.txt*, který lze použít obdobně jako soubor *info.dat* v aplikaci *opencv\_createsamples* [9].

```
Usage: opencv_annotation [params]
    -?, -h, --help, --usage
        show this message
    -a, --annotations
        (required) path to annotations txt file [example - /data/annotat
ions.txt]
    -i, --images
        (required) path to image folder [example - /data/testimages/]
    -m, --maxWindowHeight (value:-1)
        (optional) images larger in height than this value will be scale
d down
    -r, --resizeFactor (value:2)
        (optional) factor for scaling down [default = half the size]
```

Obr. 3 Parametry aplikace *opencv\_annotation* [vlastní tvorba]

Tab. 2 Stručný popis povinných parametrů aplikace *opencv\_annotation* [vlastní tvorba]

-a = <název_souboru>	název textového souboru s anotacemi
-i = <složka_souborů>	cesta ke složce s obrazy

Závěrečným krokem trénování zesílené kaskády slabých klasifikátorů je aplikace `opencv_traincascade`. Aplikace pracuje se soubory vytvořenými v předešlých aplikacích. Vstupem je vektorový soubor (`.vec`) s pozitivními vzory a textový soubor obsahující negativní vzory (`bg.txt`). Výsledkem celého procesu trénování je soubor `cascade.xml` s vytrénovanou kaskádou, uložený v předdefinované složce. Ve složce je dále uložen soubor `params.xml` obsahující informace o nastavených parametrech tréninku a výsledky jednotlivých stupňů tréninku jako soubory `stageX.xml`, kde X je označení ukončeného stupně z celkového počtu stupňů zvolených před tréninkem. Každý následující stupeň kaskády je trénován ze vzorů, které prošly všemi předchozími stupni tréninku. Trénování je ukončeno po dosažení posledního stupně tréninku nebo dříve, pokud maximální procento falešně pozitivních vzorů klesne pod stanovenou hodnotu [9].

```
Usage: opencv_traincascade
  -data <cascade_dir_name>
  -vec <vec_file_name>
  -bg <background_file_name>
  [-numPos <number_of_positive_samples = 2000>]
  [-numNeg <number_of_negative_samples = 1000>]
  [-numStages <number_of_stages = 20>]
  [-precalcValBufSize <precalculated_vals_buffer_size_in_Mb = 1024>]
  [-precalcIdxBufSize <precalculated_idxs_buffer_size_in_Mb = 1024>]
  [-baseFormatSave]
  [-numThreads <max_number_of_threads = 9>]
  [-acceptanceRatioBreakValue <value> = -1]
--cascadeParams--
  [-stageType <BOOST(default)>]
  [-featureType <{HAAR(default), LBP, HOG}>]
  [-w <sampleWidth = 24>]
  [-h <sampleHeight = 24>]
--boostParams--
  [-bt <{DAB, RAB, LB, GAB(default)}>]
  [-minHitRate <min_hit_rate> = 0.995]
  [-maxFalseAlarmRate <max_false_alarm_rate = 0.5>]
  [-weightTrimRate <weight_trim_rate = 0.95>]
  [-maxDepth <max_depth_of_weak_tree = 1>]
  [-maxWeakCount <max_weak_tree_count = 100>]
--haarFeatureParams--
  [-mode <BASIC(default) | CORE | ALL>]
--lbpFeatureParams--
--HOGFeatureParams--
```

Obr. 4 Parametry aplikace `opencv_traincascade` [vlastní tvorba]

Tab. 3 Stručný popis parametrů aplikace `opencv_traincascade` [vlastní tvorba]

-data <název_složky>	složka, kam budou ukládány výsledky tréninku
-vec <název_souboru>	název vektorového souboru s pozitivními vzory
-bg <název_souboru>	název souboru s negativními vzory
-numPos <počet = 2000>	počet pozitivních vzorů, použitých pro trénink
-numNeg <počet = 1000>	počet negativních vzorů, použitých pro trénink
-numStages <počet = 20>	počet stupňů tréninku
-precalcValBufSize <velikost = 1024>	velikost paměti RAM počítače uvolněná pro trénink

-precalcIdxBufSize <velikost = 1024>	velikost paměti RAM počítače uvolněná pro trénink
-baseFormatSave	uložení kaskády ve starém formátu
-numThreads <počet = 9>	maximální počet vláken použitých k tréninku
-acceptRatioBreakValue <hodnota = -1>	prahová hodnota tréninku, po dosažení zadané hodnoty je trénink ukončen
-stageType <typ = BOOST>	typ jednotlivých stupňů tréninku
-featureType <typ = HAAR>	typ příznaků (HAAR, LBP, HOG)
-w <velikost = 24>	šířka tréninkových vzorů v pixelech
-h <velikost = 24>	výška tréninkových vzorů v pixelech
-bt <typ = GAB>	typ zesílených klasifikátorů (DAB, RAB, LB, GAB)
-minHitRate <hodnota = 0,995>	minimální procento pozitivních nálezů (99, 5 %)
-maxFalseAlarmRate <hodnota = 0,5>	maximální procento falešně pozitivních nálezů (0, 5 %)
-weightTrimRate <hodnota = 0,95>	hodnota hmotnostního oříznutí
-maxDepth <hodnota = 1>	maximální hloubka slabého stromu
-maxWeakCount <hodnota = 100>	maximální počet slabých stromů pro každý stupeň
-mode <typ = BASIC>	typ použité sady funkcí BASIC, CORE, ALL

*Poznámka k tabulce: hodnoty uvedené v závorkách jsou výchozím nastavením aplikace*

Aplikaci `opencv_traincascade` je ukončena první z hlavních částí tvorby klasifikátoru. Druhá část je o testování a vizualizaci vytrénovaného klasifikátoru. K tomuto účelu je součástí knihovny OpenCV aplikace `opencv_visualisation`. Aplikaci se dá otestovat pouze klasifikátor vytvořený pomocí aplikace `opencv_traincascade` [9].

```
Usage: opencv_visualisation [params]
  -?, -h, --help, --usage
    show this message
  -d, --data
    (optional) path to video output folder
  -i, --image
    (required) path to reference image
  -m, --model
    (required) path to cascade xml file
```

*Obr. 5 Parametry aplikace `opencv_visualisation` [vlastní tvorba]*

*Tab. 4 Stručný popis povinných parametrů aplikace `opencv_visualisation` [vlastní tvorba]*

-i = <název_souboru>	cesta k testovanému obrazu
-m = <název_souboru>	cesta ke klasifikátoru <code>cascade.xml</code>

## **2.5 Pasportizace dopravního značení na pozemních komunikacích**

### **2.5.1 Pasportizace**

Pasportizace je proces sběru, zpracování a vyhodnocení dat použitelných při spravování majetku. Pasportizací evidujeme informace o technickém stavu předmětných objektů, které jsou dále využitelné k plánování údržby, modernizace a obnovy objektů nebo k získávání dalších technicko – ekonomických parametrů.

#### **Základní výsledky pasportizace:**

- Ekonomická stránka předmětu
- Technická stránka předmětu
- Náklady na údržbu, opravy a obnovu
- Hodnocení životnosti předmětu

#### **Základní druhy pasportů:**

- Prostorový – popis venkovních ploch a přilehlých objektů
- Stavební – popis budov z hlediska konstrukčního uspořádání
- Technický – popis majetku, vybavení a inventáře z hlediska evidenčního
- Technologický – popis vnitřních technologií budov a zařízení

#### **Nejčastější typy pasportů:**

- Pasport místních komunikací
- Pasport veřejného osvětlení
- Pasport zeleně
- Pasport hřbitova
- Pasport dopravního značení
- Pasport kanalizace

Mimo tyto základní druhy je dále rozšířen personální pasport firem, které mají velký počet zaměstnanců. V dokumentaci pasportu najdeme základní informace o zaměstnancích, jejich úkolech a pracovní době [10].

Pasportizaci dopravního značení zařadíme z hlediska základního rozdělení do technického pasportu. Tento pasport je zhotovován především pro organizace spravující dopravní infrastrukturu. V dokumentu se nachází soupis, popis a poloha jednotlivých prvků dopravního značení, odpovídající jeho skutečnému technickému stavu a poloze v terénu. Takto zjištěné informace mohou být dále použity k plánování údržby, kontrole nebo případnému projektování nového značení.

## 2.5.2 Dopravní značení na pozemních komunikacích

Každý účastník silničního provozu se musí řídit pravidly stanovenými právními předpisy. Základní právní předpisy upravující provoz na pozemních komunikacích jsou Zákon č. 361/2000 Sb., o provozu na pozemních komunikacích novelizován Zákonem č. 285/2018 Sb., a jeho prováděcí Vyhláška č. 294/2015 Sb., kterou se provádějí pravidla provozu na pozemních komunikacích novelizována Vyhláškou č. 84/2016 Sb. Jedním ze základních pravidel je řídit se dopravním značením. Podle výše zmíněného zákona se dopravní značení dělí na svislé a vodorovné. Podle způsobu instalace se dále dělí svislé značky na stálé, přenosné a proměnné, vodorovné značky na stálé a přechodné. Význam, tvar a provedení dopravních značek je stanoveno v příloze výše zmíněné prováděcí vyhlášky [11] [12].

