


**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**  
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA INFORMAČNÍCH TECHNOLOGIÍ**  
**ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ**  
FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

# **DETEKCE A ROZPOZNÁNÍ REGISTRAČNÍ ZNAČKY Z JEDOUcíHO VOZIDLA**

ON-BOARD LICENSE PLATE DETECTION AND RECOGNITION

**BAKALÁŘSKÁ PRÁCE**

BACHELOR'S THESIS

**AUTOR PRÁCE**

AUTHOR

**MARTIN TOMOVIČ**

**VEDOUcí PRÁCE**

SUPERVISOR

**Ing. JAKUB ŠPAÑHEL**

BRNO 2016

**Vysoké učení technické v Brně - Fakulta informačních technologií**

Ústav počítačové grafiky a multimédií

Akademický rok 2015/2016

**Zadání bakalářské práce**

Řešitel: **Tomovič Martin**

Obor: Informační technologie

Téma: **Detekce a rozpoznání registrační značky z jedoucího vozidla  
On-Board License Plate Detection and Recognition**

Kategorie: Zpracování obrazu

Pokyny:

1. Prostudujte základy zpracování obrazu. Zaměřte se zejména na problematiku rychlé detekce a rozpoznání registrační značky z jedoucího vozidla.
2. Vyberte vhodnou metodu a navrhnete možnosti řešení dané problematiky.
3. Experimentujte s vaší implementací a případně navrhnete vlastní modifikace metod.
4. Porovnejte dosažené výsledky a diskutujte možnosti budoucího vývoje. Zvažte další pokračování v rámci diplomové práce.
5. Vytvořte stručný plakát nebo video prezentující vaši bakalářskou práci, její cíle a výsledky.

Literatura:

- Dle pokynů vedoucího.

Pro udělení zápočtu za první semestr je požadováno:

- Splnění prvních tří bodů zadání.

Podrobné závazné pokyny pro vypracování bakalářské práce naleznete na adrese <http://www.fit.vutbr.cz/info/szz/>

Technická zpráva bakalářské práce musí obsahovat formulaci cíle, charakteristiku současného stavu, teoretická a odborná východiska řešených problémů a specifikaci etap (20 až 30% celkového rozsahu technické zprávy).

Student odevzdá v jednom výtisku technickou zprávu a v elektronické podobě zdrojový text technické zprávy, úplnou programovou dokumentaci a zdrojové texty programů. Informace v elektronické podobě budou uloženy na standardním nepřepisovatelném paměťovém médiu (CD-R, DVD-R, apod.), které bude vloženo do písemné zprávy tak, aby nemohlo dojít k jeho ztrátě při běžné manipulaci.

Vedoucí: **Špaňhel Jakub, Ing.**, UPGM FIT VUT

Datum zadání: 1. listopadu 2015

Datum odevzdání: 18. května 2016

**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**  
Fakulta informačních technologií  
Ústav počítačové grafiky a multimédií  
602 00 Brno, Božetěchova 2



doc. Dr. Ing. Jan Černocký  
vedoucí ústavu

## Abstrakt

Cielom tejto práce je vytvoriť aplikáciu na detekciu a rozpoznávanie registračných značiek, vhodnú pre spracovanie v reálnom čase. Práca obsahuje rozbor vybraných metód zaoberajúcich sa touto problematikou. Časť práce je venovaná súčasnej podobe registračných značiek v Českej republike. Pri tvorbe práce bola vytvorená nová dátová sada a bola implementovaná počítačová aplikácia. Aplikácia využíva existujúce knižnice určené pre počítačové videnie a strojové učenie. Jej úlohou je detekcia a rozpoznávanie značiek z videa. Detekcia je realizovaná pomocou kaskádového klasifikátora a rozpoznávanie pomocou perceptrónovej neurónovej siete. V závere je zhodnotená úspešnosť implementovaného riešenia.

## Abstract

This Bachelor's thesis aims to create an application for detection and recognition of license plates suitable for real-time processing. The work contains analysis of available methods. Part of the work is focused on present form of licence plates in Czech Republic. As a result of work, new data set was created and computer application was implemented. The application uses existing libraries designed for computer vision and machine learning with main purpose to detect and recognize licence plates from video. Detection is realized with help of cascade classifier, and recognition by Perceptron neural network. Final chapter subsequently contains evaluation of success rate of implemented solution.

## Klíčové slová

Detekcia registračných značiek, lokalizácia registračných značiek, rozpoznávanie registračných značiek, segmentácia znakov, české registračné značky, kaskádový klasifikátor

## Keywords

License plate detection, license plate localization, license plate recognition, character segmentation, Czech license plates, cascade classifier

## Citácia

TOMOVIČ, Martin. *Detekce a rozpoznání registrační značky z jedoucího vozidla*. Brno, 2016. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Špaňhel Jakub.

# Detekce a rozpoznání registrační značky z jedoucího vozidla

## Prehlásenie

Prehlasujem, že som túto bakalársku prácu vypracoval samostatne pod vedením pána Ing. Jakuba Špaňhela. Uviedol som všetky literárne pramene a publikácie, z ktorých som čerpal.

.....  
Martin Tomovič  
18. mája 2016

## Podakovanie

Rád by som poďakoval vedúcemu práce, Ing. Jakubovi Špaňhelovi, za jeho ochotu, cenné rady a odbornú pomoc.

© Martin Tomovič, 2016.

*Táto práca vznikla ako školské dielo na FIT VUT v Brně. Práca je chránená autorským zákonom a jej využitie bez poskytnutia oprávnenia autorom je nezákonné, s výnimkou zákonne definovaných prípadov.*

# Obsah

<b>1 Úvod</b>	<b>3</b>
<b>2 Metódy detekcie a rozpoznávania registračných značiek</b>	<b>4</b>
2.1 Registračné značky v Českej republike . . . . .	4
2.2 Detekcia a lokalizácia registračných značiek . . . . .	7
2.3 Segmentácia znakov . . . . .	11
2.4 Rozpoznávanie registračných značiek . . . . .	14
<b>3 Návrh aplikácie</b>	<b>18</b>
3.1 Aspekty návrhu . . . . .	18
3.2 Defekty registračných značiek a problémové prípady . . . . .	18
3.3 Detekcia a lokalizácia registračnej značky . . . . .	20
3.4 Segmentácia a rozpoznávanie znakov . . . . .	21
<b>4 Implementácia a vyhodnotenie navrhnutého systému</b>	<b>23</b>
4.1 Použité nástroje . . . . .	23
4.2 Dátová sada . . . . .	23
4.3 Výsledná aplikácia . . . . .	24
4.4 Zhodnotenie úspešnosti . . . . .	27
<b>5 Záver</b>	<b>29</b>
<b>Literatúra</b>	<b>30</b>

# Zoznam obrázkov

2.1	Registračné značky pre všetky cestné motorové a prípojné vozidla. Zdroj: [6].	5
2.2	Ďalšie typy štandardných registračných značiek. Zdroj: [6].	6
2.3	Stará registračná značka spred 17. júla 2001. Zdroj: [2].	6
2.4	Registračná značka na prianie. Zdroj: [6].	6
2.5	Zvláštne registračné značky. Zdroj: [6].	7
2.6	Schéma kaskádového klasifikátora.	8
2.7	Haarove príznaky použité v metóde Viola Jones.	9
2.8	Ukážka LBP príznakov. Zdroj: [11]	10
2.9	Ukážka reprezentácie integrálnym obrazom.	10
2.10	Ukážka prahovania registračnej značky.	12
2.11	Ukážka tvarov hrán.	12
2.12	Mapá hrán registračnej značky.	13
2.13	Vertikálna a horizontálna projekcia značky. Zdroj: [14].	14
2.14	Biologický neurón.	15
2.15	Schéma perceptrónu.	16
2.16	Ukážka neurónovej siete s feed-forward zapojením.	17
3.1	Schéma navrhnutého systému.	19
3.2	Problematické registračné značky.	19
3.3	Ďalšie problémy, ktoré musíme brať do úvahy.	19
3.4	Výrez s registračnou značkou a jeho časť, ktorá nás zaujíma.	21
4.1	Ukážka pozitívnych a negatívnych vzorkov dátovej sady pre detekciu.	24
4.2	Ukážka vzorkov dátovej sady pre rozpoznávanie znakov.	24
4.3	Ukážka výslednej aplikácie.	25
4.4	Oblasť záujmu - ROI na snímke z videa.	26
4.5	Všetky kontúry vo výreze a kontúra najväčšieho objektu.	26
4.6	Obdĺžnik okolo významnej oblasti a výrez so zarovnanými znakmi.	26
4.7	Kontúry znakov a obdĺžniky so znakmi.	27

# Kapitola 1

## Úvod

Detekcia a rozpoznávanie registračných značiek vozidiel je súbor metód, ktoré slúžia na čítanie registračných značiek z obrazových dát. Využíva optické rozpoznávanie znakov na prevod písmen a číslíc na značke do formy ďalej využiteľnej v automatizácii mnohých činností. V dnešnej technologickej dobe a s narastajúcim počtom vozidiel nachádza množstvo využití [1]. V kombinácii s vhodnými databázami nám môže pomôcť pri monitorovaní dopravy, hľadanií odcudzených vozidiel, kontrole parkovného, či mýtného poplatku a pod.

Táto práca sa venuje spracovaniu snímok z idúceho vozidla v reálnom čase. Na snímkach sa lokalizuje registračná značka a je rozpoznávaný jej text. Popisuje náš návrh implementácie aplikácie, ktorú sme pri jej písaní vytvárali. Pri práci využívame znalosti z oblastí počítačového videnia a strojového učenia.

V kapitole 2 sú popísané registračné značky Českej republiky a sú rozobrané metódy umožňujúce detekciu, lokalizáciu a rozpoznanie značky z obrazu. Kapitola 3 obsahuje náš návrh systému, ktorý sme pri písaní práce implementovali. Popisuje tiež aké metódy sme v našej aplikácii zvolili a problémy, na ktoré si treba dať pozor pri problematike registračných značiek. V kapitole 4 popisujeme našu implementáciu. Kapitola tiež obsahuje zhrnutie úspešnosti našej aplikácie.

