



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 FOTOGRAFIE

LICENSE PLATE DETECTION AND RECOGNITION FROM STILL IMAGE

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

KRYŠTOF JANÍČEK

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. JAKUB ŠPAŇHEL

BRNO 2016

Vysoké učení technické v Brně - Fakulta informačních technologií

Ústav počítačové grafiky a multimédií

Akademický rok 2015/2016

Zadání bakalářské práce

Řešitel: **Janíček Kryštof**

Obor: Informační technologie

Téma: **Detekce a rozpoznání registrační značky z fotografie
License Plate Detection and Recognition from Still Image**

Kategorie: Zpracování obrazu

Pokyny:

1. Prostudujte základy zpracování obrazu. Zaměřte se zejména na problematiku detekce více registračních značek vozidel v obraze a jejich rozpoznání.
2. Vyberte vhodnou metodu a navrhnete postup řešení daného problému.
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

Tato práce se zabývá návrhem a vývojem systému pro detekci a rozpoznání registrační značky vozidla. Tento systém je rozdělen na tři části, kterými jsou detekce registrační značky, segmentace znaků a rozpoznání znaků. Pro detekci registrační značky je použita kaskáda klasifikátorů, která dosahuje úspěšnosti až 95,5% a přesnosti 95,9%. Segmentace znaků je provedena pomocí vyhledávání kontur s úspěšností 93,3% a přesností 96,5%. Pro rozpoznání znaků je využita neuronová síť, která dosahuje úspěšnosti 98,4% pro jednotlivé znaky. Celý systém je schopen detekovat a rozpoznat 81,5% registračních značek v pořízené testovací datové sadě.

Abstract

This thesis describes the design and implementation of system for detection and recognition of license plate. This system is divided into three parts which are license plate detection, character segmentation and optical character recognition. License plate detection is done by cascade classifier that achieves hit rate of 95.5% and precision rate of 95.9%. Character segmentation is based on contour finding that achieves hit rate of 93.3% and precision rate of 96.5%. Optical character recognition is done by neural network and achieves hit rate of 98.4% for individual characters. The whole system is able to detect and recognize up to 81.5% of license plates from the test data set.

Klíčová slova

registrační značka, detekce registrační značky, kaskáda klasifikátorů, AdaBoost, optické rozpoznání znaků, neuronová síť, segmentace

Keywords

license plate, license plate detection, cascade classifier, AdaBoost, optical character recognition, neural network, segmentation

Citace

JANÍČEK, Kryštof. *Detekce a rozpoznání registrační značky z fotografie*. Brno, 2016. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Špaňhel Jakub.

Detekce a rozpoznání registrační značky z fotografie

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením pana Ing. Jakuba Špaňhela. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....
Kryštof Janíček
12. května 2016

Poděkování

Chtěl bych poděkovat panu Ing. Jakubovi Špaňhelovi za odborné vedení práce, cenné rady, rozšíření datové sady a vstřícnost při konzultacích. Dále bych chtěl poděkovat své rodině za podporu po dobu studia.

© Kryštof Janíček, 2016.

Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.

Obsah

1 Úvod	2
2 Detekce a rozpoznání registrační značky	3
2.1 Specifikace registrační značky	3
2.2 Využití a metody detekce a rozpoznání registračních značek	7
3 Návrh systému detekce a rozpoznání registrační značky	10
3.1 Detekce registrační značky	10
3.2 Segmentace znaků	14
3.3 Rozpoznání znaků	16
3.4 Omezení systému	19
4 Implementace a vyhodnocení systému	20
4.1 Použité technologie	20
4.2 Vytvořené datové sady	20
4.3 Detekce registrační značky	23
4.4 Segmentace znaků	25
4.5 Rozpoznání znaků	28
4.6 Vyhodnocení celého systému	29
5 Závěr	31
Literatura	32

Kapitola 1

Úvod

V dnešní době masivního rozmachu informačních technologií se stávají nejrůznější automatické a poloautomatické systémy součástí života každého člověka. Kamerové systémy zachycující dopravní situaci lze najít na každém rušnějším silničním uzlu. Tyto systémy slouží k zefektivnění, kontrole či analýze silniční dopravy. Jedním z těchto systémů je i detekce a rozpoznání registrační značky.

Cílem této práce bylo prostudovat možnosti detekce více registračních značek vozidel v obraze a jejich následné rozpoznání, návrh řešení tohoto problému a implementace takového systému. V závěru práce je navržený systém vyhodnocen a nastíněno další možné pokračování.

Struktura práce je následovná. Po úvodu následuje kapitola 2, v které jsou rozebrány technické parametry a vlastnosti registračních značek aktuálně používaných na území České republiky a srovnání s okolními státy. Dále jsou zde stručně rozebrány existující metody řešící detekci a rozpoznání registračních značek a uvedeno využití tohoto systému.

Kapitola 3 se zabývá návrhem systému detekce a rozpoznání registrační značky. Jsou zde také detailně rozepsány použité metody a omezení z nich vyplývající.

V 4. kapitole jsou popsány knihovny, které byly při implementaci systému použity. Poté je zde popsána vytvořená datová sada a její zpracování. Další části této kapitoly se věnují samotné implementaci jednotlivých modulů systému, experimentování s nimi a také jejich vyhodnocení.

Závěrem práce je kapitola 5, kde jsou shrnuty výsledky této práce a uvedeny možnosti dalšího vývoje.

Kapitola 2

Detekce a rozpoznání registrační značky

První část této kapitoly se věnuje detailnímu popisu registračních značek, které jsou v současnosti používané na území České republiky. Dále pak stručnému srovnání s registračními značkami používanými v okolních státech.

V druhé části je uveden stručný přehled přístupů k detekci a rozpoznání registračních značek a také možnosti využití takového systému.

2.1 Specifikace registrační značky

Tato část se věnuje popisu vlastností tabulek registračních značek vozidel. Specifikace registračních značek vozidel jsou dány platnou legislativou daného státu a jsou závazné pro všechny tabulky registračních značek. Tabulka registrační značky musí být vždy umístěna v přední a zadní části vozidla na viditelném místě. Jedinou výjimkou jsou jednostopá vozidla, kde je značka umístěna pouze v zadní části vozidla.