### Svislé dopravní značení

Svislé dopravní značení je umístěno na konstrukcích pevně spojených se zemí (sloupky, budovy). Osazuje se při pravém okraji komunikace nebo nad komunikací v dostatečné vzdálenosti, aby bylo včas viditelné a rozeznatelné. Pro zdůraznění významu se může značka opakovat i při levém okraji nebo použitím reflexního materiálu. Na *Obr. 6* je uvedeno rozdělení svislých značek.




*Obr. 6 Ukázka svislého dopravního značení [12]*

Zákaz, příkaz nebo omezení stanovené dopravní značkou, platí pro celou komunikaci v daném směru a je zrušeno nejbližší křižovatkou nebo příslušnou značkou. Značky upravující přednost platí pro nejbližší křižovátku [12].

### Vodorovné dopravní značení

Vodorovné dopravní značení se vyznačuje přímo na komunikaci, kde stálé značení je bílou barvou a přechodné značení žlutou nebo oranžovou barvou. Na *Obr. 7* je uvedeno rozdělení vodorovných značek.



*Obr. 7 Ukázka vodorovného dopravního značení [12]*



### **3 PRAKTICKÁ ČÁST**

V úvodu kapitoly je popsán mapovací systém použitý při sběru dat a program použitý k trénování kaskády klasifikátorů. Dále je definován praktický postup vytvoření datové sady, trénování kaskády klasifikátorů a následné testování na nezávislé sadě snímků. Závěrem praktické části je popsán automatizovaný postup vytvoření datové vrstvy GIS s využitím klasifikátoru a sady snímků z panoramatické kamery Ladybug5.

#### **3.1 Použité vybavení**

##### **3.1.1 Mobilní mapovací systém RIEGL VMX - 450**

Mobilní mapování je technologie sběru velkého množství dat v relativně krátkém čase. Používá se v lokalitách, kde není účelné použití klasických geodetických metod nebo leteckého laserového skenování, jak z časového hlediska, tak od času odvíjejícího se ekonomického hlediska. Mapovací systém je nejčastěji osazen na automobilu. Podle charakteru zájmového území se v praxi můžeme setkat i s mapovacím systémem osazeným na železničním dopravním prostředku, lodi a bezpilotním prostředku. Při sběru dat byl mapovací systém osazen na automobilu.

Základními komponenty použitého systému jsou řídicí jednotka, přijímač Globálního družicového polohového systému (dále jen GNSS), inerciální měřicí jednotka (dále jen IMU), odometr, digitální kamery a laserové skenery. Řídicí jednotka koordinuje činnosti všech komponentů systému při sběru a ukládání dat na paměťové médium. K určování prostorové polohy systému je použit GNSS přijímač ve spojení s IMU. Odometr se používá ke zpřesnění údajů ujeté trajektorie. Jako záznamové zařízení jsou považovány digitální kamery a laserové skenery. Výstupem z digitálních kamer jsou jednotlivé snímky, které dokumentují mapovanou lokalitu. Laserové skenery generují mračno prostorových bodů. Jednotlivé komponenty jsou blíže popsány v následující kapitole.

Mobilní mapovací systémy lze využít v širokém spektru oblastí. Základním použitím je mapování prostoru kolem komunikací, železnic a vodních toků. Dalším využitím jsou různé druhy pasportizace, podklady pro projekt, dokumentace skutečného stavu, prostorové analýzy a 3D modelování. Dosahovaná přesnost mobilního mapovacího systému je v řádech centimetrů. Výstupem z mobilního mapování je mračno bodů umístěné v prostoru. Pořízená data lze využít pro mapování nebo GIS aplikace [13].



Obr. 8 Mobilní mapovací systém RIEGL VMX - 450 [vlastní tvorba]

### 3.1.1.1 Komponenty systému

#### Řídící jednotka VMX – 450 - CU

Řídící jednotka je hlavním komponentem systému, která ovládá a propojuje všechny ostatní komponenty při činnostech sběru dat. Obvykle je to počítač s vysokými nároky na výkon, operační a grafickou paměť a kapacitu úložných zařízení [14].



Obr. 9 Řídící jednotka [vlastní tvorba]

## **GNSS přijímač**

GNSS přijímač slouží pro určení prostorové polohy celého systému. Na základě údajů získaných z přijímače je vypočtena trajektorie trasy. GNSS přijímač se skládá z antény, radiofrekvenční jednotky, mikroprocesoru, paměti, komunikační jednotky a zdroje napětí. Při zpracování GNSS měření je potřeba eliminovat systematické vlivy působící na měření. U mobilního mapování je použita kinematická metoda se statickou inicializací na začátku a na konci měření. Doba inicializace byla stanovena na 5 minut. Přesnost přijímače GNSS stanovená výrobcem je 20–50 mm [15].

## **Inerciální měřící jednotka**

Úkolem jednotky je udržet stabilitu polohy systému za pomoci 3 akcelerometrů a 3 gyroskopů. Akcelerometry měří zrychlení ve třech navzájem kolmých směrech. Úhlové rychlosti jsou získány pomocí gyroskopů. IMU měří nepřetržitě polohu systému v místní souřadnicové soustavě zařízení. Výsledná poloha v požadované soustavě je získána transformací.

IMU se vyznačuje vysokou relativní přesností, absolutní přesnost však klesá s časem. Proto je v mobilních mapovacích systémech kombinována s GNSS přijímačem a odometrem. Kombinací těchto komponentů je zaručena prostorová poloha i při výpadku GNSS signálu [14].

## **Odometr VMX – 450 - DMI**


Odometr je zařízení pracující na principu sledování počtu otočení kola, jehož obvod je známý. Z těchto údajů je vypočítaná ujetá vzdálenost, která slouží ke zpřesnění údajů z GNSS systému a je důležitá při následném výpočtu trajektorie pohybu vozidla [14].



*Obr. 10 Odometr [vlastní tvorba]*

### **Laserový skener VQ - 450**

Laserový skener umožňuje rychlý a efektivní sběr dat z pohybujiícího se prostředí. Skener rozmetá paprsky v kolmém směru na směr jízdy, na základě kterých získává požadované délky a směry na podrobné body v řadě po sobě jdoucích rovnoběžných rovinách. V kombinaci s GNSS systémem, IMU a odometrem získávají podrobné body nepřetržitě prostorovou polohu. Dosah a počet měření závisí na skenovací frekvenci. Skener VQ - 450 je schopen vykonat 550 000 měření za sekundu na body vzdálené až 300 m s přesností 5 mm [15].



*Obr. 11 Schéma měřící hlavy mobilního mapovacího systému VMX – 450 [15]*

### **Digitální kamera VMX – 450 – CS6**

Kamery v mapovacím systému slouží pro obrazovou dokumentaci mapované trasy. Jejich rozmístění závisí na účelu úkolu, pro který jsou použity. Standardní konfigurace pro systém VMX - 450 jsou dvě kamery nasměrované ve směru jízdy a dvě kamery proti směru. Základem kamer je barevný snímač CCD s rozlišením pět megapixelů. Kamery jsou schopny pořídit snímky v rozlišení 2452x2056 pixelů [15].