## Kapitola 2

# Metódy detekcie a rozpoznávania registračných značiek

### 2.1 Registračné značky v Českej republike

Registračné značky slúžia na jednoznačnú identifikáciu motorových a prípojných vozidiel. Každý štát má definovanú podobu vydávanej registračnej značky. V niektorých štátoch je možné zo značky rýchlo určiť oblasť, v ktorej bola vydaná. Tieto informácie nám môžu pomôcť pri monitorovaní dopravy, odhaľovaní kriminálnej činnosti, ale sú tiež často využívané na vstupných bránach na povolenie vstupu do objektov, napr. parkovísk.

České registračné značky sú vydávané podľa zákona č. 56/2001 Sb. [5] a ich podoba je predpísaná vyhláškou č. 343/2014 Sb. [6] o registrácii vozidiel. Delia sa na:


- štandardné
- na pranie
- zvláštne

Povolené znaky na registračných značkách sú všetky arabské číslice (0, 1, 2, 3, 4, 5, 6, 7, 8, 9) a písmená A, B, C, D, E, F, H, I, J, K, L, M, N, P, R, S, T, U, V, X, Y, Z. Všimnime si úmyselné vynechanie niektorých písmen z dôvodu možnej zameniteľnosti s inými znakmi. Existuje viac tvarov registračných značiek. Presný počet znakov registračnej značky nie je určený, no pohybuje sa v rozmedzí 5-8 znakov v závislosti od typu. Značku vždy tvorí obdĺžnik so zaoblením v rohoch s polomerom 10 mm. Väčšina obsahuje pri ľavom okraji modrý pruh s vyznačením znaku Európskej únie a so štátnou poznávacou značkou Českej republiky. Registračné značky taktiež obsahujú miesto na nálepku o technickej prehliadke. Umiestnenie registračnej značky musí byť také, aby bola čitateľná v nezniženej viditeľnosti na vzdialenosť minimálne 40 m (neplatí pre menšiu značku mopedov). Vyhláška určuje aj presne povolené miesta pre umiestnenie značky na vozidle. Všetky značky s výnimkou značky pre jazdu z miesta predaja do miesta registrácie vozidiel musia mať reflexné vlastnosti. Ako si môžeme všimnúť na obrázku 2.1 počet riadkov na značkách a veľkosti sú rôzne z dôvodu rôznorodosti miest na vozidlách určených pre značky. Toto platí pri väčšine typov značiek, nie len pri type zobrazenom na obrázku.

Česká republika patrí medzi štáty, v ktorých je možné zo značky rýchlo určiť, v ktorej oblasti bola vydaná. Konkrétne je možné určiť kraj pomocou prvého písmena (nie číslice) značky. Každý kraj má pridelené jedno písmeno, napr. Praha má A, Juhomoravský kraj B.



Ďalšie je možné nájsť v spomínanej vyhláške. Pri historických a športových vozidlách kraj určuje dvojica číslíc. Od 1. januára 2015 sa po zmene majiteľa nemení registračná značka, pokiaľ je vozidlo predtým registrované v inom kraji, takže už nie je možné s istotou určiť miesto trvalého pobytu majiteľa.



Obr. 2.1: Registračné značky pre všetky cestné motorové a prípojné vozidlá. Zdroj: [6].

### 2.1.1 Štandardné registračné značky

Do tejto kategórie patria registračné značky určené pre všetky cestné motorové a prípojné vozidlá (obr. 2.1). S nimi sa v doprave stretávame najčastejšie.

Ďalej sem patria značky pre zvláštne vozidlá (napr. traktory), vozidlá osôb používajúcich diplomatické výsady, imunity podľa medzinárodnej zmluvy (diplomatická značka) a pre vozidlá vyvezené do zahraničia (obr. 2.2). Tieto značky majú mierne odlišný vzhľad od prvej spomínanej. Najmenej sa líši diplomatická značka, ktorá využíva namiesto čierneho písma tmavo modré. Vždy sa skladá z dvojíc písmen CD, XX, XS alebo HC, ktoré určujú funkciu majiteľa alebo prevádzkovateľa. Značky pre zvláštne vozidlá majú namiesto bieleho žltý podklad a neobsahujú modrý pruh. Ten neobsahujú ani značky pre vozidlá vyvezené do zahraničia a od prvého typu sa líšia aj pridaným červeným pruhom na vyznačenie platnosti.

Stále sa môžeme stretnúť aj so starými registračnými značkami, vydávanými pred 17. júlom 2001 (obr. 2.3). Autobusy a nákladné vozidlá v nej majú nahradený biely podklad žltým. Na rozdiel od súčasných značiek obsahuje aj znak pomlčky.



Obr. 2.2: Ďalšie typy štandardných registračných značiek. Zdroj: [6].



Obr. 2.3: Stará registračná značka spred 17. júla 2001. Zdroj: [2].

### 2.1.2 Registračné značky na pranie

Registračné značky na pranie je možné v Českej republike získať od roku 2016. Na získanie takejto značky treba uhradiť stanovený poplatok navyše a treba si vybrať text, ktorý je jedinečný. Počet znakov základnej značky na pranie je 8 znakov (obr. 2.4). Pri značkách na motocykle je to 7 znakov a na mopedy 5 znakov.



Obr. 2.4: Registračná značka na pranie. Zdroj: [6].

### 2.1.3 Zvláštne registračné značky

Do tejto kategórie patria značky pre jazdu z miesta predaja do miesta registrácie vozidiel, pre manipulačný, skúšobný prevoz, pre historické, športové vozidlá a značky určené k umiestneniu na nosné zariadenie pripojiteľné k vozidlu (napr. nosiče bicyklov zakrývajúce značku na vozidle). Všetky tieto typy v základnej veľkosti sú zobrazené na obrázku 2.10.

Značka pre jazdu z miesta predaja do miesta registrácie vozidiel môže byť ako jediná vyrobená z nereflexného materiálu, konkrétne z bledozeleného papiera. Rovnako ako pri značke pre manipulačný prevoz je na nej prvý znak písmeno kódu kraja. Manipulačná značka, značka pre skúšobnú prevádzku, pre historické a športové vozidlá je tvorená bielym podkladom so zelenými znakmi a rámčekom. Značka pre skúšobnú prevádzku vždy začína znakom F. Pri značkách pre historické a športové vozidlá sú prvé dva znaky číslice vyjadrujúce kraj, v ktorom boli vozidlá registrované. 3. znak je pri historických vozidlách V a pri športových R. Značka na nosné zariadenie je podobná ako štandardná registračná značka pre osobné vozidlá, na mieste kam sa lepia nálepky o technickej kontrole sú však umiestnené dva znaky hviezdičky.



Obr. 2.5: Zvláštne registračné značky. Zdroj: [6].

## 2.2 Detekcia a lokalizácia registračných značiek


Medzi najznámejšie metódy detekcie patrí prístup, ktorého autorami sú Paul Viola a Michael Jones [15] a podľa ktorých je aj pomenovaný. Pôvodne bol navrhnutý pre detekciu tváří, no vykazuje dobré výsledky aj pri iných objektoch a taktiež pri detekcii registračných značiek. Páni Viola a Jones si uvedomili, že rýchlosť učenia a aj následnej detekcie závisí na rýchlosti klasifikácie objektov, ktoré nespádajú do množiny hľadaných, pretože sa ich nachádza v obrázku omnoho viac. Ich prístup pracuje s obrázkami v odtieňoch šedej a má 3 myšlienky, ktoré treba spomenúť - algoritmus AdaBoost, Haarove príznaky a integrálny obraz. Tento prístup publikovali v roku 2001. Odvtedy vzniklo mnoho modifikácií, napr. zavedením iných typov príznakov alebo využitím iných algoritmov pre boosting. O týchto pojmoch sa viac dozvedieme v tejto sekcii.

Tento spôsob detekcie objektu funguje na princípe klasifikácie pod-okien v obraze. Klasifikácia, inak povedané triedenie, rozdeľuje pod-okná do dvoch kategórií – pod-okná, ktoré pravdepodobne nie sú a ktoré pravdepodobne sú hľadaný objekt. Po klasifikovaní pod-okna, ktoré je pravdepodobne objekt, môžeme určiť polohu a veľkosť pod-okna v danom obraze. Tým sme objekt lokalizovali.

### 2.2.1 Kaskádový klasifikátor

Klasifikácia je v strojovom učení proces, ktorého úlohou je triedenie pozorovaných dát do kategórií. Klasifikátor je potom algoritmus, ktorý tento proces implementuje. Medzi klasifikátory patrí aj kaskádový klasifikátor, ktorý je tvorený viacerými klasifikátormi za sebou v tzv. kaskáde. Tento klasifikátor, tak ako ho definovali, je binárny, čo znamená, že rozdeľuje vzorky do dvoch kategórií. Kategória, ktorá nás zaujíma je tá, kde sú zaradené vzorky, ktoré klasifikátor klasifikoval ako vzorky, ktoré sú zároveň hľadaný objekt. Do druhej kategórie sú zaredané všetky ostatné vzorky. Kaskáda je degenerovaný rozhodovací strom [8]. Klasifikátory v kaskáde sa nazývajú slabé klasifikátory, pretože ich úlohou je postupne vyradovať vzorky, ktoré nepatria do hľadanej množiny, no jednotlivo aj mnoho takýchto vzorkov „prepúšťajú“. Spolu v kaskáde však tvoria tzv. silný klasifikátor, ktorý dosahuje dobré hodnoty úspešnosti. Každý slabý klasifikátor sa totižto zameriava len na malé množstvo príznakov, ktoré testuje. Hľadané objekty však môžu mať veľké množstvo spoločných príznakov. Postupné vyradovanie a jednoduchosť slabých klasifikátorov spôsobujú, že je táto metóda klasifikácie pomerne rýchla a zároveň dosahuje dobrú úspešnosť.

Kaskádou klasifikátorov neprechádza celý obraz ale len pod-okná obrazu, čo robí detekciu výpočtovo náročnou. Z tohto dôvodu sa používajú metódy na redukovanie množstva pod-okien, aby nemuseli klasifikátorom prechádzať všetky.