2.1.1 Registrační značky používané v České republice

Současné provedení registračních značek v České republice upravuje zákon č. 56/2001 a vyhláška č. 343/2014 [19]. Registrační značka je složena z pěti až sedmi znaků, které jsou tvořeny kombinací arabských číslic a velkých písmen latinské abecedy vyjma G, O, Q, W, které by se mohly zaměňovat s podobnými znaky. Značka musí obsahovat alespoň jedno písmeno a jednu číslici. Na druhé pozici značky musí být vždy písmeno, které určuje kód kraje (viz. tabulka 2.1), v kterém byla daná značka zaregistrována a vystavena. Toto pravidlo neplatí pro registrační značky na přání, které jsou rozebrány v části 2.1.1.

Tabulka registrační značky je obdélník se zaoblenými rohy s poloměrem zaoblení 10 mm, vyrobený ze slitin lehkých kovů a podklad je proveden reflexivně. Po obvodu tabulky je vylisován okraj o síle 4 mm, jehož barva je shodná s barvou znaků. Text registrační značky je do tabulky vylisován a dále je vylisován kruhový prostor pro nálepku o provedené pravidelné technické kontrole vozidla. Dále se specifikace tabulek pro registrační značky liší v návaznosti na druhu vozidla případně jeho užití.

Kraj	Kód
Hlavní město Praha	A
Jihomoravský kraj	B
Jihočeský kraj	C
Pardubický kraj	E
Královéhradecký kraj	H
Kraj Vysočina	J
Karlovarský kraj	K
Liberecký kraj	L
Olomoucký kraj	M
Plzeňský kraj	P
Středočeský kraj	S
Moravskoslezský kraj	T
Ústecký kraj	U
Zlínský kraj	Z

Tabulka 2.1: Kódy jednotlivých krajů

Rozdělení dle typu vozidla

Nejběžnějším typem tabulky pro registrační značku je tabulka určená pro osobní a nákladní automobil a autobus. Velikost této tabulky je 520×110 mm (obr. 2.1), má bílý podklad a černý text. Na levé straně se nachází modrý pruh s vyznačením znaku Evropské unie a rozlišovací značka České republiky.



Obrázek 2.1: Nejběžněji používaná registrační značka v České republice o rozměru 520×110 mm [18]


Pro osobní vozidla dále existuje několik alternativ tabulek registračních značek (obr. 2.2) a jejich kombinací. Tyto se používají pro vozidla dovezená ze zahraničí (např. USA) nebo sportovní automobily. Znaky jsou rozděleny do dvou řádků, kde v prvním jsou tři a v druhém čtyři znaky. Velikost tabulky je 280×200 mm a 320×160 mm. Modrý pruh s vyznačením znaku Evropské unie a rozlišovací značka České republiky se nachází v levém horním rohu.



Obrázek 2.2: Registrační značky alternativních rozměrů [18]

Nákladní vozidla a autobusy mají alternativní zadní tabulky registrační značky (obr. 2.3), které se také používají na přípojném vozidle. Znaký jsou opět rozděleny na dva řádky v poměru tři ku čtyřem. Velikost tabulky je 340×200 mm a modrý pruh je umístěn v levém horním rohu.

Poslední typ tabulky registrační značky je určen pro motocykly (obr. 2.3). Na motocyklech se používá pouze jedné tabulky a to v zadní části vozidla. Počet znaků registrační značky je sedm a je rozdělen do dvou řádků, kdy na prvním jsou dva znaky a na druhém čtyři znaky. Modrý pruh se nachází v levém horním rohu. Velikost této tabulky je 200×160 mm.



Obrázek 2.3: Alternativní registrační značka pro nákladní vozidla a autobusy [18] a registrační značka pro motocykl [18]

Rozdělení dle užívání

Tabulky registračních značek jsou rozděleny dle užívání vozidla různou barevností či menšími změnami obsahu tabulky. Většina typů těchto tabulek se rozměrově shoduje s druhy uvedenými výše. Základní tabulka registrační značky je popsána v podkapitole 2.1.1.

Tabulka registrační značky pro traktor a jeho přípojně vozidlo nebo samojízdný pracovní stroj má žlutý podklad a černé znaky. Na této tabulce není modrý pruh s vyznačením znaku Evropské unie a rozlišovací značka České republiky.

Vozidla určená k vývozu do zahraničí užívají tabulku registrační značky s bílým podkladem a černými znaky. Modrý pruh s vyznačením znaku Evropské unie a rozlišovací značka České republiky se na této značce nevyskytuje. Na tabulce je natištěn červený pruh s vyznačením měsíců, kde se vyznačuje platnost této registrační značky. U tabulky o rozměru 520×110 mm je tento pruh na pravé straně, u ostatních v levém horním rohu.

Diplomatická registrační značka je na bílém podkladu a znaky jsou modré. Zajímavostí je předdefinovaná kombinace znaků na čtvrté a páté pozici. Tyto kombinace určují diplomatické postavení vlastníka vozidla (viz tabulka 2.2).


Znaky	Vlastník vozidla
CD	osoba požívající diplomatických nebo konzulárních výsad a imunit
XX	administrativně-technický pracovník diplomatické nebo konzulární mise a požívající omezené diplomatické nebo konzulární výsady a imunity
XS	služební personál diplomatické nebo konzulární mise nebo člen mezinárodní organizace
HC	osoba vykonávající funkci honorárního konzula

Tabulka 2.2: Význam kombinací znaků diplomatických registračních značek

Vozidla, kterým byl vystaven průkaz historického nebo sportovně historického vozidla, smí užívat registrační značku pro historická vozidla. Její tabulka má bílé pozadí a zelený text.

Pro nově zakoupená vozidla se vydává speciální papírová registrační značka se zeleným podkladem a černým textem. Mimo textu registrační značky se zde nachází kolonka pro vyplnění data přidělení a podpisu a místa pro udělení razítka. Tato registrační značka má omezenou dobu platnosti, která je zde natištěna.

Příklady výše zmíněných tabulek registračních značek jsou uvedeny na obrázku 2.4.




Obrázek 2.4: Rozdělení registračních značek dle užívání [18]

Registrační značky na přání

Od 1. ledna 2016 nabývá účinnosti vyhláška [20] umožňující žádat o registrační značky s volitelným textem. Volitelná značka pro osobní automobil se skládá z osmi znaků, pro motocykl ze sedmi znaků a alespoň jeden z nich musí být číslice. Zvolený text nemůže obsahovat názvy úřadů, vulgární nebo hanlivé výrazy a písmena uvedená výše.