### **Panoramatická kamera Ladybug5**

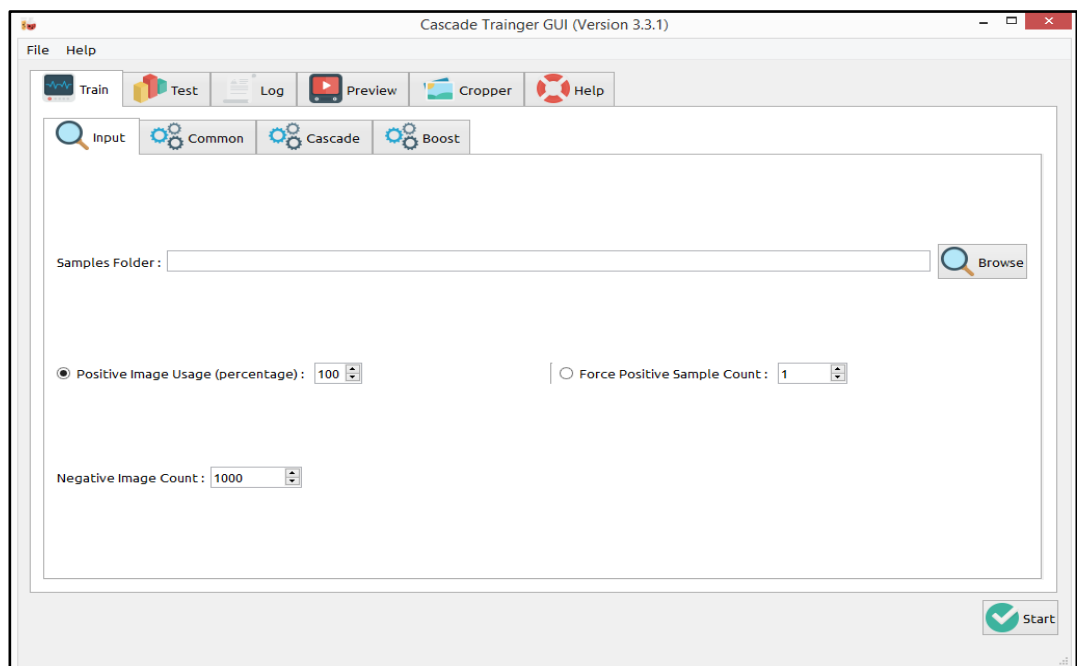
Ladybug5 je sférická kamera používaná společně se systémem RIEGEL VMX - 450. Jedná se o zařízení složené ze šesti kamer, kde každá kamera má barevný snímač CCD s rozlišením pět megapixelů. Pět kamer je soustředně rozmístěno do kruhu, aby bylo možné vytvořit 360° panoramatické snímky. Šestá kamera směřuje svisle vzhůru pro dokumentaci objektů nacházejících se nad vozidlem. Umístění Ladybug5 je na konzoli nad vozidlem tak, že přední kamera směřuje ve směru jízdy a zbylé čtyři doplňují zařízení na pravidelný pětiúhelník. Kamera je schopna pořídit deset snímků za sekundu s rozlišením 2048x2448 pixelů [16].



Obr. 12 Kamera Ladybug5 [16]

### 3.1.2 Cascade Trainer GUI

Cascade Trainer GUI je program vytvořený pro 32bitovou i 64bitovou verzi operačního systému Windows. Obsahuje všechny potřebné nástroje k tvorbě klasifikátoru. Pro vytvoření datové sady lze využít nástroj *Cropper*, kterým je v grafickém okně vybrán vzorek a uložen do zadané složky. K trénování slouží karta *Train*, která je dále rozdělena na záložky *Input*, *Common*, *Cascade* a *Boost*. V těchto záložkách jsou zadávány parametry tréninku. O celém postupu tréninku je veden protokol, který lze zobrazit na kartě *Log*. Výsledný klasifikátor lze otestovat na kartě *Test* a grafický výsledek je zobrazen na kartě *Preview* [17].



Obr. 13 Ukázka prostředí programu Cascade Trainer GUI [17]

Prvním krokem je vytvoření složky libovolného názvu i umístění. Pro příklad byla vytvořena složka „*Klasifikátor*“ na disku. V této složce je nutné vytvořit dvě podsložky, první s názvem „*p*“ pro pozitivní vzory a druhou s názvem „*n*“ pro vzory negativní. Je důležité dodržet značení podsložek, protože program je na tyto názvy naprogramován.

Jednotlivé vzory lze získat nástrojem *Cropper*. V rozhraní se nastaví cesta k požadovaným obrazům a výstupní složka, kam budou vzory ukládány. Pro uložení pozitivního vzoru je vhodné nastavit složku vytvořenou v prvním kroku s názvem „*p*“, obdobný je postup pro negativní vzory. Složka s obrazy je načtena a v okně je zobrazen první obraz. Jednotlivé obrazy lze posouvat pomocí šipek. Po vybrání příslušného vzoru je dialogem zobrazena volba k uložení do zadané složky nebo stornování výběru. Tento nástroj není nutné použít, pokud jsou připravené vlastní sady vzorů.

Parametry trénování se nastavují v jednotlivých podzáložkách karty *Train*. Jako první je nastavena cesta ke složce, kde jsou uloženy sady vzorů. V našem případě složka „*Klasifikátor*“ na disku. Dále je zvolen počet pozitivních a negativních vzorů, které mají být použity pro trénink. Na další záložce se nastavují parametry tréninku. Volí se počet stupňů kaskády, velikost uvolněné operační paměti Random – Access – Memory (dále jen RAM) pro trénink a počet vláken. Záložkou *Cascade* se nastavují parametry kaskády. Důležité je nastavení šířky a výšky pozitivního vzoru a modelu pro extrahování příznaků. Obecně se dá říci, že se vzrůstající velikostí vzoru, vzrůstá doba potřebná k tréninku. Je doporučeno ponechat jednu hodnotu na 24 pixelů a druhou dopočítat z poměrů stran vzoru. Parametry *Boost* je doporučeno ponechat na výchozích hodnotách.

Po stisknutí tlačítka Start je trénink zahájen. Průběh tréninku lze sledovat na kartě *Log*. Jako první jsou vytvořeny seznamy vzorů *neg.lst* a *pos.lst*. Na základě souboru *pos.lst* je vytvořen aplikací *opencv\_createsamples* soubor *pos\_samples.vec*. Dále je ve zvoleném umístění vytvořena složka *classifier*, kam jsou ukládány výsledky jednotlivých stupňů tréninku *stage.xml* a uložen soubor s parametry. Po ukončení tréninku je do složky přidán protokol *log.txt* a výsledná kaskáda *cascade.xml*. Tímto je proces trénování ukončen.

Testování kaskády klasifikátorů lze provést na kartě *Test*. Po zadání cesty ke kaskádě je zvolen zdroj dat, ve kterém je provedena detekce. Na výběr je jednotlivý obraz, složka s obrazy nebo video. Následně je zvolen výstup detekce z možností výběru ořezaných výsledků uložených do zadané složky nebo videa. Graficky je výsledek testu zobrazen na kartě *Preview* [17].



## 3.2 Příprava trénovacích dat

Od vedoucího práce byla převzata sada panoramatických snímků pořízených v rámci činností výzkumného centra Advanced Materials, Structures and Technologies (dále jen AdMaS), které je součástí Fakulty stavební Vysokého učení technického v Brně. Sada obsahovala 20 000 snímků z různých mapovaných lokalit. Jelikož se jedná o snímky z mobilního mapování, obsahuje sada spoustu velice podobných a nerelevantních snímků pro účel této práce. Obecně by negativní vzory mohly být všechno, kromě pozitivních vzorů. Vhodné je volit takové negativní vzory, které souvisejí se zájmovými objekty k detekci. Vhodnými negativními vzory pro trénink spolehlivého klasifikátoru dopravního značení nejsou vzory oblohy nebo stromů. Z tohoto důvodu byly z jednotlivých snímků vybírány jen reprezentativní vzorky obsahující právě dopravní značení, různé stavební objekty a předměty použitelné pro další postup práce. Taktéž byly odstraněny snímky obsahující státní poznávací značky a lidské obličeje z důvodu ochrany soukromí. Snímky z mobilního mapování byly vybrány záměrně, protože úzce souvisejí s cílem této práce. Tímto postupem byl vytvořen reprezentativní výběr obsahující 5 000 snímků.

Dalším krokem bylo pečlivé prozkoumání všech snímků a jejich následné rozdělení do dvou skupin. První skupina obsahuje pozitivní snímky, ve kterých se vyskytuje dopravní značení. Do druhé skupiny byly umístěny všechny ostatní negativní snímky. Tyto dvě skupiny jsou výsledným podkladem pro vytvoření pozitivní a negativní sady vzorů pro účely trénování klasifikátoru.

Negativní sada byla vytvořena na základě negativních snímků. Snímky byly jednoduchým nástrojem rozděleny na dlaždice o velikosti 200x200 pixelů. Ze snímku o velikosti 8000x4000 pixelů bylo vytvořeno celkem 378 dlaždic, ze kterých byly následně vybrány jen relevantní vzory. Výsledná sada obsahuje 2 000 negativních vzorů.



*Obr. 14 Ukázka negativních vzorů [vlastní tvorba]*

Vytvoření pozitivní sady bylo náročnější a časově nákladnější. Z veškerého dopravního značení byl výběr omezen na značku „hlavní komunikace“ a značku „dej přednost v jízdě“, z důvodu jejich nejčastějšího výskytu.



*Obr. 15 Ukázka vybraných značek [12]*

Celkový počet pozitivních vzorů lze rozdělit na tři části podle způsobu pořízení. V první části byly značky ručně vybrány ze skupiny pozitivních snímků, avšak jejich počet nebyl velký. Druhou částí je sada doplněna vlastními fotografiemi pořízenými mobilním telefonem a následným ořezáním nepotřebného pozadí kolem značek. Poslední částí byly značky vybrány z webové aplikace Google Street View. Celkový počet pozitivních vzorů je 560 pro každý druh značky.