Obr. 2.6: Schéma kaskádového klasifikátora.

### 2.2.2 Metódy redukovania množstva pod-okien

Jednou zo základných metód redukovania počtu pod-okien pri klasifikácii je určenie najmenej a najväčšej nožnej veľkosti pod-okna. Taktiež je možné určiť tzv. scale faktor, to znamená o koľko sa zväčší prehľadávacie okno pri prehľadávaní s inou veľkosťou okna. Udáva sa formou násobku predchádzajúceho okna.

Ďalšou možnosťou je určenie ROI (anglicky *Region of interest* - oblasť záujmu). Zábery z kamery umiestnenej vo vozidle môžu obsahovať časti vozidla, napr. časť kapoty, spätné zrkadlo, z dôvodu, že nebolo možné kameru nastaviť inak. Tiež si môžeme všimnúť, že vo veľkej väčšine snímkov sa vo vrchnej časti nachádza iba obloha, alebo že registračné značky sú zvyčajne umiestnené v podobnej výške. Veľká väčšina detekcií by sa teda objavovala len v určitej časti obrazu – oblasti záujmu. Objekty následne vyhľadávame len v tejto určenej oblasti. Pri určovaní ROI však musíme byť opatrní a zohľadniť všetky situácie, ktoré môžu nastať.


### 2.2.3 Adaboost

Adaptive boosting alebo skrátene AdaBoost slúži na vytvorenie kaskádového klasifikátora. Publikovali ho v roku 1995 Yoav Freund a Robert Schapire [7]. V roku 2003 im zaňho bola udelená Gödelova cena. Tento algoritmus patrí medzi metódy tzv. boostingu. Cieľom boostingu je zlepšenie klasifikačnej presnosti ľubovoľného algoritmu strojového učenia [13]. Väčšinou pomocou hľadania viacerých slabých klasifikátorov, ktoré spolu utvoria silný klasifikátor. Slabý klasifikátor je obvykle nejaká jednoduchá funkcia, s mierne väčšou úspešnosťou ako náhodná klasifikácia.

Algoritmus AdaBoost tiež funguje na tomto princípe. Jeho výnimočnosť spočíva v používaní váh pre tréningové dáta a ich špecifickom upravovaní v každej iterácii. Na začiatku majú všetky dáta rovnakú váhu. Každá iterácia sa skladá z viacerých krokov. Najprv sa vyberie slabý klasifikátor, s najnižšou chybou pri aktuálnych váhach. Skontroluje sa, či nie je chyba väčšia ako 50%, pretože by algoritmus mohol prestať konvergovať. Následne sa aktualizujú váhy tréningových dát, podľa toho ako úspešne prešli slabým klasifikátorom. Čím menšia úspešnosť, tým väčšia váha. V ďalšej iterácii sa teda bude hľadať slabý klasifikátor, ktorý bude viac brať do úvahy menej úspešné dáta. Adaboost exponenciálne redukuje tréningovú chybu v závislosti na rastúcom počte klasifikátorov [13]. Výsledkom AdaBoostu je lineárna kombinácia jednoduchých slabých klasifikátorov.

### 2.2.4 Haarove príznaky


Haarove príznaky sú pomenované podľa vlnky, z ktorej vychádzajú – Haarovej vlnky. Vlnka je funkcia, ktorá sa používa na rozklad funkcií a signálov – fyzikálnych veličín závislých na čase. Haarove príznaky, ktoré využívajú Viola a Jones su zobrazené na obrázku 2.12. V ich metóde sú použité ako slabé klasifikátory v algoritme AdaBoost. Hodnota príznaku je počítaná ako rozdiel sumy pixelov svetlej oblasti a sumy pixelov tmavej oblasti. Príznaky sú počítané pre všetky pod-okná obrazu. V každom obraze síce existuje veľký počet pod-okien, no integrálna reprezentácia obrazu, vysvetlená v ďalšej sekcii značne urýchľuje určenie hodnôt príznakov.



Obr. 2.7: Haarove príznaky použité v metóde Viola Jones.

Príznaky  $A$ ,  $B$  slúžia na detekciu hrán, príznak  $C$  na detekciu čiar a  $D$  na detekciu diagonálnych línií. Existujú aj rozšírené sady Haarových príznakov, v ktorých sa pridáva centrálny príznak na detekciu bodov alebo sa využíva natočenie príznakov.

Pri tejto problematike treba spomenúť aj iné príznaky využívané v počítačovom videní na detekciu objektov. Medzi najznámejšie patria SIFT, SURF, HoG a LBP. Pri vytváraní práce sme sa stretli najmä s príznakmi LBP (anglicky *Local binary patterns* - miestne binárne vzory) [10]. Počítajú sa pre každý pixel obrazu. Ich princípom je prahovanie okolných bodov s hodnotou prahu určenou jasom stredového bodu, čo nám umožňuje detekovať základné objekty ako body, čiary, hrany a rohy. Využívajú binárne operácie a pomerne jednoduché výpočty, čo sa prejavuje na ich rýchlosti a vhodnosti použitia v real-time programoch.



Obr. 2.8: Ukážka LBP príznakov. Zdroj: [11]

### 2.2.5 Integrálny obraz

Integrálny obraz je reprezentácia obrazu, v ktorej je hodnota každého bodu určená súčtom predchádzajúcich hodnôt intenzít v obraze, v smere doľava a hore až k bodu 0, 0 (obr. 2.9). Integrálnu hodnotu na súradniciach  $x, y$  môžeme vypočítať vzťahom:

$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (2.1)$$


Na vytvorenie integrálneho obrazu nám stačí len jeden prechod obrazom s použitím rovnice:

$$ii(x, y) = i(x, y) + ii(x - 1, y) + ii(x, y - 1) - ii(x - 1, y - 1) \quad (2.2)$$

Následne nám táto reprezentácia umožní rýchly výpočet Haarových príznakov zo vstupného obrazu. Sumu  $S$  pixelov danej, ľubovoľne veľkej ( $h$  - výška,  $w$  - šírka) a ľubovoľne umiestnenej ( $x, y$  - súradnice ľavého horného rohu) oblasti môžeme jednoducho vypočítať pomocou dvoch operácií sčítania a jedenej operácie odčítania:

$$S = (ii(x - 1, y - 1) + ii(x - 1 + w, y - 1 + h)) - (ii(x - 1, y - 1 + h) + ii(x - 1 + w, y - 1)) \quad (2.3)$$

V rovniciach 2.1, 2.2 a 2.3  $i$  značí hodnotu intenzity bodu a  $ii$  integrálnu hodnotu bodu. Taktiež treba poznamenať, že platí:  $ii(-1, y) = 0, ii(x, -1) = 0$



Obr. 2.9: Ukážka reprezentácie integrálnym obrazom.

### 2.2.6 Ďalšie metódy lokalizácie registračných značiek

Pri probléme lokalizácie je nutné spomenúť aj ďalšie postupy, s ktorými sme sa pri vytváraní práce stretli. Popisované metódy nevyužívajú strojové učenie a fungujú na princípe

využívania znalostí, ktoré o značkách máme. Môžu využívať farebné vlastnosti značiek, ich rozmery a veľkosť, veľký počet hrán na malom priestore (znaky registračnej značky) a pod. Dajú sa pomocou nich dosiahnuť dobré výsledky, či už rýchlostné alebo v rámci úspešnosti a nepotrebnú tréningovú sadu na učenie sa. Vyžadujú však dobrú analýzu všetkých možností, ktoré môžu nastať a riešenia nie sú veľmi variabilné. Problémom týchto prístupov môže byť citlivosť na svetelné podmienky, rôzne defekty registračných značiek alebo ich natočenie, skosenie a pod.

Zaujímavá je metóda založená na analýze farieb. Táto metóda vyhľadáva modrý pásik pri ľavom okraji registračných značiek. Tento pásik vyjadruje členstvo krajiny, v ktorej boli vydané, v Európskej únii. Tento pásik sa však nenachádza na starších typoch registračných značiek, výhodou môže byť naopak schopnosť detekcie najpoužívanejších registračných značiek všetkých členských štátov EÚ. Pre zníženie falošných detekcií je možné použiť techniky kontrolujúce či sa v modrom pásiku nachádza znak európskej únie a kontrolovať pomery strán a orientáciu obdĺžnika s modrým pásikom.

Ďalšie prístupy lokalizácie registračnej značky sú založené na segmentácii obrazu tak, ako je opísaná v kapitole 2.3. Dá sa aplikovať aj na celý vstupný obraz a hľadať v ňom oblasti s určitými vlastnosťami. Najjednoduchším princípom je hľadať oblasti, ktoré idú aproximovať štvoruholníkom, majú určitý pomer strán. Ďalej je možné hľadať oblasti len s určitou veľkosťou alebo natočením, podľa toho aké značky sa budú vyskytovať vo vstupných dátach. To sa dá dobre využiť napríklad pri fixných kamerách. Na ich záberoch sú značky väčšinou pod podobným uhlom, s podobným rozsahom veľkostí a pod.

## 2.3 Segmentácia znakov

Výstupom detektora je výrez s registračnou značkou. Ten obsahuje jednotlivé znaky použité v značke, ktoré sú umiestnené na určitom pozadí. Úlohou segmentácie je oddeliť významné oblasti – znaky, aby mohli byť ďalej spracovávané. Ak je segmentácia úspešná a podarilo sa oddeliť všetky významné objekty, jedná sa o úplnú segmentáciu. Segmentácia, ktorá len obraz rozdeľuje na homogénne oblasti, napr. z hľadiska jasu, farby a pod. sa nazýva čiastočná. Pre kompletnú segmentáciu je často potrebná spolupráca s vyššou úrovňou spracovania, ktorá využíva konkrétne znalosti o probléme.


Pri riešení segmentácie znakov registračnej značky sme sa stretli s myšlienkami spomenutými v tejto sekcii.