Starý typ registrační značky

Registrační značky vydávané do roku 2001 stále zůstávají platné. Tabulka registrační značky má bílý podklad a černý text (obr. 2.5). Text registrační značky je tvořen třemi písmeny a dvěma dvojčísly mezi kterými je pomlčka. Písmena vychází z bývalých názvů krajů. Pro tuto registrační značku také existuje několik obdobných typů jako u stávající verze registrační značky.



Obrázek 2.5: Starý typ registrační značky

2.1.2 Registrační značky používané v okolních státech

V České republice je nejběžněji možné se setkat s registračními značkami okolních států, především Slovenska. Oficiální název registračních značek na Slovensku je evidenční číslo vozidla (dále bude používáno označení registrační značka). Tabulka registrační značky je rozměrově stejná jako v České republice, tedy 520×110 mm. Tabulka má bílé pozadí s černými znaky. Na její levé straně je modrý pruh s vyznačením znaku Evropské unie a rozlišovací značka Slovenské republiky (obr. 2.6). Hlavním rozdílem oproti české registrační značce je text. Text je složen ze sedmi znaků, kde první dva značí kód okresu, kde je vozidlo registrované. Následují tři číslice a dvě písmena, která značí sérii registrační značky. Mezi druhým a třetím znakem se nachází státní znak Slovenské republiky. Použitý font se výrazně liší od fontu použitého u českých registračních značek.



Obrázek 2.6: Registrační značka Slovenské republiky [8]

Registrační značky v rámci Evropské unie se podobají v rozměrech tabulky. Největší rozdíl je v počtu znaků, použitém fontu, případně v použití grafických prvků jako je státní znak.



Obrázek 2.7: Příklady registračních značek států Evropské unie [23, 1, 21, 24]

2.2 Využití a metody detekce a rozpoznání registračních značek

V dnešní době masivního rozmachu informačních technologií se stávají nejrůznější automatické a poloautomatické systémy součástí života každého člověka. Kamerové systémy zachycující dopravní situaci lze najít na každém rušnějším silničním uzlu. Tyto systémy plní několik různých funkcí. Jedná se především o zefektivnění, prevenci a v neposlední řadě kontrolu silniční dopravy.

2.2.1 Současné využití systému pro detekci a rozpoznání registračních značek

Detekce a rozpoznání registrační značky se dnes využívá především při kontrole silniční dopravy Policií České republiky, případně dalších státních útvarů. Ze záznamu pořízeného

kamerovým systémem pak lze automaticky dohledat vlastníka vozidla, které spáchalo přeštupek, například překročení maximální povolené rychlosti nebo nerespektování dopravního značení.

Další možností využití v oblasti státní sféry je kontrola placení dálničního mýta či jiných poplatků souvisejících s využíváním silniční dopravy. Takový systém pak v centrální evidenci dohledá, zda má vlastník dané registrační značky tyto poplatky zaplacený.

V poslední době se detekce a rozpoznání registračních značek začíná využívat i ve sféře soukromé. Příkladem tohoto využití může být automatický přístup na soukromé parkoviště či do soukromého areálu.

2.2.2 Existující metody řešící detekci registračních značek

V současnosti existuje mnoho přístupů pro detekci registrační značky v obraze. Tyto přístupy jsou založené na různých principech a využívají rozdílné vlastnosti obrazu. Několik z nich bylo vybráno a stručně popsáno. Patří mezi ně Houghova transformace, Gaborova transformace, metoda založená na morfologii a algoritmus AdaBoost.

Houghova transformace

Tento algoritmus je jeden z nejefektivnějších pro detekci linií v binárním obraze. Vyhledává oblasti, které obsahují dvě paralelní linie a ty jsou považovány za kandidátní oblasti. Jeho nevýhodou je vysoký výpočetní čas při použití algoritmu na binární snímek ve velkém rozlišení. Pro redukci výpočetního času je možné jej kombinovat s algoritmem pro analýzu kontur. Na snímek se použije algoritmus pro detekci hran. Pomocí algoritmu pro analýzu kontur se vyhledají uzavřené oblasti, na které je poté aplikována Houghova transformace. Tímto postupem se zmenší prohledávaná oblast a tím se zredukuje výpočetní čas bez změny úspěšnosti. Tento algoritmus však může detekovat světla vozidla či další části karosérie a je potřeba takovéto oblasti při dalším zpracování eliminovat. Více informací lze najít v těchto článcích [6, 3].

Gaborova transformace

Gaborova transformace pro detekci registrační značky je představena v článku [5]. Gaborova transformace je systém počítačového vidění, který detekuje registrační značku a provádí segmentaci na jednotlivé znaky. Gaborův filtr je nástroj pro analýzu textur. Textura celé registrační značky včetně znaků a dalších komponent je použita pro detekci kandidátní oblasti. Výhodou tohoto postupu je nezávislost na velikosti a úhlu natočení registrační značky. Pro získání oblastí jednotlivých znaků je potřeba nejprve aplikovat prahování, což vede k získání binárního snímku. Poté morfologickou operaci dilatace, která spojí sousední oblasti. Nakonec se oblasti vyříznou.

Metoda založená na morfologii

Metoda založená na morfologii je použita v článcích [10, 7]. Morfologie zpracovává obraz na základě tvarů. Každý takový tvar má strukturovaný element a morfologické operátory analyzují snímek na jeho základě. Registrační značka má tvar obdélníku a je tedy možné ji pomocí morfologie detekovat. Detekováno bývá mnoho kandidátních oblastí a proto je potřeba vybrat jen takové, které vyhovují definovaným kritériím, jako je poměr stran. Při použití této metody se vstupní snímek nejprve převede do odstínů šedi, poté je aplikován

Sobelův operátor pro detekci hran. Dále se použije morfologická operace dilatace a poté uzavření. Nakonec se z výsledného snímku odstraní šum.

Algoritmus AdaBoost

Detekce registrační značky pomocí algoritmu AdaBoost je představena v článku [2]. Algoritmus AdaBoost vybere několik klasifikátorů z velké množiny slabých klasifikátorů a poté z nich vytvoří silné klasifikátory. Tato množina je také nazývána jako kaskáda klasifikátorů. Algoritmus je založen na strojovém učení a potřebuje tedy velkou sadu vstupních dat. Hlavní nevýhoda tohoto přístupu je citlivost na změnu počasí, světelných podmínek či natočení registrační značky. Tyto problémy lze částečně eliminovat použitím různorodé datové sady.