*Obr. 16 Ukázka pozitivních vzorů [vlastní tvorba]*

### **3.3 Trénování kaskády klasifikátorů**

K trénování kaskády je možné využít příkazový řádek systému Windows, kde je však nepřehledné rozhraní a všechny parametry se musí zadávat pomocí příkazů. Další možností je program Cascade Trainer GUI vytvořený vývojářem a expertem v oblasti počítačového vidění A. Ahmadim, který je volně dostupný z webových stránek [17]. Bylo ověřeno, že oběma způsoby jsou dosaženy stejné výsledky. Pro trénování kaskády byl zvolen program Cascade Trainer GUI pro jeho jednoduché grafické rozhraní, přehlednost a dobře popsany návod pro práci s programem. Poslední vydaná verze je 3. 3. 1 z roku 2017, která používá verzi knihovny OpenCV 3. 3. 1.



### 3.3.1 Experimentální pokusy volby parametrů tréninku

Prvním krokem bylo potřeba zjistit nejvhodnější kombinaci parametrů tréninku k dosažení požadované spolehlivosti klasifikátoru. Bylo testováno jednoduché předzpracování obrazu ve formě použití barevného modelu RGB nebo GRAY. Dále je posuzován vliv počtu jednotlivých vzorů a použité modely příznaků. K testování byly použity dva nepoužívanější typy příznaků: HAAR a LBP. K účelu testování byly vytvořeny dvě nezávislé sady snímků obsahující 16 pozitivních snímků a 14 snímků negativních, každá pro jeden druh dopravního značení. Tyto snímky byly pořízeny přední kamerou Ladybug5 a mají rozlišení 1024x1224 pixelů. Sada pro dopravní značku „dej přednost v jízdě“ obsahuje celkem 19 pozitivních vzorů značky, sada pro značku „hlavní komunikace“ obsahuje 16 pozitivních vzorů značky.

Na základě získaných informací z přečtených článků a materiálů uvedených v teoretické části práce, byly voleny různé kombinace parametrů. Velikost pozitivních vzorů byla podle návodu na webových stránkách OpenCV zvolena 24x24 pixelů. Tato velikost je doporučena pro snížení časové náročnosti tréninku. Pro negativní vzory byla zvolena velikost 200x200 pixelů, což je optimální velikost obsahující dostatek obrazové informace. Testováním bylo také ověřeno, že použitím velikosti negativních vzorů 48x48 pixelů se sníží potřebná doba tréninku na úkor spolehlivosti klasifikátoru, kdy bylo detekováno malé množství pozitivních vzorů a počet falešně pozitivních nálezů byl větší než 30 %. Velikost uvolněné paměti RAM pro trénink byla nastavena na 2 048 Mb pro zrychlení doby tréninku. Ostatní parametry, které nejsou jmenovány nebo nejsou předmětem testování, byly ponechány na výchozích hodnotách, jak uvádí A. Ahmadi na svých webových stránkách, a které jsou přednastaveny v aplikaci.

#### **Shrnutí neměnných parametrů pro trénink:**

- Počet stupňů kaskády = 20
- Velikost uvolněné paměti pro trénink = 2048 Mb
- Velikost pozitivních vzorů = 24x24 pixelů
- Velikost negativních vzorů = 200x200 pixelů
- Typ zesílení = GAB (AdaBoost)
- Minimální HitRate = 0,995 (99,5 %)
- Maximální FalseAlarm = 0,5 (0,5 %)

Jako pomocný nástroj byla použita knihovna OpenCV v prostředí jazyku Python. Python je rychle rozvíjející se programovací jazyk použitelný na všech operačních systémech. Dalšími výhodami jsou jeho rychlost, jednoduchost, rozšiřitelnost a aplikovatelnost. Python umí pracovat s tisíci knihovnami třetích stran, které v kombinaci s knihovnou Python vytvářejí nekonečné možnosti použití. Nutno dodat, že je vyvíjen s otevřeným zdrojovým kódem a je volně ke stažení z webových stránek [18]. Při tvorbě skriptů použitých v práci jsem se inspiroval na webových stránkách dokumentujících tutoriály a postupy práce v jazyce Python [19].

V práci je použit jazyk Python verze 3. 7. 2, který je implementován pomocí aplikace Python 3. 7. 2 Shell. Pro zpracování vzorů byl vytvořen jednoduchý skript k převodu barevných vzorů do stupňů šedi a na změnu velikosti vzorů (viz Obr. 17).

```
import numpy as np
import cv2 as cv
import os
from PIL import Image #import potřebných knihoven

if(not os.path.isdir("gray")): #když v umístění není složka "gray", tak je vytvořena
    os.mkdir("gray")

i=0
for img in os.listdir("prevod"): #cyklus k projití všech obrazů ve složce "prevod"
    i=i+1
    imgLoad = cv.imread('prevod/'+img); #načtení obrazů
    resized=cv.resize(imgLoad, (24,24)) #změna velikosti původního obrazu
    gray = cv.cvtColor(imgLoad, cv.COLOR_BGR2GRAY) #převod obrazu z RGB do stupňů šedi
    cv.imwrite("gray/"+str(i)+".png",gray) #uložení nového obrazu do složky "gray"

print("HOTOVO") #informace o dokončení cyklu
```

Obr. 17 Ukázka skriptu na změnu barvy a velikosti [vlastní tvorba]

Pomocí cyklu jsou načteny jednotlivé obrazy předem umístěné ve složce „prevod“. Obrazům je změněna velikost na 24x24 pixelů a jsou převedeny do stupňů šedi. Takto převedené obrazy jsou uloženy do vytvořené složky „gray“. Červeně uvedené texty jsou pouze poznámkou k jednotlivým příkazům.

Další vytvořený skript slouží k ověření spolehlivosti klasifikátorů vytvořených v rámci experimentálního testování. Skript je uveden na Obr. 18. Pro jednotlivé klasifikátory byly vytvořeny testovací sady obsahující 30 snímků. Ve snímcích je celkem 16 pozitivních vzorů značky „hlavní komunikace“ a 19 pozitivních vzorů značky „dej přednost v jízdě“. Výsledky testování jsou uvedeny v Tab. 5.

```

import numpy as np
import cv2 as cv
import os
from PIL import Image #import potřebných knihoven

cascade = cv.CascadeClassifier("cascade.xml") #načtení kaskády klasifikátorů

for img in os.listdir("images"): #cyklus k projití všech obrazů ve složce "images"

    imgLoad = cv.imread('images/'+img); #načtení obrazů

    gray = cv.cvtColor(imgLoad, cv.COLOR_BGR2GRAY) #převod obrazu z RGB do stupňů šedi

    #detekce objektů v obraze
    signs = cascade.detectMultiScale(gray, scaleFactor = 1.05, minNeighbors = 4)
    arr_signs = np.asarray(signs)

    for (x,y,w,h) in signs: #cyklus, který vytvoří obdélník kolem detekovaného objektu
        img = cv.rectangle(imgLoad, (x,y), (x+w,y+h), (0,255,0),10)

        cv.imshow("Vysledek",img) #zobrazení výsledku
        cv.waitKey(0) #čeká na stisk libovolné klávesy

    cv.destroyAllWindows() #zavře okno a pokračuje na další obraz


```

Obr. 18 Ukázka skriptu na testování spolehlivosti detekce [vlastní tvorba]

Nejprve je načtena vytrénovaná kaskáda klasifikátorů. Skript projde všechny testovací obrázky předem uložené ve složce „images“. Ke zrychlení detekce je obraz převeden do stupňů šedi. Pomocí cyklu je na každý obraz aplikován klasifikátor. Je nastavena hodnota 1,05 pro měřítko detekčního okna a hodnota 4 pro minimální počet sousedů. Pokud je hledaný objekt nalezen, uloží se souřadnice a rozměry objektu do proměnné „signs“. Pokud klasifikátor nic nenalezne, pokračuje se dalším obrazem. V dalším kroku je použit cyklus, který projde souřadnice a rozměry obsažené v proměnné „signs“ a vykreslí kolem objektu obdélník. Výsledkem je okno zobrazující obraz s hledaným objektem.