### 2.3.1 Prahovanie

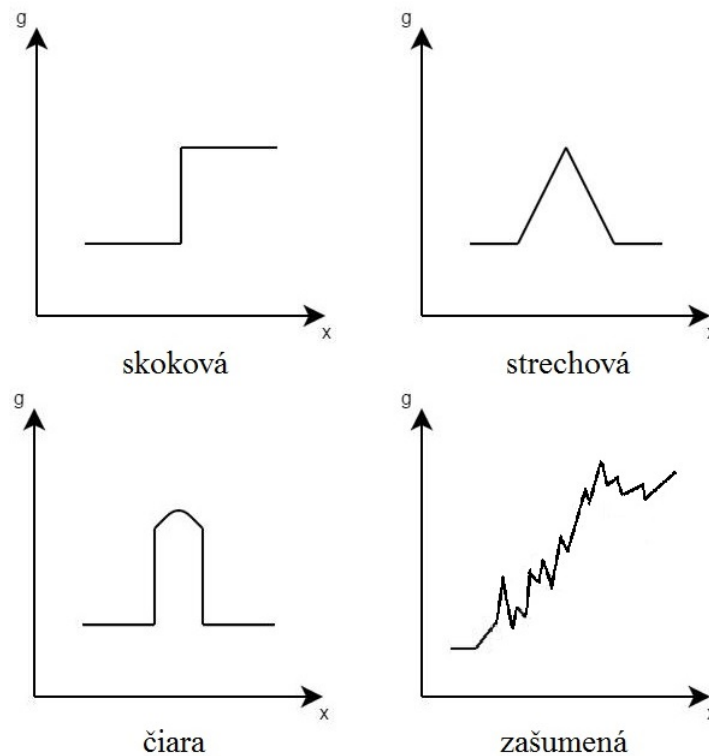
Metóda prahovania patrí medzi základné postupy segmentácie. Využíva skutočnosť, že veľa objektov či oblastí je charakterizovaných konštantnou odrážavosťou a pohltivosťou svojho povrchu. Oddeluje oblasti na základe jasov jednotlivých bodov. Táto metóda je použiteľná aj na problém registračných značiek, pretože je pre ne typický veľký kontrast medzi znakmi na značke a pozadím. Je určená konštanta nazývaná prah, ktorá rozdeľuje obraz na oblasti s nižšou hodnotou jasu ako prah a s vyššou hodnotou jasu ako prah. Túto metódu môžeme popísať funkciou:

$$f(x) = \begin{cases} 0 & \text{ak } x < \text{prah} \\ 1 & \text{ak } x \geq \text{prah} \end{cases} \quad (2.4)$$

Kde  $x$  je hodnota jasů a  $prah$  je hodnota prahu. Pri prahovaní treba správne zvoliť optimálny prah, s tým nám môže pomôcť napríklad metóda Otsu [12]. Tá stanoví optimálny prah pre celý obrázok, pomocou znižovania spoločného rozptylu, aby sa čo najlepšie oddelilo pozadie. Práh však môže byť určený jednotlivo pre každý pixel v závislosti od okolia. Vtedy hovoríme o adaptívnom prahovaní. Svoje uplatnenie nachádza hlavne pri obrazoch s nerovnomerným osvetlením, tieňmi a pod. Práve s týmito problémami sa môžeme stretnúť aj pri segmentácii registračných značiek.



Obr. 2.10: Ukážka prahovania registračnej značky.



Obr. 2.11: Ukážka tvarov hrán.



### 2.3.2 Detekcia hrán

Medzi najpoužívanejšie metódy segmentácie patria aj metódy založené na informáciách o hranách v obraze. Oddeľujú v obrazoch významné oblasti a sú čiastočne invariantné voči zmene osvetlenia. Delenie funguje na princípe hľadania miest v obraze, v ktorých dochádza k nespojitým zmenám nejakých hodnôt. Ako túto hodnotu budeme uvažovať hodnotu jasú. Ako si môžeme všimnúť na obrázku 2.11 hrana môže byť rozličných tvarov. Reálne sa stretáme len zo zašumenými hranami, ostatné tvary obrazových funkcií s hranou sú idealizované. Hrana teda popisuje rýchlosť zmeny a smer najväčšieho rastu spojitej obrazovej funkcie (matematický model obrazu). Hranové body sú body s veľkým modulom gradientu tejto funkcie. Gradient je teda vektorová veličina určujúca smer rastu funkcie a veľkosť rastu.

Hrany je potrebné v obraze detekovať, na čo existuje niekoľko prístupov. Všetky sú veľmi citlivé na šum obrazu, takže je nutné predspracovanie vstupného obrazu. To môžeme realizovať rôznymi filtermi, napr. Gaussovým alebo mediánovým. Keďže uvažujeme hľadanie hrán na základe náhlych zmien jasú medzi bodmi v obraze, musí byť ako vstup použitý obraz v odtieňoch šedej. Jednoduché detektory využívajú na určenie zložiek gradientu tzv. hranové operátory. Sú to vlastne konvolučné jadrá. Konvolúcia je metóda, ktorá postupne prechádza obraz po bodoch a počíta nové hodnoty bodov využívajúc ich okolie. Výsledkom konvolúcie obrazu s daným hranovým operátorom - konvolučným jadrom je hľadaná zložka gradientu. Okolie je však predom určené daným operátorom. Nastáva problém určenia správneho operátora a veľkosti okolia. Tento problém rieši Cannyho hranový detektor [4], ktorý hľadá najvhodnejší hranový operátor.

Výstupom z detektora je obraz nazývaný mapa hrán. Tento obraz je pre segmentáciu prakticky nepoužiteľný, preto je potrebné ďalšie spracovanie, ktoré spája hrany do reťazí, ktoré lepšie zodpovedajú priebehu hraníc objektov, inak povedané kontúr.

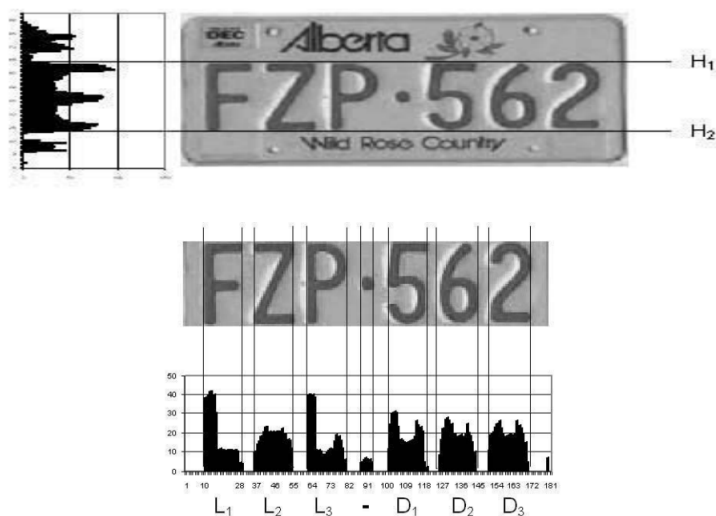


Obr. 2.12: Mapa hrán registračnej značky.

### 2.3.3 Segmentácia pomocou vertikálnej a horizontálnej projekcie

Základom tejto metódy [14] je vytvorenie grafov, v ktorých je na osi x číslo riadku alebo stĺpca a na osi y počet pixelov s danou vlastnosťou. Vstupom tejto metódy je väčšinou binárny obrázok, ktorý vznikol prahovaním. Metódy na určenie prahov a zlepšenie výsledkov su popísané v sekcii 2.3.1.

Registračná značka obsahuje v horizontálnom i vertikálnom smere tmavé a svetlé miesta. Po správnom prahovaní by mali byť znaky tmavé a ich okolie resp. pozadie svetlé. Mapovaním počtu tmavých pixelov v riadku alebo stĺpci do grafu nám vznikne graf. Riadky a stĺpce, v ktorých sa nachádzajú znaky, by mali obsahovať viac čiernej farby ako miesta, kde sa nenachádzajú. Ideálne, pri žiadnom šume a žiadnych vzniknutých artefaktoch, by mal byť počet čiernych pixelov medzi znakmi nulový. Registračná značka však obsahuje napr. nálepky o technickej kontrole, modrý pás členstva v EÚ alebo rôzne artefakty vzniknuté nedokonalým prahovaním, tieňom, defektami značky a pod. Preto je potrebné pri analýze grafov uvažovať aj tieto možnosti a určiť si hranice od akej hodnoty čiernej farby je na obrázku pravdepodobne hľadaný znak. Keďže máme vytvorené grafy projekcie pre horizon-



Obr. 2.13: Vertikálna a horizontálna projekcia značky. Zdroj: [14].

tálny i vertikálny smer, sme schopní určiť presnú polohu znakov. Problémy môžu nastať ak je značka natočená alebo skosená a pod. Vtedy je potrebné pred spracovaním značku otočiť a skosiť vzhľadom na perspektívu v akej bola značka zachytená.

## 2.4 Rozpoznávanie registračných značiek

### 2.4.1 Existujúce riešenia

Najjednoduchšou možnosťou ako rozpoznať znaky na registračnej značke je využitie už existujúcich knižníc a softvérových riešení na OCR. Takmer všetky sú však vytvárané hlavne za účelom rozpoznávania súvislého textu. Zahŕňajú v sebe prvky strojového učenia a počítačového videnia, no mnohé riešenia posudzujú aj lingvistiku. To znamená, že vyhľadávajú v texte súvislé slová a vety, pri rozpoznávaní berú ohľad aj na správnosť slov a stavbu vety. Taktiež sa snažia rozpoznávať diakritiku. To je pri registračných značkách nežiadúce, keďže sú len postupnosťou znakov z malej podmnožiny všetkých znakov, ktoré sú tieto riešenia schopné rozpoznať. Sled znakov v značke je pre pozorovateľa na prvý pohľad úplne náhodný, takmer bez žiadnych pravidiel.

Existujú riešenia určené na rozpoznávanie textu písaného rukou a riešenia na rozpoznávanie tlačeného textu. Pri tlačenom texte je často treba tieto riešenia dotrénovať na konkrétny font písma pomocou dátovej sady. Bez dotrénovania by mohli mať zvýšenú chybovosť. Vďaka svojej robustnosti a prepracovanosti však môžu naopak dosahovať dobrú úspešnosť. Nevýhodou pri takto robustných a variabilných riešeniach sú však nižšie rýchlosti spracovania.