2.2.3 Existující metody řešící rozpoznání registračních značek

V dnešní době je pro rozpoznání znaků používáno velké množství různých metod. Bylo vybráno několik metod, které jsou vhodné pro použití v této práci a jsou dále stručně popsány. V této sekci jsou popsány metody pro rozpoznání znaků, které využívají shodu se šablonou, SVM klasifikátor nebo neuronovou síť.

SVM klasifikátor

V článku [17] je představen algoritmus strojového učení Support Vector Machine, který je použit pro klasifikaci znaků registrační značky. Tento algoritmus vytvoří na základě trénovacích dat rozdělených do dvou kategorií model, který určí zda nový vzorek patří do jedné či druhé kategorie. V tomto modelu jsou jednotlivé vzorky reprezentovány body v prostoru. Skupiny bodů rozdílných kategorií jsou pak odděleny co nejširší mezerou. Nové vzorky jsou umístěny do tohoto prostoru a na základě jejich umístění vůči mezeře je rozhodnuto, do které kategorie náleží. Pro rozpoznání znaků registrační značky je vytvořen takovýto model pro každý znak. Z výstupů jednotlivých modelů je pak vybrán ten s nejvyšším ohodnocením.

Neuronová síť

Neuronová síť pro rozpoznání znaků registrační značky je použita v článku [16]. Neuronovou síť je potřeba nejprve natrénovat. Pro trénování jsou zde použity snímky znaků převedené do binárního formátu. Trénování sítě upravuje hodnoty parametrů, které se označují váhy. Tyto parametry popisují model, který mapuje sadu příznaků vstupního snímku na odpovídající výstup. Proces ladění parametrů probíhá nad testovací sadou znaků, u které je určeno propojení vstupu a výstupu. Natrénovaná neuronová síť pak klasifikuje znaky do tříd dle pravděpodobnosti.


Rozpoznání pomocí shody se šablonou

Rozpoznání znaků pomocí shody se šablonou použili autoři článku [4]. Tato metoda porovnává části snímku s částmi ve vzorovém snímku. Proces porovnání posunuje snímek šablony do všech možných pozicí rozpoznávaného snímku a získává numerickou hodnotu, která udává míru shodnosti obou snímků v dané oblasti. Předpokladem použití tohoto přístupu je nevelká odlišnost vzorových snímků a rozpoznávaných snímků.

Kapitola 3

Návrh systému detekce a rozpoznání registrační značky

Systém pro detekci a rozpoznání registrační značky se zpravidla skládá ze tří základních modulů. První fází je detekce oblasti registrační značky. Vstupem tohoto modulu je zdrojový snímek, který se upraví pro následnou detekci. Výstupem je výřez zdrojového snímku, kde byla detekována registrační značka. Dalším modulem je segmentace znaků. Ve výřezu snímku detekovaného modulem detekce jsou lokalizovány jednotlivé znaky, které jsou vyříznuty a dále poskytnuty poslednímu modulu. Posledním modulem je rozpoznání znaků. Segmentované znaky jsou předzpracovány a rozděleny do tříd reprezentujících jednotlivé znaky. Po úspěšném rozpoznání je z jednotlivých znaků složen text registrační značky.



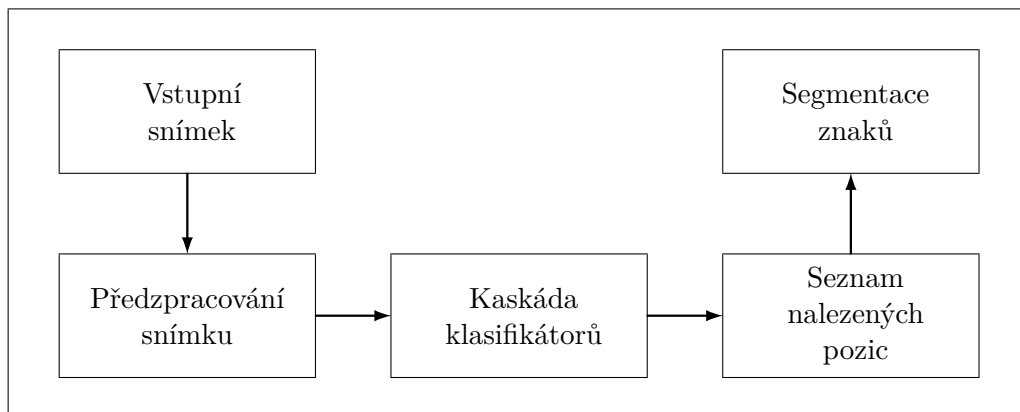
Obrázek 3.1: Schéma systému

3.1 Detekce registrační značky

Pro detekci registrační značky byla zvolena kaskáda klasifikátorů. Pro trénování kaskády klasifikátorů je použita pozitivní datová sada popsaná v sekci 4.2.1 a algoritmus Gentle AdaBoost s příznaky LBP, které jsou popsány v části 3.1.1.

Vstupem tohoto modulu je snímek, v kterém má být nalezena registrační značka. Tento snímek je potřeba před samotnou detekcí zpracovat. Prvně je na vstupní snímek aplikováno

Gaussovské rozostření a poté je snímek převeden do odstínů šedi. Nyní je snímek připraven pro detekci registračních značek pomocí kaskády klasifikátorů. Mezi oblastmi detekovanými kaskádou klasifikátorů, jako registrační značka, jsou i oblasti, kde se registrační značka nenachází. Tyto oblasti je nutné při dalším zpracování vyloučit.



Obrázek 3.2: Schéma modulu detekce registrační značky

Tolerance kaskády klasifikátorů vůči světelným podmínkám, velikosti registrační značky, úhlu pohledu a dalším, je určena snímky použitými při trénování. Z toho vyplývá, že čím různorodější je datová sada, tím lepší je výsledek detekce registrační značky.



Obrázek 3.3: Oblasti detekované kaskádou klasifikátorů

3.1.1 Kaskáda klasifikátorů

Tento přístup k detekci objektů v obraze přinesli Viola a Jones [22]. Práci prezentují na detekci obličejů v obraze, ale tento přístup lze využít i pro další objekty. Jejich práce je založena na třech hlavních myšlenkách.