Obr. 19 Ukázka pozitivních detekcí [vlastní tvorba]



Obr. 20 Ukázka falešně pozitivních detekcí [vlastní tvorba]

Tab. 5 Vybrané výsledky experimentálního testování [vlastní tvorba]

Druh značky	Počet vzorů		Barevný model	Typ příznaků	Nalezené značky/ celkový počet značek	Negativně pozitivní nálezy	Úspěšnost detekce značky
	P	N					
▽	200	200	RGB	LBP	12/19	0	65 %
◇	200	660	RGB	HAAR	13/16	0	81 %
▽	320	660	RGB	HAAR	18/19	2	95 %
▽	500	1000	RGB	HAAR	18/19	2	95 %
▽	500	1000	GRAY	HAAR	18/19	0	95 %
▽	500	1000	RGB	LBP	18/19	5	95 %
▽	500	1000	GRAY	LBP	18/19	2	95 %
◇	500	1000	RGB	HAAR	13/16	1	81 %
◇	500	1000	GRAY	HAAR	15/16	0	94 %
◇	500	1000	RGB	LBP	14/16	0	88 %
◇	500	1000	GRAY	LBP	16/16	2	100 %





V tabulce jsou použity následující zkratky: P značí pozitivní vzory, N negativní vzory

Z tabulky je patrné, že se stoupajícím počtem vzorů, vzrůstá úspěšnost detekce značky. Po prvním orientačním tréninku byly počty pozitivních ku negativním vzorům voleny v poměru jedna ku dvěma a vyšším, jak je doporučeno podle odborného článku [20]. Takto zvoleným poměrem se zvýšila úspěšnost detekce. Dále je patrné, že při použití vzorů ve stupních šedi dosahuje míra detekce spolehlivých výsledků a zejména počet falešně pozitivních nálezů je minimalizován. Nejspolehlivějších výsledků dosáhneme použitím vzorů ve stupních šedi s extrakcí příznaků HAAR. Výsledkem experimentálního testování jsou na základě dosažených výsledků zeleně zvýrazněné klasifikátory, které byly použity pro další zpracování.

Jako další možné kritérium pro volbu klasifikátoru je délka tréninku a rychlost detekce hledaných objektů. Délka tréninku je ovlivněna zejména vytížením počítače a velikostí uvolněné operační paměti RAM, proto jsou uvedené časy pouze orientační.

Dalším kritériem ovlivňujícím délku tréninku je počet použitých vzorů a druh příznaků. Údaje uvedené v tabulce byly dosaženy při použití 500 pozitivních a 1 000 negativních vzorů. K určení rychlosti detekce bylo použito 1 000 snímků o velikosti 1024x1224 pixelů. Rychlost je uvedena jako počet snímků za sekundu.

Tab. 6 Časová náročnost tréninku a detekce [vlastní tvorba]


Druh značky	Barevný model	Typ příznaků	Negativně pozitivní nálezy	Úspěšnost detekce značky	Uvolněná operační paměť	Doba tréninku	Rychlost detekce
	RGB	HAAR	1	81 %	2 048 Mb	3 h 10 m	4,7/s
	GRAY	HAAR	0	94 %	2 048 Mb	2 h 18 m	5,2/s
	RGB	LBP	0	88 %	2 048 Mb	51 m	5,3/s
	GRAY	LBP	2	100 %	2 048 Mb	37 m	5,3/s

Údaje uvedené v tabulce prokazují, že dobu tréninku výrazně ovlivňuje typ použitých příznaků a barevný model použitých vzorů. Jak už bylo zmíněno, menší časová náročnost příznaků LBP je na úkor kvality detekce a počtu falešně pozitivních nálezů. Rozhodnutí, jaký typ příznaků zvolit je závislé na požadavcích uživatele, účelu použití a požadované spolehlivosti klasifikátoru. Rychlost detekce je pro zvolený počet 1 000 snímků přibližně stejná pro všechny použité kombinace, tedy pět snímků za sekundu. Časové údaje jsou pouze orientační a jsou vztaheny k použitému počítači (64bitový operační systém Windows 8.1, procesor i7-4702MQ 2,20 GHz, 8 GB RAM).

## 3.4 Testování spolehlivosti klasifikátoru

### 3.4.1 Sběr dat

K testování na nezávislé sadě snímků bylo potřeba takovou sadu získat. Ke sběru snímků bylo využito mapovacího systému z výzkumného centra AdMaS. Mapovacím vozidlem byla projeta lokalita znázorněná na *Obr. 21*. Celkem bylo získáno 1 473 snímků z jednotlivých kamer, které byly zpracováním v kanceláři spojeny do 1 473 panoramatických snímků. Pro testování byly vybrány snímky pouze z přední kamery ve směru jízdy, protože poskytují pouze pohled vpřed. U panoramatických snímků zobrazujících 360° okolí mapovacího systému by se při dalším zpracování mohl vyskytnout problém, a to detekce značek v opačném směru, než je směr jízdy.



*Obr. 21 Trasa sběru snímků [21]*

Začátek trasy byl v areálu výzkumného centra AdMaS. Dále trasa pokračovala ulicí Purkyňovou, kolem zastávek tramvaje Technologický park, Skácelova, až po křižovatku s ulicí Tábor. Na křižovatce bylo odbočeno na ulici Hradeckou. Po ulici Hradecká vedla trasa až ke sjezdu u Technického muzea zpátky na ulici Purkyňovu. Z ulice Purkyňova bylo odbočeno na ulici Podnikatelskou a kolem kolejí VUT Pod Palackého vrchem byla trasa ukončena zpátky ve výzkumném centru AdMaS.



### 3.4.2 Testování klasifikátoru

K testování byla použita sada snímků pořízená při průjezdu uvedenou lokalitou mobilním mapovacím systémem vědeckého centra AdMaS. Celkem bylo použito 1 473 snímků z přední kamery Ladybug5. Vytrénované klasifikátory byly aplikovány na sadu snímků a jejich pomocí byly vybrány pouze snímky obsahující hledané značky. Tento proces byl implementován pomocí skriptu napsaném v programovacím jazyku Python. Výsledkem je sada vybraných snímků obsahující hledané dopravní značení, která je použita pro další zpracování.

```
import numpy as np
import cv2 as cv
import os
from PIL import Image
from shutil import copyfile #import potřebných knihoven

cascade = cv.CascadeClassifier("cascade.xml") #načtení kaskády klasifikátorů

if(not os.path.isdir("hledane_fotky")): #pokud není v umístění složka "hledane_fotky"
    os.mkdir("hledane_fotky") #tak ji vytvoří

for img in os.listdir("images"): #cyklus k projití všech obrazů ve složce "images"

    imgLoad = cv.imread('images/'+img); #načtení obrazů

    gray = cv.cvtColor(imgLoad, cv.COLOR_RGB2GRAY) #převod obrazu z RGB do stupňů šedi

    #detekce objektů v obraze
    signs = cascade.detectMultiScale(gray, scaleFactor = 1.05, minNeighbors = 4)
    arr_signs = np.asarray(signs)

    #podmínka, pokud je velikost proměnné signs větší než 0 = obsahuje hledaný objekt
    #nakopíruje obraz s hledaným objektem do složky "hledane_fotky"
    if arr_signs.size > 0:
        copyfile("images/"+img, "hledane_fotky/"+img)
```





Obr. 22 Ukázka skriptu na vytřížení hledaných fotek [vlastní tvorba]

Prohlídkou sady snímků a ověřením v terénu byl zjištěn počet vybraných dopravních značek. Celkem je v zájmové lokalitě 14 značek „dej přednost v jízdě“ a 16 značek „hlavní cesta“.

Pro vyhodnocení spolehlivosti existují dva druhy přístupu. Prvním přístupem je vyhledání co největšího počtu zájmových objektů bez ohledu na počet falešně pozitivních nálezů. Jako druhá možnost je vyhledání nezbytného počtu objektů s minimálními falešnými nálezy. Tyto dva přístupy jsou ovlivněny volbou měřítka detekčního okna („scaleFactor“) a minimálním počtem sousedů („minNeighbors“). Měřítka detekčního okna je údaj v procentech, který udává, kolikrát je detekční okno zvětšeno při každém průchodu celého snímku. Velikost okna se zvětšuje až do dosažení velikosti snímku. Měřítka 1.05 znamená, že se detekční okno po průchodu celým snímkem zvětší o 5 %. Parametr měřítka nejvíce ovlivňuje celkovou dobu detekce. Počet sousedů ovlivňuje falešně pozitivní nálezy. Při zvolení parametru sousedů rovného nule, získáme všechny nálezy, které klasifikátor detekuje. Optimální je použít hodnotu v rozmezí 3–6.

Pro testování byly parametry měřítka okna a sousedů voleny v závislosti na dvou zmíněných přístupech. Přesnost klasifikátoru v % je určena z podílu nalezených značek ku celkovému počtu. Rychlost detekce je vztažena k celkovému počtu 1 473 snímků a je vyjádřena jako počet snímků za sekundu. Zhodnocení spolehlivosti klasifikátorů je přehledně sestaveno v *Tab. 7*.

*Tab. 7 Výsledky testování klasifikátorů [vlastní tvorba]*

Druh značky	Měřítka okna	Počet sousedů	Celkem vybraných snímků	Nalezené značky/ celkový počet značek	Negativně pozitivní nálezy	Úspěšnost detekce značky	Rychlost detekce
	1,05	5	77	14/14	42	100 %	4,7/s
	1,25	6	20	12/14	0	86 %	14,6/s
	1,05	3	60	15/16	40	94 %	5,1/s
	1,08	6	16	12/16	1	75 %	7,6/s

Podle údajů uvedených v tabulce je patrná provázanost jednotlivých parametrů. Se zvětšujícím se měřítkem detekčního okna vzrůstá rychlost detekce. S rostoucím počtem sousedů klesá úspěšnost detekce, na druhou stranu je výhodou klesající počet falešně pozitivních nálezů. Pro další zpracování byly vybrány zeleně zvýrazněné kombinace parametrů. Důvodem výběru spolehlivosti na úkor falešným nálezům je význam dalšího použití vytřížených snímků.