Vačšina kvalitných aplikácií je chránených licenciami a poskytovaných len za poplatok. Existujú ale aj aplikácie, ktoré sú dostupné zdarma. Medzi opensource riešenia patria napr. GOCR, FreeOCR, VietOCR alebo Tesseract OCR. Posledný spomenutý je vyvíjaný známou spoločnosťou Google.

### 2.4.2 Template matching

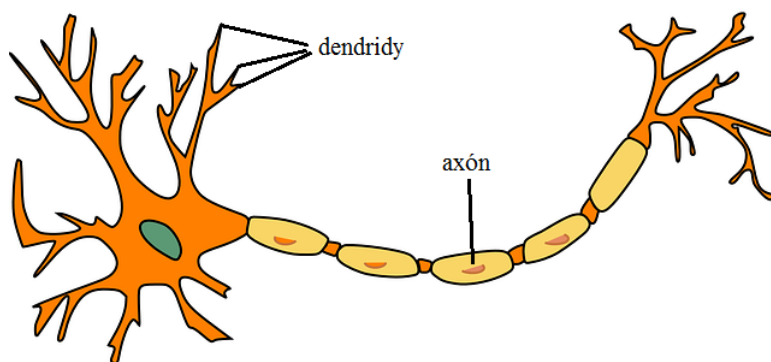
Template matching alebo porovnanie so vzorom, funguje na princípe porovnávania vstupného obrazu s predom určeným vzorom. Pri rozpoznávaní registračnej značky teda máme vzory povolených znakov, ktoré porovnávame s výrezmi získanými pomocou segmentácie. Na určenie zhody sa používa viacero metód [3], napr. metóda rozdielu štvorcov. Využíva vzorec:

$$R(x, y) = \sum_{x', y'} [T(x', y') - I(x + x', y + y')]^2 \quad (2.5)$$

Výsledkom porovnávania je číslo  $R$ , ktoré čím je bližšie k 0, tým je zhoda väčšia.  $T$  je vzorový obraz a  $I$  je obraz s objektom na identifikáciu. Na vstupnom obraze bude s najväčšou pravdepodobnosťou znak, ktorý dosahuje najväčšej zhody – číslo  $R$  je najbližšie k 0. Vzorový obraz je možné po obraze posúvať. To by sa dalo využiť, vynechať fázu segmentácie a použiť túto metódu už na celý výrez značky. Táto metóda však vyžaduje, aby objekt na vstupnom obraze nebol zošikmený, otočený alebo nejako deformovaný. Objekt na obraze tiež musí byť rovnakej veľkosti ako je objekt vo vzorovom obraze. V opačnom prípade by mohol tento prístup dosahovať veľkú chybovosť. Vstupné obrazy je teda nutné patrične predspracovať.

### 2.4.3 Neurónové siete


Neuróny v živých organizmoch umožňujú viesť signály a reagovať na ne. Skladajú sa z dendridov a výbežku nazývaného axón (obr. 2.14). Dendridy slúžia na prijímanie signálov z okolitých neurónov, axón slúži na vysielanie signálov. Axón je na konci rozvetvený, takže je schopný vyselať signály do niekoľkých ďalších neurónov. Rýchlosť prenosu je u človeka 5-125 m/s. Vnútri nervovej bunky vzniká potenciál pre každý signál, ak je tento potenciál dostatočne veľký, bunka pošle signál pomocou axónu ďalej. Spojenie, ktoré odoslanie ďalej realizuje sa nazýva synapsia, je to teda spojenie axónu s dendridom iného neurónu.



Obr. 2.14: Biologický neurón.

Umelé neuróny, tvoriace neurónové siete fungujú podobne. Sú vlastne abstrakciou biologických neurónov. Neurónová sieť je teda abstrakciou neurónového systému. Umelé neuróny je možné matematicky popísať a teda aj implementovať do formy programu.

Základný model neurónu sa nazýva perceptrón. Jeho schéma je zobrazená na obrázku 2.15. Vstupov môže mať veľa, každý vstup má zároveň určenú váhu. Príkladom vstupov




Obr. 2.15: Schéma perceptrónu.

môžu byť napr. jednotlivé pixely obrázku. Hodnoty vstupov sa vynásobia ich váhami. Následne sú spočítané. Ďalej sa postupuje podľa typu perceptrónu. Môže byť diskretný alebo spojitý. Diskretný perceptrón pracuje nespojito, jeho výstupy sú teda len 2 možné hodnoty. Tie sa určia pomocou hodnoty  $\Theta$ , ktorá sa nazýva prah excitácie. Excitácia alebo vzбудenie je v prenesenom význame na biologický neurón stav kedy sa signál pošle ďalej. To nám určuje hodnotu výstupu. Ak je suma vstupov váhovaných príslušnými váhami menšia ako prah excitácie na výstup sa nastaví 1. hodnota, ak je väčšia alebo rovná nastaví sa 2. hodnota. Druhým typom perceptrónu je spojitý perceptrón. Výstup môže naberať veľa hodnôt – je spojitý. Hodnota na výstupe je daná tzv. aktivačnou funkciou. Vstupom tejto funkcie je už spomínaná suma vstupov váhovaných príslušnými váhami. Aktivačná funkcia môže byť napr. sigmoida:

$$P(x) = \frac{1}{1 + e^{-x}} \quad (2.6)$$

Učenie neurónu prebieha pomocou aktualizovania váh tak, aby zo sady tréningových vstupov, bola na výstupe neurónu očakávaná hodnota, ktorá musí byť pri tréningových vstupoch dopredu určená. Jedná sa teda o učenie s učiteľom.

Umelý neurón dokáže klasifikovať objekty len do dvoch tried, pretože má len jeden výstup. Neurónové siete sa skladajú z viacerých vrstiev a každá vrstva môže mať niekoľko neurónov. Vďaka tomu je možné riešenie zložitejších problémov, v ktorých nestačí priestor rozdeliť na dva podpriestory. Medzi najpoužívanejšie metódy zapojenia neurónov v neurónovej sieti patrí tzv. feed-forward zapojenie. Neuróny na jednej vrstve sú prepojené so všetkými neurónmi na ďalšej vrstve (obr. 2.16). Prvá vrstva na obrázku je tzv. vstupná vrstva, jej úlohou je len preposielanie signálov na všetky neuróny v ďalšej vrstve. Neuróny v ostatných vrstvách pracujú rovnako ako vyššie spomenutý neurón. Každý neurón v sieti rieši iba časť daného problému. Výsledok je tvorený kompozíciou príspevkov od všetkých neurónov.



Obr. 2.16: Ukážka neurónovej siete s feed-forward zapojením.

## Kapitola 3

# Návrh aplikácie

### 3.1 Aspekty návrhu

Výsledný program by mal byť schopný rozpoznávať značky v reálnom čase z videa. Musíme sa teda snažiť o čo najväčšiu rýchlosť celého procesu detekcie a rozpoznávania. O to sme sa snažili použitím rýchlych metód, spomínaných v tejto kapitole. Museli sme si uvedomiť problémy, s ktorými sa môžeme v reálnom svete stretnúť, napr. defekty registračných značiek, rôzne uhly pohľadu a pod. Program by taktiež mal mať čo najmenšiu hodnotu tzv. false-alarmov, to znamená detekciu a následný pokus rozpoznania objektu, ktorý nie je značkou. Problém môžu spôsobovať objekty pripomínajúce značky – okná, reklamné nápisy, dlažobné kocky a pod.

Veľký vplyv na funkčnosť programu má aj kvalita vstupného obrazu. Pri kamere vo vozidle sa často môžeme stretnúť s rozmazanými značkami z dôvodu pomalého expozičného času. Čím krajší je expozičný čas, tým ostrejší je každý snímok videa. Problémom pri nízkom expozičnom čase však môže byť citlivosť na svetelné podmienky.

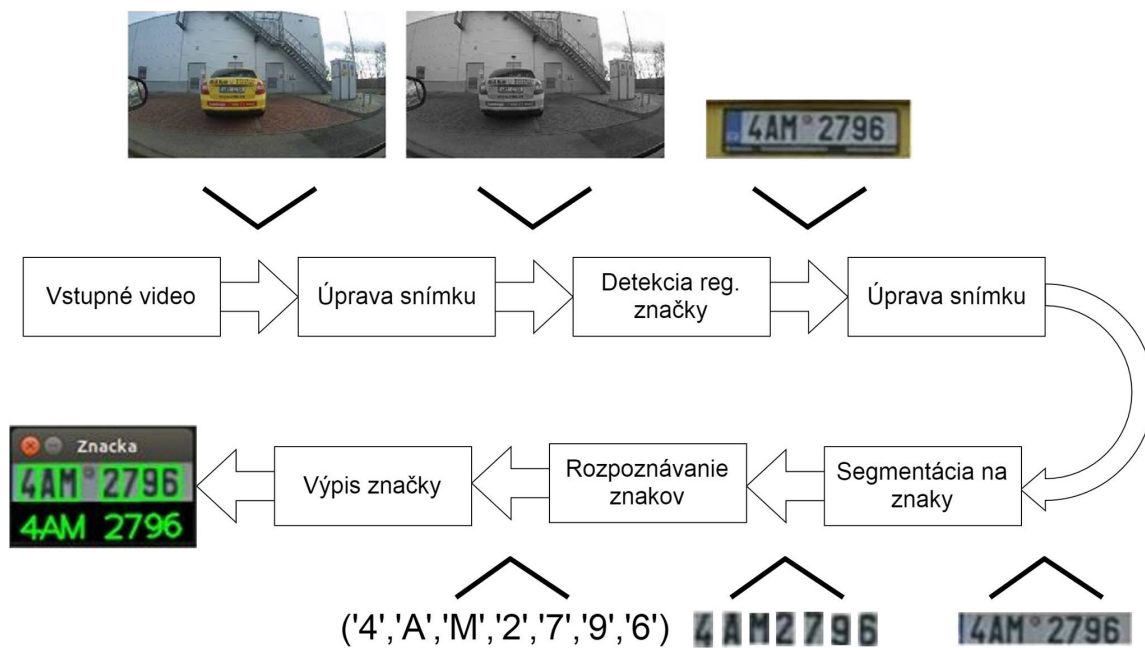
Náš algoritmus je stavaný na základnú veľkosť registračnej značky s jedným riadkom znakov. Nemal by mať problém so staršími značkami. Program by bolo možné rozšíriť aj na iné rozmery značiek, vyžadovalo by si to však mierne modifikácie a hlavne zaradiť zábery takýchto značiek do tréningovej sady.