Prvním přínosem je zavedení nového formátu reprezentace obrazu, který se nazývá integrální obraz. Ten umožňuje detektoru velmi rychlé zpracování příznaků. Systém detekce nepracuje přímo s intenzitou pixelů v obraze, ale využívá sadu příznaků, které jsou podobné Haarovým příznakům. Integrální obraz je spočítán z originálního obrazu jen za pomoci několika operací nad každým pixelem.


Druhým přínosem je algoritmus strojového učení založený na algoritmu AdaBoost. Algoritmus vybere z velké sady příznaků jen několik nejdůležitějších a vytvoří z nich velice

efektivní klasifikátory. V každém podokně obrazu je větší množství Haarových příznaků než samotných pixelů a proto učící proces musí většinu příznaků vyřadit. Výběr příznaků je dosažen jednoduchou modifikací algoritmu AdaBoost: každý vrácený slabý klasifikátor závisí pouze na jednom příznaku. Každý stupeň posilování klasifikátoru, který vybírá nový slabý klasifikátor, tedy může být vnímán jako proces vybírající příznak. AdaBoost poskytuje efektivní učící algoritmus a dobrý výkon.

Třetím přínosem je metoda, která úspěšně kombinuje složitější klasifikátory do kaskádové struktury. Ta výrazně zrychluje detekci zaměřením pozornosti jen na slibné oblasti v obraze. Pojem zaměření pozornosti znamená, že lze často rychle určit, kde se objekt v obraze nachází. Další zpracování pak probíhá jen nad těmito oblastmi. Klíčovou mírou takového přístupu je počet nedetekovaných hledaných objektů (false negatives).

Příznaky

Tento postup detekce objektů klasifikuje obrazy na základě hodnot jednoduchých příznaků. Existuje mnoho důvodů k použití příznaků místo jednotlivých pixelů. Nejčastějším důvodem je, že příznaky mohou zakódovat doménu znalostí, kterou je obtížné naučit pomocí konečné množiny trénovacích dat. Dalším důvodem je vyšší rychlost systému založeném na příznacích oproti systému založeném na práci s jednotlivými pixely. Jednoduché příznaky použité v práci jsou podobné Haarovým příznakům. Hodnota dvou obdélníkových příznaků je rozdílem pixelů na jejich ploše. Obdélníky mají stejný tvar i velikost a sousedí spolu (obr. 3.4). Hodnota příznaku tří obdélníků je součet vnějších obdélníků odečtený od prostředního obdélníku. Hodnota příznaku čtyř obdélníků je vypočtena rozdílem mezi páry diagonálních obdélníků.



Obrázek 3.4: Příklad Haarových příznaků [22]

Příznaky Local Binary Pattern (lokální binární vzor, dále jen LBP) byly poprvé představeny v článku [11] a slouží k popisu vlastností obrazu. Tyto příznaky jsou reprezentovány histogramem. Tato verze LBP pracuje s hodnotami osmi sousedních pixelů centrálního pixelu, jehož hodnota je použita jako práh. Pro výpočet hodnot sousedních pixelů je použita tato funkce:

$$s(x) = \begin{cases} 1 & \text{když } N(x) > C \\ 0 & \text{jinak} \end{cases} \quad (3.1)$$

kde C je hodnota centrálního pixelu a $N(x)$ je hodnota sousedního pixelu.

Hodnoty sousedních pixelů po prahování jsou pak vynásobeny váhou určenou odpovídajícím pixelům. Nakonec jsou sečteny výsledné hodnoty sousedních pixelů a tím je stanovena hodnota centrálního pixelu. Princip tohoto výpočtu je znázorněn na obrázku 3.5.

6	5	2
7	6	1
9	3	7


1	0	0
1		0
1	0	1

1	2	4
8		16
32	64	128

1	0	0
8	169	0
32	0	128

Obrázek 3.5: Princip výpočtu LBP příznaku [11]

Po výpočtu hodnoty všech pixelů vznikají lokální primitivní textury (obr. 3.6), které odpovídají sousedním hodnotám v originálním obraze. Tato primitiva představují body, roviny, hrany, rohy a další.



Obrázek 3.6: Příklad příznaků LBP [14]

Integrální obraz

Obdélníkové příznaky lze vypočítat velmi rychle pomocí pokročilé reprezentace obrazu nazvané integrální obraz. Integrální obraz v pozici x, y obsahuje součet pixelů vlevo a nad touto pozicí:

$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (3.2)$$

kde $ii(x, y)$ je integrální obraz a $i(x, y)$ je originální obraz. Použitím páru následujících rovnic:

$$s(x, y) = s(x, y - 1) + i(x, y) \quad (3.3)$$

$$ii(x, y) = ii(x - 1, y) + s(x, y) \quad (3.4)$$

(kde $s(x, y)$ je kumulativní součet řádku, $s(x, -1) = 0$ a $ii(-1, y) = 0$) může být integrální obraz vypočítán při jednom průchodu originálním obrazem.

Učení klasifikátoru

Pro danou sadu příznaků a trénovací sadu může být pro učení klasifikátoru použit jakýkoliv přístup strojového učení. V tomto systému je použita varianta algoritmu AdaBoost pro vybrání malé sady příznaků i učení klasifikátoru. V původní podobě je algoritmus AdaBoost využíván pro zlepšení klasifikačního výkonu jednoduchého učícího algoritmu.

V tomto případě jednoduchý učící algoritmus vybere jeden obdélníkový příznak, který nejlépe odlišuje pozitivní a negativní vzorky. Pro každý příznak je určen optimální práh

klasifikační funkce tak, aby co nejmenší počet vzorků byl chybně klasifikován. Slabý klasifikátor $h_j(x)$ se tak skládá z příznaku f_j , hodnoty prahu θ_j a parity p_j indikující směr nerovnosti:


$$h_j(x) = \begin{cases} 1 & \text{když } p_j f_j(x) < p_j \theta_j \\ 0 & \text{jinak} \end{cases} \quad (3.5)$$

Parametr x je podokno originálního obrazu, zde o velikosti 24×24 pixelů.