Primárním cílem práce je vytvoření datové vrstvy GIS obsahující dopravního značení, která má obsahovat všechny dopravní značky v zájmové lokalitě. Proto je důležité, aby klasifikátor našel co největší počet vyskytujících se značek. Falešné nálezy lze odstranit dalším zpracováním. Časové údaje jsou pouze orientační a jsou vztaženy k použitému počítači (64bitový operační systém Windows 8.1, procesor i7-4702MQ 2,20 GHz, 8 GB RAM).

Finálním výstupem této části zpracování jsou dvě sady snímků. Sada pro dopravní značku „dej přednost v jízdě“ obsahuje 77 snímků a sada značky „hlavní komunikace“ obsahuje 60 snímků. Tyto sady jsou předmětem dalšího zpracování, kterému se věnuje nadcházející kapitola 3.5.





Obr. 23 Příklady falešně pozitivních nálezů [vlastní tvorba]



Obr. 24 Ukázka detekovaných značek [vlastní tvorba]

### 3.4.3 Návrh zlepšení spolehlivosti klasifikátorů

Z dosažených výsledků lze usoudit, že klasifikátor má určité nedostatky. Zejména se jedná o spolehlivost detekce objektů a s tím spojený počet falešných nálezů. Tyto nedostatky lze odstranit rozšířením sad pozitivních a negativních vzorů vstupujících do trénování kaskády. Sady lze rozšířit pořízením nových snímků a použitím už vytrénovaného klasifikátoru. K tomuto účelu lze využít už zmíněnou aplikaci Cascade Trainer GUI. Pomocí karty *Test* v aplikaci lze provést detekci nových objektů. Výstupem jsou vyřezané objekty detekované klasifikátorem. Vyřazením těchto objektů lze přidat pozitivní nálezy do sady pozitivních vzorů a falešné nálezy přidat do sady negativních vzorů. Tento postup lze aplikovat opakovaně a postupně tak zlepšovat kvalitu detekce provedené klasifikátorem, až do splnění požadovaných nároků na přesnost a počet falešných nálezů. Jelikož je cílem práce ověření funkčnosti automatizovaného postupu, není klasifikátor dále zlepšován. Zlepšení může být předmětem další práce.

### 3.5 Tvorba datové vrstvy GIS

Geografický informační systém lze definovat jako rámec vedený počítačovými prostředky pro shromažďování, správu a analýzu prostorových dat. Základ systému je založen na geografických vědních oborech. Pomocí GIS lze jednoduše kombinovat různé typy dat a spojit je do jediného systému. Dále je možné vytvářet analýzy, sdílet informace a řešit komplexní problémy spojené s uloženými prostorovými daty. Díky této všestrannosti poskytuje GIS hlubší náhled do uložených dat, kde podává informace o vazbách, situacích a struktuře konkrétních prostorových prvků, které pomáhají uživateli lépe se zorientovat a rozhodovat.

GIS používá spousta světových organizací pracujících v různých oborech. Organizace si tvoří vlastní systémy a shromažďují velké množství dat, které pak mohou sdílet s okolním světem. Tomu napomáhá spojení geografických věd s nástroji na porozumění a komunikaci. Tímto přístupem je snaha dosáhnout společného cíle, a to získání užitečných informací z různých typů dat [22].



Obr. 25 Struktura GIS [23]

K vytvoření datové vrstvy GIS byl použit program s otevřeným zdrojovým kódem QGIS. Program je volně dostupný z webové stránky [24], kde byly čerpány i informace a tutoriály práce v programu. QGIS byl zvolen pro jeho bezplatnou dostupnost a obsáhlou dokumentaci. Výstupem této závěrečné kapitoly práce jsou datové vrstvy formátu shapefile obsahující dopravní značení. Datové vrstvy jsou v souřadnicovém systému World Geodetic System 1984 (dále jen WGS-84).

### 3.5.1 Úprava vstupních snímků


Protože požadovaná sada snímků obsahuje i snímky falešně pozitivní, bylo před dalším zpracováním nutné protřídit sadu a vybrat pouze snímky obsahující dopravní značení. Dalším úskalím je, že některé značky jsou na více snímcích. To bylo zapříčiněno při sběru dat, kdy byl nastaven interval pořízení snímků na pět metrů. Tyto duplicitní snímky bylo potřeba ze sady odstranit. Úpravy snímků je možné provést dvěma způsoby. Prvním způsobem je ruční prohledání složky a vytřídění nepotřebných snímků přímo v prostředí Windows. Druhou možností je importování všech snímků do programu QGIS a provést odstranění nepotřebných prvků z datové vrstvy přímo v prostředí aplikace. Byla zvolena první možnost úpravy, protože je méně časově náročná. Výsledkem je 15 snímků pro značku „hlavní cesta“ a 12 snímků pro značku „dej přednost v jízdě“. Počet vytříděných snímků pro značku „hlavní cesta“ odpovídá počtu skutečně detekovaných značek z testování klasifikátorů. Počet vytříděných snímků pro značku „dej přednost v jízdě“ je pouze 12. Zbylé dvě značky byly sice detekované, ale protože se nacházejí v jiném jízdním pruhu, než byla trasa jízdy, nebyly pro další zpracování použity, protože by nebylo možné je správně lokalizovat.



Obr. 26 Ukázka atributů prvku [vlastní tvorba]

### 3.5.2 Postup práce v programu QGIS

Prvním krokem bylo na kartě *Projekt* zvolení možnosti *Nové* a vytvoření nového projektu. Do vytvořeného projektu bylo potřeba nahrát vybrané snímky. Důležité je, aby měly snímky ve svém Exifu (zkratka z anglického Exchangeable image file format) uloženy souřadnice Globálního polohového systému (dále jen GPS) místa pořízení snímku. Exif je formát metadat, vkládaných do souborů pořízených kamerami. Mezi metadaty lze nalézt čas expozice, citlivost, datum, čas, GPS souřadnice místa pořízení a jiné [25]. Na kartě *Zásuvné moduly* byla vybrána možnost *Správa a instalace zásuvných modulů*, kterou je otevřeno nové okno s nabídkou.



Obr. 27 Základní nabídka programu QGIS [vlastní tvorba]

Do pole vyhledání byl zadán název nástroje pro import snímku *ImportPhotos*. Nástroj byl následně nainstalován do programu QGIS. Po instalaci se vytvořily dvě nové ikony přidávané pod základní nabídku. První ikona je pro importování snímků a druhá pro jejich prohlížení. Po zvolení nástroje pro import snímků je otevřeno nové okno, kde jsou požadovány vstupní parametry. Vstupem tohoto nástroje jsou předpřipravené složky se snímky. Výstupem je datová vrstva *shapefile*. Import byl proveden dvakrát, poprvé pro dopravní značku „hlavní komunikace“ a podruhé pro značku „dej přednost v jízdě“. Druhou ikonou je možné spustit nástroj pro prohlížení snímků, ke kterým má každý prvek uvedenou cestu v atributové tabulce. Snímek lze zobrazit dvojklikem myši na požadovaný prvek. Vybraný prvek je žlutě zvýrazněn, aby byl lehce identifikovatelný (viz Obr. 29). Byly vytvořeny dvě datové vrstvy *shapefile*, které byly dále upravovány do podoby možného výstupu.


Pro snadnější lokalizaci značek v lokalitě byla ve *Správci otevřených zdrojů dat* přidána služba *Webových Mapových Služeb* (zkratka WMS) *Ortofoto* a datová vrstva *komunikací ze Základní báze geografických dat České republiky* (zkratka ZABAGED). Obě služby poskytuje Český úřad zeměměřický a katastrální na svých webových stránkách [26]. Do programu je možné vložit různé mapové podklady od různých poskytovatelů.

Vizuální odlišení prvků značky „hlavní cesta“ a značky „dej přednost v jízdě“ bylo provedeno na základě změny symbolů, kdy byl použit rastrový symbol s nahraným obrazem dané značky. Dále jsou uvedeny ukázky tvorby v programu QGIS.