S využitím poznatkov, spomínaných v teoretickej časti práce, sme vytvorili návrh systému zobrazený na obrázku 3.1. Skladá sa z troch základných častí – Detekcii registračnej značky na snímke z videa, segmentácia výrezu získaného detekciou a rozpoznávaním znakov. Tieto časti a nutné úpravy snímok medzi nimi sú rozpísané v tejto kapitole. Na obrázku si môžeme všimnúť príklady výstupov a vstupov medzi jednotlivými časťami.


### 3.2 Defekty registračných značiek a problémové prípady

Problémom pri detekcii a rozpoznávaní značiek by mohli byť registračné značky s nejakým poškodením. Bežne sa môžeme stretnúť so špinavými značkami. Mnohokrát je znečistenie také silné, že znemožňuje rozpoznanie značky voľným okom, nie to ešte rozpoznanie programom. Náš program by sa mal snažiť čo najlepšie abstrahovať postupy, ktoré robí podvedome aj človek pri rozpoznaní značky. Znečistenie môže byť spôsobené prachom, snehom, blatom a pod. Taktiež sa môžeme stretnúť s poohýbanými značkami a doškriabanými značkami. Tieto problémy sú zobrazené na obrázku 3.2.

Problémy nám môžu spôsobiť aj značky pripevnené pomocou skrutiek. Takýto spôsob



Obr. 3.1: Schéma navrhnutého systému.



Obr. 3.2: Problematické registračné značky.



Obr. 3.3: Ďalšie problémy, ktoré musíme brať do úvahy.

upevnenia môžeme pozorovať hlavne na značkách staršieho typu. Na upevnenie používajú občania aj plastové stahovacie pásiky. Ak je pásik umiestnený medzi znakmi, nemalo by to spôsobovať problémy. V praxi sa však stretávame aj s pásikmi prekrývajúcimi znaky značky, čo predstavuje problém najmä pri rozoznávaní jednotlivých znakov.

Ďalšie problémy môžu spôsobovať svetelné podmienky, v akých bolo vstupné video natáčané. Registračná značka môže byť veľmi presvetlená, čo môže spôsobiť splynutie znakov s pozadím. S týmto problémom sa môžeme stretnúť kvôli reflexným vlastnostiam značiek. Častejšie sa však môžeme stretnúť s malým osvetlením videa, ktoré v spojení s nízkym expozičným časom spôsobuje nečitateľnosť znakov na značke a často aj znemožnenie detekcie značky. Ďalej sa môžeme stretnúť s tieňmi vrhnutými okolitými objektami alebo rôznymi vyvýšeniami na aute. Pri vytváraní práce sme sa stretli aj s problémom, že registračnú značku zakrývalo ťažné zariadenie.

Na obrázku 3.3 sa nachádza natočená značka, s takýmito zábermi tiež musíme počítať. Ďalej sa tam nachádza značka, na ktorú bol vrhnutý tieň a značka, ktorá je mierne prekrytá ťažným zariadením.

### 3.3 Detekcia a lokalizácia registračnej značky

Detekciu a lokalizáciu značiek sme sa rozhodli realizovať pomocou kaskádového klasifikátora natrénovaného algoritmom Adaboost. Využili sme pri tom príznaky LBP z dôvodu ich rýchlosti. Experimentovali sme aj s Haarovými príznakmi, no vyskytli sa problémy s operačným systémom, keďže je tréning časovo náročnejší a vyžaduje množstvo pamäte. Uvedené metódy sú viac vysvetlené v sekcii 2.2. Snímku treba pred spracovaním upraviť na obrázok v odtieňoch šedej. Keďže detekcia musí byť rýchla, musíme sa zaoberať aj metódami na jej zrýchlenie.

Na začiatku musíme zvoliť minimálne rozmery výrezu značky tak, aby bolo možné značku aj rozpoznať. Zároveň nezatažujeme počítač prehľadávaním malých pod-okien v obraze. Keďže má program značku nie len detekovať, ale aj rozpoznať nemalo by zmysel detekovať malé značky, na ktorých nebude možné rozpoznať jednotlivé znaky. Taktiež je si treba dať pozor na otočené značky. Tento problém riešime tak, že otočené a skosené značky zaradíme do sady na tréningovanie klasifikátora pre detekciu. To znamená, že takéto značky detekujeme, no pri rozpoznaní si musíme obraz predspracovať. Aj pri takýchto značkách ale nezaraďujeme do tréningovej sady väčšie extrémy, pretože by vznikalo mnoho problémov v ďalšom spracovaní. Do sady pre registračné značky budú zaradené výrezy s menším okolím značky, čo ničomu neškodí, keďže značky budú ešte predspracované. Taktiež sa budú jednoduchšie vytvárať výrezy pre tréningovanie a detektor bude mať k dispozícii viac hrán, ktoré príznaky v detektore využívajú.

Pre potreby klasifikátora je nutné z farebného snímku vytvoriť obrázok v odtieňoch šedej. Farebný snímok môže využívať rôzne farebné modely. Najpoužívanejší model je model RGB. Každý pixel v obraze je daný 3 hodnotami. Tieto hodnoty určujú intenzitu jeho farebných zložiek. V modeli RGB sú to červená, zelená a modrá. Výsledná farba pixelu je vytvorená zmiešaním týchto zložiek. Ak majú všetky 3 zložky maximálnu intenzitu, pixel je biely, nulová intenzita všetkých farieb naopak vytvorí čierny pixel. Obrázok v odtieňoch šedej je tvorený pixelmi, ktoré reprezentuje len jedna hodnota a tou je intenzita pixelu. Tú môžeme vypočítať pomocou vzorca:

$$I = 0,299 * R + 0,587 * G + 0,114 * B \quad (3.1)$$




Kde  $I$  je výsledná intenzita bodu,  $R$  je hodnota červenej zložky,  $G$  zelenej a  $B$  modrej. Každá zložka je vynásobená iným koeficientom z dôvodu rozdielnej citlivosti ľudského oka na spomínané farebné zložky.

Výrez s registračnou značkou je na snímku z kamery detekovaný viackrát vždy s miernym posunutím alebo zmenšením pod-okna. Môžeme teda stanoviť tzv. minimálny počet susedov, t. j. koľko takýchto okien sa musí prekrývať, aby sme mohli určiť, že sa v kandidátnej oblasti nachádza hľadaný objekt. Správne zvolenie minimálneho počtu prekrývajúcich sa pod-okien nám pomôže zlepšiť kvalitu detekcie. Ak je toto číslo veľmi nadhodnotené nepodarí sa nám na snímkach detekovať nič. Pri nízkom počte budú značky detekované na jednej snímke viackrát alebo sa do ďalšej fázy dostanú aj výrezy, ktoré sú len false-alarmy – objekty, ktoré nie sú hľadaným objektom, no sú mu podobné.

### 3.4 Segmentácia a rozpoznávanie znakov

Výstupom z detekcie registračných značiek je výrez so značkou. Keďže obsahuje aj malé okolie značky, ktoré je v tejto fáze pre nás nezaujímavé, potrebujeme lokalizovať len presne výrez registračnej značky. Na to využijeme techniky segmentácie spomínané v sekcii 2.3. Pomocou prahovania alebo detekcie hrán a následného určenia hraníc objektov sa snažíme lokalizovať len pre nás zaujímavú časť. Môžeme vychádzať z toho, že oblasť, ktorá nás zaujíma je vždy najväčší súvislý objekt na výreze a má tvar štvoruholníka, ideálne obdĺžnika. Keď sa nám podarí objekt lokalizovať, musíme ho otočiť tak, aby boli znaky v jednom riadku. Najlepšie by bolo objekt transformovať tak, aby sme odstránili aj prípadné skosenie.



Obr. 3.4: Výrez s registračnou značkou a jeho časť, ktorá nás zaujíma.

Po tomto kroku nasleduje segmentácia jednotlivých znakov. K ich nájdeniu používame tiež techniky segmentácie spomínané v kapitole 2.3.

Pri použití prahovania môžu vplyvom šumu, zlého osvetlenia alebo defektov značky vzniknúť artefakty, ktoré sú nežiadúce. Tieto artefakty nám tiež môžu spôsobovať „zlievanie“ viacerých znakov do jedného objektu. Odstránenie artefaktov môžeme riešiť zlepšením spôsobu prahovania alebo morfológickými transformáciami.

Pri identifikácii objektov môžeme vychádzať z toho, že v danom výreze pre nás zaujímavej oblasti budú mať znaky vždy podobnú veľkosť. S vhodne nastavenými hodnotami rozmedzí výšky a šírky znakov, by sme mali dostávať len objekty znakov. Musíme si dať pozor, aby sa nám ako znaky nedetekovali nálepky o technickej kontrole. Znak pomlčky v starších značkách môžeme ignorovať, pretože nemá žiadny ďalší význam.

Lokalizovaním znakov získame výrezy so znakmi, ktoré je nutné ďalej rozpoznáť. Na ich rozpoznávanie využívame neurónovú sieť, ktorú je nutné natréňovať. Vstupom neurónovej siete bude sled intenzít bodov obrazu daného znaku. Obraz znaku teda musí byť v odtieňoch šedej. Neurónová sieť má presne určený počet vstupov a presne určený počet výstupov. Môžeme si všimnúť, že napríklad znaky I a M majú rozdielnu šírku. Obrazy znakov musíme

roztiahnuť tak, aby sme mali vždy rovnaký počet vstupov, a teda na rovnakú výšku a šírku. Výstupom siete je znak, ktorý je s najväčšou pravdepodobnosťou znak na vstupnom obraze.