Konstrukce kaskády klasifikátorů

Konstrukce kaskády klasifikátorů zajistí zvýšený výkon detekce, což sníží potřebný výpočetní čas. Klíčovou myšlenkou je vytvoření menších posilněných klasifikátorů, které jsou více efektivní. Tyto klasifikátory zamítají velkou část negativních podoken obrazu, zatímco detekují většinu pozitivních podoken. Jednodušší klasifikátory jsou použity k zamítnutí většiny podoken předtím, než jsou použity složitější klasifikátory.

Celková podoba detekčního procesu je rozhodovací strom, který je nazván kaskáda (viz. obrázek 3.7). Pozitivní výsledky prvního klasifikátoru spustí druhý klasifikátor, který je také upraven k dosažení velmi dobrých výsledků detekce. Nezamítnutá podokna z druhého klasifikátoru spustí třetí klasifikátor a tento postup se opakuje.



Obrázek 3.7: Schéma kaskády klasifikátorů. Série klasifikátorů je aplikována na každé podokno. První klasifikátor eliminuje většinu negativních vzorků při velmi malé době zpracování. Další vrstvy zamítnou další negativní podokna, ale potřebují vyšší dobu pro zpracování. Po několika vrstvách je počet podoken rapidně snížen [22].

3.2 Segmentace znaků

Vstupem modulu segmentace znaků je oblast, kterou detektor označil jako registrační značku. Tuto oblast je potřeba zpracovat a nalézt pozice jednotlivých znaků nebo zahodit v případě, že se o registrační značku nejedná. Pro řešení tohoto problému byly navrženy dva různé přístupy.

Prvním přístupem je kaskáda klasifikátorů, která detekuje znaky. Druhý přístup hledá v obraze kontury a filtruje je podle parametrů odpovídajícím znakům registrační značky.

3.2.1 Segmentace znaků pomocí kaskády klasifikátorů


Pro segmentaci znaků byla vyzkoušena kaskáda klasifikátorů, která je schopna detekovat oblasti jednotlivých znaků. Kaskáda použitá pro detekci znaků je natrénována nad znaky z datové sady pro trénování neuronové sítě, která je popsána v části 4.2.2. Detailnější popis kaskády klasifikátorů je pak uveden v části 3.1.1.

3.2.2 Vyhledávání kontur znaků

Oblast označená modulem detekce zachycuje kromě registrační značky i karoserii vozidla či další nechtěné objekty a často není ve vodorovné poloze. Pro extrakci tabulky registrační značky ze snímku a následnou rotaci je použit algoritmus Watershed. Zpracovaný snímek je poté převeden do binárních hodnot. V binárním obraze jsou vyhledány kontury a z těch aproximovány obdélníky obalující potenciální oblast znaků. Těchto oblastí je velké množství a proto je potřeba je vytřídit. Vytříděný seznam pozic jednotlivých oblastí je dále zaslán do modulu rozpoznání znaků.

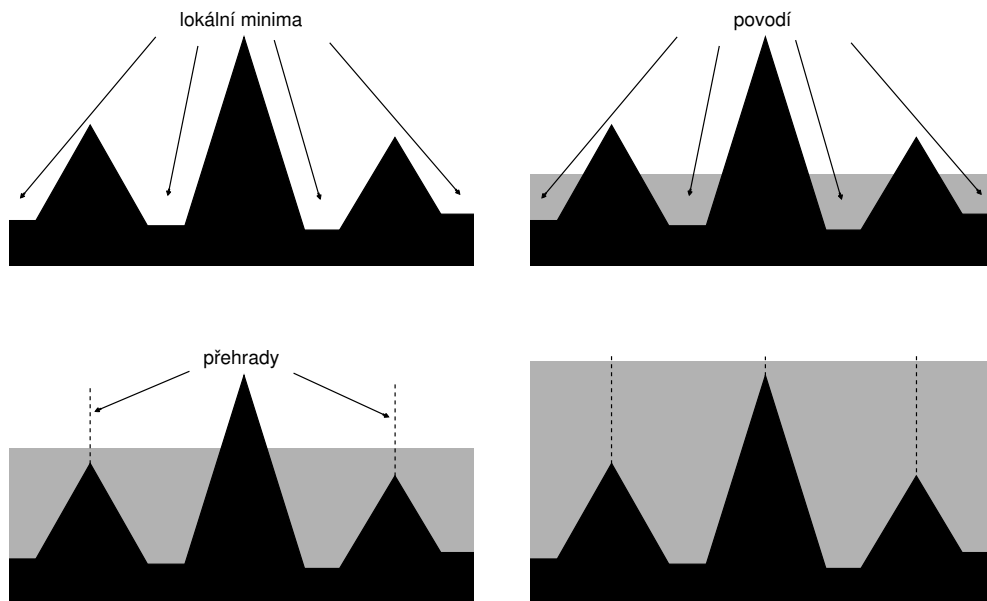
Zpracování vstupního snímku

Snímek vstupující do modulu segmentace znaků obsahuje kromě samotné registrační značky i její bezprostřední okolí. Snímky s registrační značkou, která není ve vodorovné poloze, mohou obsahovat složitě členité části karosérie či světla, které jsou při dalším zpracování chybně označeny jako znaky. Pro eliminaci těchto rušivých elementů je vhodné extrahovat registrační značku či jen část tabulky s bílým pozadím. Pro získání této oblasti je použit algoritmus Watershed, který dokáže oddělit oblast obsahující karoserii a oblast s registrační značkou. Po oddělení obou částí je oblast registrační značky pootočená do vodorovné pozice. Ukázka tohoto postupu je znázorněna na obrázku 3.8.



Obrázek 3.8: Postup extrakce registrační značky ze vstupního snímku. Vstupní snímek (a), použití algoritmu Watershed (b) a otočení registrační značky do vodorovné polohy (c)

Algoritmus Watershed je založen na předpokladu, že na jakýkoliv obraz v odstínech šedi je možné pohlížet jako na topografickou plochu. Tato plocha je pak postupně zaplavována vodou od nejnižších pozic až po nejvyšší. Vysoká intenzita pixelů v obraze znamená kopce a nízká intenzita nížiny. Algoritmus začíná v bodech lokálních minim, odkud se oblast postupně zaplavuje, čímž se vytvoří povodí (catchment basin). Aby se jednotlivá povodí neslila dohromady, jsou vytvořeny hráze (dams) v bodech lokálních maxim. Zaplávání oblastí pokračuje, dokud není dosaženo nejvyššího bodu, tedy maximální intenzity pixelu. Tímto postupem je získán obraz rozdělený do regionů (povodí), které jsou odděleny hrázemi. Průběh algoritmu je znázorněn na obrázku 3.9.