Obr. 28 Ukázka možného výstupu pro pasportizaci – výřez [vlastní tvorba]



Obr. 29 Ukázka zobrazení snímku vybraného prvku [vlastní tvorba]

### 3.6 Zhodnocení výsledků práce

Z dosažených výsledků je zřejmé, že k vytrénování spolehlivého klasifikátoru je potřeba shromáždit dostatečné množství vzorů a zvolit vhodné parametry. Dostatečným množstvím vzorů pro zvolené značky se prokázalo použití 500 pozitivních vzorů pro oba typy značek a 1 000 negativních vzorů. Se vzrůstajícím počtem vzorů byla dosáhnuta vyšší spolehlivost detekce. Jako vhodné se ukázalo převedení vzorů do stupňů šedi a použití Haarových příznaků. Použití vzorů ve stupních šedi snižuje dobu potřebnou k tréninku. Příznaky LBP jsou sice méně časově náročné, avšak dosahují horší úspěšnosti detekce nebo vyššího počtu falešně pozitivních nálezů než příznaky HAAR.

Klasifikátory byly testovány na nezávislé sadě 1 473 snímků. Pro značku „dej přednost v jízdě“ byla dosažena úspěšnost detekce 100 % a současně nalezeno 42 falešně pozitivních nálezů. Pro značku „hlavní cesta“ byla dosažena úspěšnost detekce 94 % a nalezeno 40 falešně pozitivních nálezů. Protože je cílem práce datová vrstva GIS, obsahující dopravní značení, je vhodné, aby klasifikátor rozeznal co největší počet značek vyskytujících se v lokalitě i na úkor vyššího počtu falešných nálezů. Jako další možný výsledek, z hlediska minimalizace počtu falešně pozitivních vzorů, lze považovat dosažení úspěšnosti detekce 86 % a žádný falešně pozitivní nález pro značku „dej přednost v jízdě“ a pro značku „hlavní cesta“ úspěšnost detekce 75 % a 1 falešně pozitivní nález.

Dosažené výsledky dokládají možnost použití natrénované kaskády klasifikátorů k detekci značek a tím automatizovanému zpracování snímků z mobilního mapovacího systému. Pro zvolené druhy značek není potřebný vysoký počet pozitivních vzorů, protože typy značky jsou neměnné a není mezi nimi takový rozdíl, jako jsou rozdíly mezi vzory při detekci lidských obličejů.

Úskalím postupu je dosahovaná přesnost umístění značky, která je v řádech metrů. Tato přesnost je způsobena pořízením snímku z pohybujícího se vozidla s intervalem záznamu snímku 5 m. Dalším aspektem ovlivňující polohu značky jsou GPS souřadnice vztažené k trajektorii trasy a tím umístění značek v cestě. Zlepšení přesnosti umístění značky ve směru jízdy by bylo možné nastavením menšího intervalu záznamu snímku. Dalším problémem je více rozpoznávaných značek na jednom snímku. Jedná se zejména o křižovatky, kde se nachází přímý a odbočovací jízdní pruh. Klasifikátor rozpozná značky v obou pruzích, ale umístí je na stejné místo pořízení snímku. Je tedy znemožněno správné umístění značky, která se nachází mimo trajektorii trasy. Tímto postupem je možné správně detekovat pouze značky podél trajektorie trasy.

Natrénované klasifikátory jsou schopné provést spolehlivou detekci značek ve snímcích z mobilního mapovacího systému. Zlepšení spolehlivosti klasifikátorů a snížení počtu falešných nálezů by bylo možné zvýšením počtu vzorů k trénování.

## 4 ZÁVĚR

Diplomová práce se zabývá rozpoznáním svislých dopravních značek ve snímcích pořízených panoramatickou kamerou Ladybug5 mobilního mapovacího systému. V první části práce jsou popsány teoretické poznatky potřebné k pochopení problematiky. Druhá část se věnuje konkrétním postupům trénování a testování klasifikátorů a automatizované tvorby datové vrstvy GIS. Cílem práce bylo seznámení se s problematikou vyhledání objektů zájmu ve snímcích, vytrénování spolehlivého klasifikátoru, ověření spolehlivosti klasifikátorů na nezávislé sadě snímků a automatizované vytvoření datové vrstvy GIS obsahující svislé dopravní značení.

V rámci práce byly pomocí knihovny OpenCV vytrénovány dva klasifikátory, jeden pro dopravní značku „hlavní cesta“ a druhý pro dopravní značku „dej přednost v jízdě“. Klasifikátory byly vytrénovány s implementací algoritmu AdaBoost a Haarových příznaků na základě vytvořených pozitivních a negativních vzorů. Ověření spolehlivosti klasifikátorů bylo provedeno na nezávislé sadě 1 473 snímků pořízených panoramatickou kamerou Ladybug5. Vyhodnocením výsledků ověření byla stanovena úspěšnost detekce dopravní značky „hlavní cesta“ 94 % a 40 falešně pozitivních nálezů a úspěšnost 100 % pro značku „dej přednost v jízdě“, kde bylo falešně detekováno 42 vzorů. Rychlost detekce je v průměru pět snímků za sekundu. Současně s ověřením byly klasifikátorem detekované snímky uloženy do zvláštní složky, na základě kterých byla vytvořena datová vrstva GIS.

Přínosem práce je propojení metody mobilního mapování a aplikací počítačového vidění. Konkrétně využití detekce objektů zájmu k automatizovanému rozpoznání a vytřížení snímků pořízených mobilním mapovacím systémem. Dále z těchto snímků automatizovaně vytvořit datovou vrstvu GIS obsahující objekty zájmu. Datové sady jsou využitelné například k pasportizaci.

Mezi hlavní výhody uvedeného postupu lze zařadit časovou úsporu při zpracování velkého objemu snímků a tím ušetřené finance. Další výhodou je, že celý postup je realizován v bezplatném softwaru s otevřeným zdrojovým kódem.

Úskalím uvedeného postupu je přesnost polohy dopravních značek. Značky jsou lokalizovány s přesností několika metrů. Lze tedy konstatovat, že uvedený postup je možné použít pro aplikace, kde není důležitá přesná poloha objektu, ale jeho evidence.

Výstupem práce jsou vytrénované klasifikátory a datové vrstvy GIS obsahující dopravní značení. Datové vrstvy jsou v souřadnicovém systému WGS-84.

## SEZNAM POUŽITÉ LITERATURY

- [1] ŠONKA, Milan a Václav HLAVÁČ. *Počítačové vidění: první česká kniha o zpracování digitalizovaných obrazů; rozpoznávání objektů v obrazech; analýza trojrozměrných a pohybujících se objektů; příklady aplikací počítačového vidění*. Praha: Grada, 1992. Nestůjíte za dveřmi.
- [2] VIOLA, P. a M. JONES. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* [online]. 2001, 1, I511-I518 [cit. 2019-05-20]. ISSN 10636919. Dostupné z: <https://www.cs.cmu.edu/~efros/courses/LBMV07/Papers/viola-cvpr-01.pdf>
- [3] DALAL, N a B TRIGGS. Histograms of oriented gradients for human detection. In: *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)* [online]. IEEE, 2005, 1, 886-893 vol. 1 [cit. 2019-05-20]. DOI: 10.1109/CVPR.2005.177. ISBN 0769523722. Dostupné z: <http://lear.inrialpes.fr/people/triggs/pubs/Dalal-cvpr05.pdf>
- [4] WILSON, Phillip, John FERNANDEZ a Phillip WILSON. *Facial feature detection using Haar classifiers*. *Journal of Computing Sciences in Colleges*[online]. 2006, 21(4), 127-133 [cit. 2019-05-20]. ISSN 1937-4771. Dostupné z: <http://search.proquest.com/docview/29382216/>
- [5] ŠEBELA, Miroslav *Detekce objektu ve videosekvencích: diplomová práce*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací, 2010. 64 s. Vedoucí práce byl Ing. Petr Číka, Ph.D.
- [6] Products. *Eyedeas* [online]. Praha: Eyedeas Recognition, 2019 [cit. 2019-05-20]. Dostupné z: <http://www.eyedeas.cz/cs/products/>
- [7] Introduction. *Open Source Computer Vision* [online]. Doxygen, 2018 [cit. 2019-05-20]. Dostupné z: <https://docs.opencv.org/3.4.3/d1/dfb/intro.html>
- [8] YANG, Chu-sing a Yung-hsuan YANG. *Improved local binary pattern for real scene optical character recognition*. *Pattern Recognition Letters* [online]. Elsevier B.V, 2017, 100, 14-21 [cit. 2019-05-20]. DOI: 10.1016/j.patrec.2017.08.005. ISSN 0167-8655. Dostupné z: <https://www.sciencedirect.com.ezproxy.lib.vutbr.cz/science/article/pii/S016786551730260>