Ďalej musíme rozpoznané znaky správne zoradiť, aby sa nestávalo, že rozpoznávanie siete funguje správne, no registračná značka sa nám po rýchlom porovnaní zdá zle rozpoznaná. K zostaveniu celého čísla môžeme využiť súradnice, ktoré sme získali pri segmentácii znakov predtým, ako sme z nich vytvorili výrez. Zoradenie znakov podľa horizontálnej súradnice nám teda zostaví znaky v značke do správneho poradia.

Inou možnosťou rozpoznávania môže byť použitie externých knižníc a nástrojov na optické rozpoznávanie znakov. Tie často umožňujú rozpoznanie textu z celého obrazu bez toho, aby sme museli znaky segmentovať. Segmentáciu znakov už totiž majú implementované. Vtedy stačí využiť externé riešenia už s obrazom, v ktorom sme odstránili zbytočný okraj. Niektoré externé nástroje umožňujú aj definovanie množiny znakov, ktoré sa na obraze môžu nachádzať. Toto je využiteľné aj pri registračných značkách, ktoré môžu obsahovať len určitú množinu znakov. Musíme však dávať pozor na už spomínané artefakty, ktoré sa musíme snažiť čo najviac eliminovať, aby ich nástroje nedetekovali ako znaky. To celý proces robí časovo náročnejším.

Niektorým externým nástrojom je možné odosielať na rozpoznanie iba výrezy znakov s tým, že majú detekovať len jeden znak. V tom prípade je postup podobný ako pri využití neurónovej siete na rozpoznanie výrezu.

## Kapitola 4

# Implementácia a vyhodnotenie navrhnutého systému

### 4.1 Použité nástroje

Na implementáciu bol použitý programovací jazyk Python 2.7. Funkcie počítačového videnia a spracovania obrazu zabezpečovala knižnica OpenCV 3, no použité boli len funkcie z verzie 2, ktoré obsahuje aj táto novšia verzia. Táto knižnica obsahuje aj funkcie a nástroje pre strojové učenie a klasifikáciu, ktoré sme využívali pri detekcii. Na klasifikáciu vo fáze rozpoznávania sme využívali knižnicu Scikit-learn, konkrétne jej zatiaľ neoficiálnu verziu, ktorá je ešte vo fáze vývoja s číslom verzie 0.18.dev0.

Knižnica OpenCV je robustná multiplatformová knižnica obsahujúca množstvo funkcií na spracovanie obrazu, obsahuje aj nástroje na strojové učenie a prácu so súbormi – videami a obrázkami v rôznych formátoch. Knižnica obsahuje už natrénové klasifikátory, napr. aj klasifikátor na detekciu ruských registračných značiek. Experimentovanie s týmto klasifikátorom tiež prispelo k pochopeniu problematiky, ešte predtým čo bol natrénovaný vlastný. Je písaná v jazyku C++, no obsahuje aj rozhranie pre iné jazyky napr. Python, Java a pod. Výhodou tejto knižnice je veľká komunita používateľov a množstvo publikácií. My sme čerpali hlavne z publikácie [3] a [9]. Knižnica je voľne šíriteľná pod licenciou BSD.

Scikit-learn je multiplatformová knižnica slúžiaca na počítačové učenie. Využíva matematické a vedecké knižnice pre Python s názvami NumPy a SciPy. Je písaná v jazyku Python, no pre zlepšenie výkonnosti sú niektoré časti písané v C++. Obsahuje tiež modul nazývaný Joblib, ktorý umožňuje ukladať natrénované klasifikátory, aby mohli byť neskôr znova použité, bez nutnosti tréovania.

Experimentovali sme aj s programom Tesseract OCR, ktorý slúži na optické rozpoznávanie znakov a knižnicou pre strojové učenie s názvom Caffe.

### 4.2 Dátová sada

Dátovú sadu, pomocou ktorej sme trénovali detektor značiek a neurónovú sieť, sme si sami vytvárali. Na zachytávanie videí, z ktorých bola neskôr vytváraná dátová sada boli použité 2 kamery. Najprv boli zábery natáčané vstavanou kamerou telefónu Google Nexus 4. Zábery boli natáčané pri pomalej chôdzi. Vzhľadom na nízku kvalitu a hlavne nízky počet snímkov za sekundu, a tým spojený dlhý expozičný čas, sme ďalšie videá natáčali pomocou kamery Xiaomi Yi Sports. Videá boli natáčané v rozlíšení 1280x720 so snímkovacou frekvenciou 120


snímok/s z idúceho vozidla, na väčších parkoviskách. Kamera bola umiestnená na bočnom okne vozidla. Videá boli prechádzané snímok po snímku a manuálne boli vytvárané výrezy s registračnou známkou na natrénovanie detektora. Bolo vytvorených 653 výrezov na pozitívnu detekciu a 544 snímok ktoré neobsahovali registračnú značku. Ukážka pozitívnych vzorkov je vľavo na obrázku 4.2, negatívnych vpravo.



Obr. 4.1: Ukážka pozitívnych a negatívnych vzorkov dátovej sady pre detekciu.

Sada na tréning detekcie bola rozšírená aj snímkami z externého zdroja. Bola použitá sada zo školského serveru Merlin vytváraná pre potreby grafického ústavu. Rozšírená sada obsahovala 1656 výrezov na pozitívnu detekciu a 1249 negatívnych obrázkov.

Sadu pre rozpoznávanie výrezov jednotlivých znakov sme tiež vytvorili vlastnú. Bolo zhotovených 6893 výrezov rovnakých veľkostí, ktoré boli roztriedené podľa toho, aký znak sa na nich nachádza. Pri nedostatočnom počte výrezov, pri niektorých znakoch, sme použili na tréningovanie neurónovej siete znaky zo sady grafického ústavu.



Obr. 4.2: Ukážka vzorkov dátovej sady pre rozpoznávanie znakov.

### 4.3 Výsledná aplikácia

Výsledná aplikácia implementuje systém navrhnutý v kapitole 3. Jej vstupom je video a počas svojho behu zobrazuje video používateľovi, na videu sú vyznačené oblasti s detekovanou registračnou značkou. Ak sa podarí značku rozpoznať, je zobrazený aj text značky. Ďalšie okno aplikácie zobrazuje poslednú detekovanú značku s vyznačenými znakmi, ktoré sa podarili lokalizovať pomocou segmentácie. Pod každým lokalizovaným znakom sa zobrazuje písmeno alebo číslo, ktoré bolo z výrezu znaku klasifikované. Toto okno slúži na kontrolu časti rozpoznávania.



Obr. 4.3: Ukážka výslednej aplikácie.

Aplikáciu je možné pozastaviť pomocou klávesy `space` a ukončiť pomocou klávesy `esc`.

#### 4.3.1 Detekcia registračnej značky

Kaskádový klasifikátor bol natrénovaný s pomocou nástroja `opencv_createsamples` a `opencv_traincascade` knižnice OpenCV. Bola použitá nami vytvorená dátová sada a sada od UPGM FIT VUT v Brne. Program má ako vstupný parameter cestu k videu, v ktorom treba detekovať a rozpoznať registračné značky. Toto video prechádza po snímkach, každá je prevedená do odtienov šedej a je vybraná oblasť ROI, v ktorej sa najčastejšie nachádzajú registračné značky z dôvodu zrýchlenia (obr. 4.4). Tento krok bol nutný, pretože pri veľkosti snímky trvala detekcia cca 400ms (jednojadrový procesor, 4GB RAM, integrovaná grafická karta). Určené ROI začína v 1/4 vertikálnej osi a končí v 3/4. Tým sme zmenšili prehľadávanú oblasť a program sa dvojnásobne zrýchlil. Pri inom type vstupných videí je možné, že bude treba ROI upraviť, poprípade pri dostatočnom výkone ani nepoužívať.

Takto predpripravená snímka je odoslaná funkcii implementujúcej kaskádový klasifikátor. Minimálna veľkosť registračnej značky je zvolená 75 x 26 pixelov a maximálna 375 x 125 pixelov. Táto funkcia z knižnice OpenCV nám vracia množinu pozícií a veľkostí všetkých nájdených výrezov, ktoré sú následne vyrezané zo vstupného obrazu a postupne odosielané na ďalšie spracovanie.

#### 4.3.2 Úprava výrezu pred segmentáciou znakov

Úlohou tejto fázy nášho riešenia je upraviť výrez získaný pri detekcii na formát, ktorý nám uľahčí ďalšie spracovanie. Musíme na ňom nájsť len oblasť so značkou obsahujúcu text značku a číslice. Výrez získaný pri detekcii je mierne rozmazaný, aby sa potlačil šum. Potom je pomocou Otsu prahovania vysvetleného v teoretickej časti prevedený do binárneho obrázku. Následne sú hľadané všetky hranice objektov – kontúry na tomto obrázku, tým nám vznikne množina objektov. Objekt, ktorý nás zaujíma by mal byť na výreze najväčším súvislým objektom. Hľadáme teda medzi objektami taký, ktorý obsahuje čo najviac pixelov. Všetky kontúry a kontúra najväčšieho objektu sú zobrazené na obrázku 4.5.



Obr. 4.4: Oblast záujmu - ROI na snímke z videa.



Obr. 4.5: Všetky kontúry vo výreze a kontúra najväčšieho objektu.

Následne je potrebné nájsť výrez otočiť tak, aby boli znaky na značke v jednej rovine. Z kontúry opisujúcej oblasť, ktorá nás zaujíma je vytvorený obdĺžnik, ktorý ju najlepšie opisuje (obr. 4.6). Experimentovali sme aj s aproximáciou kontúry objektu pomocou polygónu, ktorý by mal ideálne tvoriť štvoruholník, no stretli sme sa s problémom, že značku neopisovala súvislá kontúra, ale kontúra okolo objektu bola veľmi komplikovaná. Bolo to z dôvodu, že pri zhoršených podmienkach sa niektoré znaky alebo artefakty „zlievali“ s okrajom značky.



Obr. 4.6: Obdĺžnik okolo významnej oblasti a výrez so zarovnanými znakmi.