Obrázek 3.9: Průběh algoritmu Watershed [25]

Tento postup je vysoce citlivý k šumu v obraze, čímž vzniká velký počet regionů. Tomuto problému lze předejít označením počátečních oblastí zaplavitelní. Tím se omezí počet hrází a počet segmentovaných regionů. Více informací lze nalézt v tomto článku [25].

Třídění nalezených oblastí

Třídění oblastí probíhá v několika po sobě navazujících krocích. V každém kroku je odstraněna skupina oblastí spadajících do určité kategorie.

Nejprve jsou vyřazeny všechny oblasti, jejichž plocha nebo poměr stran jsou mimo zvolené intervaly. Tyto oblasti jsou většinou text nebo symbol v modrém pruhu či reklamní nápis na rámečku registrační značky. V dalším kroku jsou odstraněny duplicitní oblasti a spojeny překrývající se oblasti. V této kategorii kritérií se nacházejí uzavřené znaky (např. B, D nebo 0), u kterých je potřeba vnitřní oblast odstranit. Dále znaky N či H, kde dochází k nespojitosti prostřední části znaku. Tyto oblasti jsou pak spojeny do jedné. U snímků v menším rozlišení či větším úhlu pohledu může dojít k překrývání oblastí jednotlivých znaků. Ke spojení oblastí tedy dochází jen pokud výsledná oblast odpovídá svou šířkou průměru. Další třídění probíhá na základě průměrné výšky oblastí a jejich vzájemnou vzdáleností. V tomto kroku jsou odstraněny oblasti odpovídající rámečku registrační značky.

Tento postup třídění je znázorněn na obrázku 3.10.

3.3 Rozpoznání znaků

Vstupem modulu rozpoznání znaků je seznam pozic nalezených znaků. Nalezená pozice se vyřízne z originálního snímku registrační značky a její velikost se změní na 10×16 pixelů. Dále se pro každou oblast získají tři druhy příznaků. Příznaky poskytují informace o vstupním obraze, jako je například směr a umístění hran. Příznaky jsou získány pomocí prahování snímku a detekcí horizontálních a vertikálních hran. Detekce hran je provedena pomocí So-



Obrázek 3.10: Ukázka postupu filtrování nalezených oblastí znaků. Na snímku a) jsou všechny nalezené oblasti, na snímku b) jsou vyřazeny oblasti nevyhovující definovanému poměru stran nebo plochy oblasti. Snímek c) je po odstranění překrývajících se oblastí a snímek d) po vyřazení oblastí s neodpovídající výškou

belova operátoru. Takto získané příznaky pak slouží neuronové síti pro ohodnocení snímku. Toto ohodnocení určuje s jakou pravděpodobností rozpoznávaný znak patří do dané třídy znaků. Tento postup se opakuje pro všechny nalezené oblasti v seznamu. Výstupem tohoto modulu je pak rozpoznávaný text registrační značky.

Neuronová síť


Neuronová síť je výpočetní model, jejímž vzorem je skutečná neuronová síť. Neuronová síť je používána v oblasti umělé inteligence. Skládá se z umělých neuronů, které jsou navzájem propojeny. Každý neuron může mít několik vstupů, ale pouze jeden výstup.

V této práci je použita dopředná neuronová síť, přesněji vícevrstvá síť perceptronů, což je nejběžněji používaný typ neuronové sítě. Tato síť se skládá ze vstupní vrstvy, výstupní vrstvy a jedné nebo více skrytých vrstev. Každá vrstva neuronové sítě obsahuje jeden nebo více neuronů přímo propojených s neurony předešlé a následující vrstvy.


Všechny neurony v této síti jsou podobné. Každý z nich má několik vstupních propojení, které přivádějí na vstup výstup neuronů předešlé vrstvy a jeden výstup, skrz který posílají výsledky několika neuronům v další vrstvě. Hodnoty získané z předešlé vrstvy jsou sečteny s určitými váhami, které jsou individuální pro každý neuron a biasem. Součet je transformován pomocí aktivační funkce, která může být různá pro různé neurony. V případě výstupu x_j vrstvy n je výstup y_i vrstvy $n + 1$ vypočítán funkcí [15]:

$$u_i = \sum_j (w_{i,j}^{n+1} * x_j) + w_{i,bias}^{n+1} \quad (3.6)$$

$$y_i = f(u_i) \quad (3.7)$$



Obrázek 3.11: Příklad vícevrstvé perceptronové sítě se třemi vrstvami. Vstupní vrstva obsahuje tři vstupy, výstupní vrstva dva výstupy a pět neuronů je ve skryté vrstvě [15]



Obrázek 3.12: Struktura neuronu [15]

Sobelův operátor

Sobelův operátor je popsán v knize [9]. Sobelův operátor je klasický lineární filtr pro detekci hran. Je založen na jednoduchém jádru o velikosti 3×3 , které je znázorněno na obrázku 3.13.

Když se na obraz podíváme jako na dvoudimenzionální funkci, Sobelův operátor může být vnímán jako míra změn v obraze ve vertikálním a horizontálním směru. Tato míra je v matematice nazývána gradientem a je definována jako dvourozměrný vektor vytvořený z první derivace funkce ve dvou ortogonálních směrech:

$$\text{grad}(I) = \left[\frac{\partial I}{\partial x}, \frac{\partial I}{\partial y} \right]^T \quad (3.8)$$

Sobelův operátor tedy poskytuje aproximaci gradientu obrazu odlišností pixelů v horizontálním a vertikálním směru. Sobelův operátor pracuje s malým oknem okolo daného pixelu za účelem snížení vlivu šumu.