- [9] Cascade Classifier Training. *Open Source Computer Vision* [online]. Doxygen, 2018 [cit. 2019-05-20]. Dostupné z: [https://docs.opencv.org/3.4.3/dc/d88/tutorial\\_traincascade.html](https://docs.opencv.org/3.4.3/dc/d88/tutorial_traincascade.html)
- [10] KUDA, František a Eva BERÁNKOVÁ. *Facility management v technické správě a údržbě budov*. Praha: Professional Publishing, 2012. ISBN 978-80-7431-114-7.
- [11] Zákon č. 361/2000 Sb., *o provozu na pozemních komunikacích* ve znění pozdějších předpisů
- [12] Prováděcí vyhláška č. 294/2015 Sb., *kteou se provádějí pravidla provozu na pozemních komunikacích* ve znění pozdějších předpisů
- [13] PETRIE, Gordon. An Introduction to the Technology: Mobile Mapping Systems. *GeoInformatics* [online]. Emmeloord: CMedia B. V, 2010, 13(1), 32-33,35-43 [cit. 2019-05-20]. ISSN 13870858. Dostupné z: <http://search.proquest.com/docview/744030407/>
- [14] DEUTSCH, Jiří. Mobilní mapování v architektuře. Brno, 2013. 56 s., 15 s. příl., Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav geodézie. Vedoucí práce doc. Ing. Vlastimil Hanzl, CSc.
- [15] Riegl VMX-450. *Compact Mobile Laser Scanning System* [online]. Austria: Riegl, 2015 [cit. 2019-05-20]. Dostupné z: [http://www.riegl.com/uploads/tx\\_pxriegldownloads/DataSheet\\_VMX-450\\_2015-03-19.pdf](http://www.riegl.com/uploads/tx_pxriegldownloads/DataSheet_VMX-450_2015-03-19.pdf)
- [16] Ladybug5 USB3. *Flir* [online]. Wilsonville: FLIR Systems, 2019 [cit. 2019-05-20]. Dostupné z: <https://www.flir.com/support/products/ladybug5-usb3#Specifications>
- [17] Cascade Trainer GUI. *Amin-ahmadi* [online]. WordPress, 2019 [cit. 2019-05-20]. Dostupné z: <http://amin-ahmadi.com/cascade-trainer-gui/>
- [18] About. *Python* [online]. Python Software Foundation, 2019 [cit. 2019-05-20]. Dostupné z: <https://www.python.org/>
- [19] Resources. *Python* [online]. Python Software Foundation, 2019 [cit. 2019-05-20]. Dostupné z: <https://www.python.org/doc/>
- [20] Annamraju, Abhishek Kumar & Singh, Akash. (2015). Analysis and Optimization of Parameters used in Training a Cascade Classifier. *Advances in Image and Video Processing* (ISSN: 2054-7412).3.25-48.10.14738/aivp.32.1152. Dostupné z: [https://www.researchgate.net/publication/275768392\\_Analysis\\_and\\_Optimization\\_of\\_Parameters\\_used\\_in\\_Training\\_a\\_Cascade\\_Classifier](https://www.researchgate.net/publication/275768392_Analysis_and_Optimization_of_Parameters_used_in_Training_a_Cascade_Classifier)

- [21] Plánování trasy. *Mapy* [online]. Seznam.cz, 2019 [cit. 2019-05-20]. Dostupné z: [www.mapy.cz](http://www.mapy.cz)
- [22] What is GIS. *Esri* [online]. Praha: ArcData, 2019 [cit. 2019-05-20]. Dostupné z: <https://www.esri.com/en-us/what-is-gis/overview>
- [23] DELUCA, Patrick. GIS is a Network that Creates Connections. In: *SpringShare* [online]. 2012 [cit. 2019-05-20]. Dostupné z: <https://lisdemo.libguides.com/c.php?g=586692>
- [24] Download. *QGIS.org* [online]. Creative Commons Attribution-ShareAlike, 2019 [cit. 2019-05-20]. Dostupné z: <https://www.qgis.org/en/site/index.html>
- [25] EXIF Definition. *Techterms* [online]. Sharpened Productions, 2012 [cit. 2019-05-20]. Dostupné z: <https://techterms.com/definition/exif>
- [26] Nahlížení do katastru nemovitostí. *Český úřad zeměměřický a katastrální* [online]. ČÚZK, 2010 [cit. 2019-05-10]. Dostupné z: [www.geoportal.cuzk.cz](http://www.geoportal.cuzk.cz)

## SEZNAM POUŽITÝCH ZKRATEK

AdaBoost	adaptivní zesílení (anglicky Adaptive Boosting)
AdMaS	pokročilé materiály, struktury a technologie (anglicky Advanced Materials, Structures and Technologies)
BSD	licence pro svobodný software (anglicky Berkeley Software Distribution)
CCD	zařízení s volnými náboji (anglicky Charge-Coupled Device)
GIS	Geografický informační systém (anglicky Geographic Information System)
GNSS	Globální družicový polohový systém (anglicky Global Navigation Satellite System)
GPS	Globální polohový systém (anglicky Global Positioning System)
GRAY	barevný model stupňů šedi (anglicky Gray scale)
HAAR	Haarovy příznaky (anglicky Haar Features)
HOG	histogram orientovaných gradientů (anglicky Histogram of oriented gradients)
IMU	inerciální měřicí jednotka (anglicky Inertial Measurement Unit)
LBP	lokální binární vzory (anglicky Local Binary Pattern)
OpenCV	knihovna s otevřeným zdrojovým kódem (anglicky Open Source Computer Vision)
RAM	operační paměť (anglicky Random – Access – Memory)
RGB	barevný model červená, zelená a modrá (anglicky Red, Green, Blue)
WGS-84	Světový geodetický systém 1984 (anglicky World Geodetic System 1984)

## SEZNAM OBRÁZKŮ A TABULEK

Obr. 1 Haarovy příznaky [4] .....	15
Obr. 2 Parametry aplikace opencv_createsamples [vlastní tvorba] .....	18
Obr. 3 Parametry aplikace opencv_annotation [vlastní tvorba] .....	19
Obr. 4 Parametry aplikace opencv_traincascade [vlastní tvorba] .....	20
Obr. 5 Parametry aplikace opencv_visualisation [vlastní tvorba].....	21
Obr. 6 Ukázka svislého dopravního značení [12] .....	23
Obr. 7 Ukázka vodorovného dopravního značení [12] .....	24
Obr. 8 Mobilní mapovací systém RIEGL VMX - 450 [vlastní tvorba] .....	26
Obr. 9 Řídící jednotka [vlastní tvorba] .....	26
Obr. 10 Odometr [vlastní tvorba].....	27
Obr. 11 Schéma měřicí hlavy mobilního mapovacího systému VMX – 450 [15].....	28
Obr. 12 Kamera Ladybug5 [16].....	29
Obr. 13 Ukázka prostředí programu Cascade Trainer GUI [17].....	29
Obr. 14 Ukázka negativních vzorů [vlastní tvorba] .....	31
Obr. 15 Ukázka vybraných značek [12].....	32
Obr. 16 Ukázka pozitivních vzorů [vlastní tvorba].....	32
Obr. 17 Ukázka skriptu na změnu barvy a velikosti [vlastní tvorba].....	34
Obr. 18 Ukázka skriptu na testování detekce [vlastní tvorba] .....	35
Obr. 19 Ukázka pozitivních detekcí [vlastní tvorba] .....	35
Obr. 20 Ukázka falešně pozitivních detekcí [vlastní tvorba] .....	36
Obr. 21 Trasa sběru snímků [21].....	38
Obr. 22 Ukázka skriptu na vytřídění hledaných fotek [vlastní tvorba] .....	39
Obr. 23 Příklady falešně pozitivních nálezů [vlastní tvorba].....	41
Obr. 24 Ukázka detekovaných značek [vlastní tvorba].....	41
Obr. 25 Struktura GIS [23].....	42
Obr. 26 Ukázka atributů prvku [vlastní tvorba] .....	43
Obr. 27 Základní nabídka programu QGIS [vlastní tvorba] .....	44
Obr. 28 Ukázka možného výstupu pro pasportizaci – výřez [vlastní tvorba] .....	45
Obr. 29 Ukázka zobrazení snímku vybraného prvku [vlastní tvorba] .....	45

Tab. 1 Stručný popis parametrů aplikace opencv_createsamples [vlastní tvorba].....	18
Tab. 2 Stručný popis povinných parametrů aplikace opencv_annotation [vlastní tvorba] .....	19
Tab. 3 Stručný popis parametrů aplikace opencv_traincascade [vlastní tvorba] .....	20
Tab. 4 Stručný popis povinných parametrů aplikace opencv_visualisation [vlastní tvorba].....	21
Tab. 5 Vybrané výsledky experimentálního testování [vlastní tvorba].....	36
Tab. 6 Časová náročnost tréninku a detekce [vlastní tvorba].....	37
Tab. 7 Výsledky testování klasifikátorů [vlastní tvorba] .....	40

## **SEZNAM ELEKTRONICKÝCH PŘÍLOH**

Příloha č. 1 Klasifikátory	1.1 Hlavní cesta
	1.2 Dej přednost v jízdě
Příloha č. 2 Datové vrstvy	2.1 Hlavní cesta
	2.2 Dej přednost v jízdě
Příloha č. 3 Vytřízené fotky	3.1 Hlavní cesta
	3.2 Dej přednost v jízdě