Pomocou súradníc rohov štvoruholníka, popisujúceho najväčšiu oblasť, výrez so značkou aj okolím natočíme a orežeme tak, ako je zobrazené na obrázku 4.6. Pre účely ďalšieho spracovania je výrez upravený tak, aby mal presne stanovené rozmery. Tie sme si určili na 150 x 33 pixelov. V ďalšom spracovaní je totiž vyžadované, aby znaky hľadané vo výreze mali určité rozpätie veľkostí.

### 4.3.3 Segmentácia znakov

Segmentácia znakov prebieha podobným spôsobom ako nájdenie výrezu značky na výstupe z detektora. Výrez značky je prahovaný pomocou metódy Otsu a následne sú nájdené

kontúry všetkých objektov. Pomocou výšky a šírky najmenších možných bounding boxov je určované, či je objekt znak alebo nie (obr. 4.7). Bounding box je najmenší obdĺžnik, ktorým sa dá objekt opísať a zároveň sú jeho strany rovnobežné s hranami výrezu. Výšku a šírku musíme kontrolovať z dôvodu možného výskytu artefaktov alebo nálepiek o technickej kontrole na značke.



Obr. 4.7: Kontúry znakov a obdĺžniky so znakmi.

#### 4.3.4 Rozpoznávanie znakov a výpis

Na klasifikáciu jednotlivých výrezov bola použitá perceprónová neurónová sieť, ktorú v knižnici Scikit-learn 0.18.dev0 implementuje trieda `MLPClassifier`. Pri trénovaní bola použitá väčšina defaultných nastavení tejto siete. Experimentovali sme s počtom iterácií na učenie, vďaka tomu sme dosiahli úspešnosť 98% pre výrezy, ktorých bola trébovaná. Táto úspešnosť bude pri rozpoznávaní nových výrezov pravdepodobne dosť nižšia, presnú hodnotu sme však nezistovali. Ako aktivačná funkcia neurónov bola použitá funkcia ReLU daná vzťahom:

$$P(x) = \max(0, x) \quad (4.1)$$

Tento objekt bol uložený, aby boli zachované natrébované váhy jednotlivých neurónov. Pri rozpoznávaní bol obnovený a použitý na predikciu znakov zo vstupných obrazov. Predikované znaky boli zoradené podľa horizontálnej súradnice. Následne sa v našej počítačovej aplikácii zobrazí okno, na ktorom je vidieť ako boli znaky segmentované a text registračnej značky. Vo videu sa zobrazí rámček okolo detekovaného výrezu registračnej značky. Nad rámčekom sa zobrazí text značky, ktorý je výsledkom nášho rozpoznávania.

### 4.4 Zhodnotenie úspešnosti

Pre potreby testovania aplikácie boli nakrútené 2 dlhšie videá. Jedno video bolo nakrútené na rovnakom parkovisku, ako video pre potreby trébovania, druhé na odlišnom parkovisku. Na rovnakom parkovisku bolo samozrejme nakrúcané až po nejakej dobe (zhruba 2 týždne), aby sa na parkovisku nenachádzali rovnaké vozidlá.

Pri testovaní sme zistili, že detektor má pomerne dobrú úspešnosť. Podarilo sa detekovať 94% značiek z testovanej vzorky. Pri počítaní tohto čísla sme uvažovali len normálne pozorovateľné registračné značky vozidiel, okolo ktorých sme vozidlom prechádzali. Malé značky v diaľke nám samozrejme detektor nedetekoval. Čo sa týka falošných detekcií, vyskytovali sa ojedinele. Úspešnosť mohlo znížiť aj použitie ROI, pretože sa v testovacej vzorke vyskytli aj vzorky, kde sa značka viditeľne nachádzala mimo ROI. To mohlo znížiť aj počet false-alarinov, keďže vďaka tejto metóde sa neposudzovala časť vozovky, na ktorej môžu byť zle detekované rôzne pätníky, dlažobné kocky alebo pozemné dopravné značenie. Problematické značky väčšinou mali niektorý z defektov spomínaných v sekcii 3.2.

Úspešnosť rozpoznávacej časti, do ktorej je zahrnutá aj segmentácia bola 57%. V 22% došlo k správnej detekcii len časti znakov. V mnohých prípadoch z úspešných rozpoznání však k správne rozpoznaniu značky došlo až keď nebola pod veľkým uhlom. Ostatné značky sa nepodarilo rozpoznáť alebo boli úplne zle rozpoznané. Pomocou analýzy a okna zobrazujúceho segmentáciu znakov, sme dospeli k záveru, že problematická je najmä časť segmentácie.

Aplikácia bola testovaná manuálne s použitím testovacieho videa. Mohlo sa stať, že značka nebola na niektorých snímkach videa úspešne detekovaná alebo rozpoznaná. Pri väčšej snímkovacej frekvencii nás však takéto prípady nezaujímali, ak vo väčšine ostatných snímkov problém s detekciou alebo rozpoznáním tejto konkrétnej značky nebol.



# Kapitola 5

## Záver

Pri tvorbe tejto práce boli naštudované metódy z oblasti počítačového videnia a strojového učenia, hlavne v súvislosti s témou práce. Ďalej bola implementovaná počítačová aplikácia slúžiaca na detekciu a rozpoznávanie registračných značiek z videa. Aplikácia využíva zaujímavé knižnice zo spomínaných oblastí.

Pri vytváraní aplikácie vznikla nová dátová sada na tréning kaskádového klasifikátora pre účely detekcie. Ďalej sme vytvorili dátovú sadu so znakmi zo značiek na tréning neurónovej siete pre účely rozpoznávania znakov. Implementovaná detekcia vykazovala úspešnosť 94% a správne rozpoznať celú registračnú značku sa podarilo s úspešnosťou 57%.

Do budúcnosti by sme chceli aplikáciu upraviť tak, aby sa zlepšila rýchlosť spracovania jednej snímky a aby sa zlepšila úspešnosť rozpoznávania. Určite by bolo prospešné vylepšiť metódy na segmentáciu znakov. Aplikáciu by bolo tiež vhodné upraviť, aby mal používateľ k dispozícii viac nastavení a možností.

# Literatúra

- [1] *Cleaner cars with the Global Fuel Economy Initiative* [online]. United Nations Environment Programme [cit. 2016-04-20]. Dostupné z: <<http://www.unep.org/climatechange/ClimateChangeConferences/COP18/Booklet/CLEANERCARSWITHTHEGLOBALFUELECONOMYINITIATI.aspx>>.
- [2] *Poznávací značky (SPZ) v letech 1960-2002* [online]. [cit. 2016-04-21]. Dostupné z: <<http://www.feudal.cz/spz/html/1960-2002.htm>>.
- [3] BRADSKI, G.; KAEHLER, A. *Learning OpenCV*. Sebastopol: O'Reilly, 2008. ISBN 978-0-596-51613-0.
- [4] CANNY, J. A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1986, s. 679–698. ISSN 0162-8828.
- [5] ČESKO. *Předpis č. 56/2001 Sb. : Zákon o podmínkách provozu vozidel na pozemních komunikacích a o změně zákona č. 168/1999 Sb., o pojištění odpovědnosti za škodu způsobenou provozem vozidla a o změně některých souvisejících zákonů (zákon o pojištění odpovědnosti z provozu vozidla), ve znění zákona č. 307/1999 Sb.* [online]. Zakonyprolidi.cz, c2001 [cit. 2016-04-27]. Dostupné z: <<http://www.zakonyprolidi.cz/cs/2001-56>>.
- [6] ČESKO. *Předpis č. 343/2014 Sb. : Vyhláška o registraci vozidel* [online]. Zakonyprolidi.cz, c2014 [cit. 2016-04-27]. Dostupné z: <<http://www.zakonyprolidi.cz/cs/2014-343>>.
- [7] FREUND, Y.; SCHAPIRE, R. E. A decision-theoretic generalization of on-line learning and an application to boosting. *Computational Learning Theory: Second European Conference, EuroCOLT '95*. 1995, s. 23–37. ISBN 978-3-540-59119-1.
- [8] JURÁNEK, R. *Rozpoznávání v obraze : AdaBoost a detekce objektů* [online]. FIT VUT v Brně, 2013 [cit. 2016-04-27]. Dostupné z: <[http://www.fit.vutbr.cz/study/courses/IKR/public/prednasky/06\\_rozpoznavani\\_v\\_obraze/2013-IKR-Rozpoznavani%20v%20obraze%20-%20detection.pdf](http://www.fit.vutbr.cz/study/courses/IKR/public/prednasky/06_rozpoznavani_v_obraze/2013-IKR-Rozpoznavani%20v%20obraze%20-%20detection.pdf)>.
- [9] LAGANIERE, R. *OpenCV 2 computer vision application programming cookbook: over 50 recipes to master this library of programming functions for real-time computer vision*. Birmingham: Packt Publishing, 2011. ISBN 978-1-849513-24-1.
- [10] LIAO, S.; ZHU, X.; LEI, Z.; aj. Learning Multi-scale Block Local Binary Patterns for Face Recognition. *Advances in Biometrics*. 2007, s. 828–837. ISBN 978-3-540-74548-8.

- [11] LÁNIK, A.; ZUZAŇÁK, J. *Extrakce obrazových příznaků* [online]. FIT VUT v Brně [cit. 2016-05-13]. Dostupné z: <<http://www.fit.vutbr.cz/~ilanik/POV/pov.pdf>>.
- [12] OTSU, N. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*. 1979, vol. 9, no. 1, s. 62–66. ISSN 2168-2216.
- [13] PŘINOSIL, J.; KROLIKOWSKI, M. Využití detektoru Viola-Jones pro lokalizaci obličeje a očí v barevných obrazech. *Elektrorevue - Internetový časopis*. 2008, č. 31, s. 1–16. ISSN 1213-1539.
- [14] RAHMAN, C. A.; BADAWY, W.; RADMANESH, A. A Real Time Vehicle's License Plate Recognition System. *Advanced Video and Signal Based Surveillance, 2003. Proceedings. IEEE Conference on*. 2003, s. 163–166. ISBN 0-7695-1971-7.
- [15] VIOLA, P.; JONES, M. Rapid object detection using a boosted cascade of simple features. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2001, vol. 1, s. I-511–I-518. ISSN 1063-6919.