Jelikož je gradient dvourozměrný vektor, tak má normu a směr. Norma gradientu vektoru udává amplitudu změn v obraze a obvykle se počítá jako Euklidovská norma:

$$|\text{grad}(I)| = \sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2} \quad (3.9)$$

Vektor gradientu vždy ukazuje do směru největší změny. Pro obraz to znamená, že směr gradientu bude ortogonální k hraně, ukazující směr od tmavších po světlejší pixely. Směr úhlu gradientu je vypočítán následovně:

$$\angle \text{grad}(I) = a \tan\left(-\frac{\partial I}{\partial y} / \frac{\partial I}{\partial x}\right) \quad (3.10)$$

-1	0	1		-1	-2	-1
-2	0	2		0	0	0
-1	0	1		1	2	1

Obrázek 3.13: Jádro Sobelova operátoru o velikost 3×3 pro detekci vertikálních a horizontálních hran [9]

3.4 Omezení systému

Vzhledem k použitým algoritmům strojového učení (viz. sekce 3.1 a 3.3) je navržený systém omezen na základě různorodosti datové sady. Pořízená datová sada je popsána v části 4.2. Konkrétně kaskáda klasifikátorů je schopna detekovat registrační značky stejných či podobných formátů jako jsou registrační značky v trénovací datové sadě. Naprostá většina registračních značek v datové sadě je nejběžněji používaného typu (obrázek 2.1) a tedy systém je omezen na tento formát registračních značek.

Pro trénování neuronové sítě jsou použity znaky nacházející se na českých registračních značkách. Je tedy možné předpokládat, že zahraniční registrační značky s odlišným fontem budou mít sníženou úspěšnost rozpoznání oproti českým registračním značkám.

Navržený systém je tedy zaměřen na detekci a rozpoznání aktuálně vydávaných českých registračních značek ve formátu 520×110 mm.

Kapitola 4

Implementace a vyhodnocení systému

V této kapitole jsou představeny technologie použité pro vývoj systému a datové sady vytvořené pro implementaci a testování systému. Dále je zde popsána implementace jednotlivých modulů systému a provedené experimenty. Experimenty sloužily k určení optimálních hodnot jednotlivých postupů. Jednotlivé části systému jsou zde také vyhodnoceny a nakonec je vyhodnocen systém jako celek.

4.1 Použité technologie

Vytvořený systém je implementován v jazyce C++ s použitím knihoven OpenCV a TinyDir, které jsou v této sekci představeny. Výsledný systém je multiplatformní aplikace ovládaná pomocí příkazového řádku s volitelným grafickým výstupem.

OpenCV

OpenCV (Open Source Computer Vision)¹ je multiplatformní knihovna zaměřená na počítačové vidění a strojové učení. Knihovna nabízí více než 2500 optimalizovaných algoritmů. Původně byla vyvinuta firmou Intel a v současnosti je volně šiřitelná pod licencí BSD. Knihovna je napsaná v jazyce C++ a je možné ji využít v řadě dalších jazyků, např. Python, Java nebo C#. V této práci je použita verze 2.4.

TinyDir

TinyDir² je jednoduchá a přenosná knihovna pro čtení složek a souborů.

4.2 Vytvořené datové sady

Pro vypracování této práce bylo potřeba vytvořit datovou sadu registračních značek. Snímky datové sady byly pořízeny na území města Brna s rozlišením 1600×1200 px. Celkem bylo pořízeno 913 snímků vozidel. Snímky jsou různorodé počtem registračních značek, úhlem pohledu, velikostí či typem registrační značky (viz. kapitola 2).

¹<http://opencv.org/>

²<https://github.com/cxong/tinydir>

Dále byla vedoucím práce poskytnuta datová sada snímků vyříznutých z šesti videí. Tato datová sada obsahuje celkem 4380 snímků s rozlišením 848×480 px. Dle očekávání většina registračních značek odpovídá nejběžněji používanému formátu vydávanému v současnosti v České republice (obr. 2.1).

Z pořízené datové sady bylo vyčleněno 192 snímků pro účely testování systému. V testovací sadě se nachází registrační značky zachycené pod velkým úhlem, registrační značky starého formátu i zahraniční. Zbytek datové sady je určen pro trénování vybraných algoritmů a dále bude označován jako trénovací datová sada.



Obrázek 4.1: Snímky z pořízené datové sady

4.2.1 Datová sada pro trénování detektoru

Pro trénování detektoru registračních značek byla potřeba pořízenou trénovací sadu ručně zpracovat. Byla vytvořena pozitivní datová sada, která obsahuje výřezy registračních značek z originálních snímků a soubor obsahující cesty k jednotlivým snímkům registračních značek. Dále byla vytvořena negativní datová sada, která se skládá z originálních snímků, kde je pozice registrační značky začerněna. Anotační soubor negativní sady obsahuje seznam cest k jednotlivým snímkům. Tyto datové sady jsou zobrazeny na obrázku 4.2 a v tabulce 4.1 je uveden počet snímků.



Obrázek 4.2: Příklad snímků z pozitivní a negativní datové sady

Datová sada	Počet snímků
pozitivní sada	3443
negativní sada	3942

Tabulka 4.1: Počet snímků v datových sadách

4.2.2 Datová sada pro trénování rozpoznání znaků

Datová sada pro trénování neuronové sítě se skládá z výřezů jednotlivých znaků registračních značek. Znaky byly ručně vyříznuty z datové sady pozitivních snímků určených pro trénování detektoru registračních značek. Na obrázku 4.3 je ukázána datová sada znaku 3. Po vyříznutí jsou znaky roztrženy do odpovídajících kategorií. V pořízené sadě písmen se v dostatečném množství vyskytuje písmeno B, avšak zbytek používaných písmen je v nedostatečném počtu. Tento problém byl vzhledem k místě sběru datové sady předpokládán. V tabulce 4.2 je uveden počet získaných znaků v každé kategorii.

Znak	Počet	Znak	Počet	Znak	Počet
0	469	C	56	P	31
1	481	D	16	Q	1
2	444	E	30	R	20
3	464	F	10	S	35
4	469	G	6	T	70
5	429	H	19	U	12
6	460	I	52	V	23
7	470	J	42	W	2
8	465	K	35	X	6
9	458	L	39	Y	11
A	125	M	76	Z	112
B	568	N	18		

Tabulka 4.2: Počet znaků v datové sadě



Obrázek 4.3: Vyříznuté znaky

4.2.3 Příprava testovací datové sady

Pro vyhodnocení úspěšnosti jednotlivých modulů a celého systému byla připravena testovací datová sada. Sada se skládá ze 192 snímků. Tato sada byla dále rozdělena do čtyř kategorií. První kategorie je označena jako „normální“ a obsahuje registrační značky zachycené ve vodorovné pozici. Kategorie označená jako „otočené“ obsahuje registrační značky zachycené pod velkým úhlem pohledu. Do další kategorie jsou zařazeny registrační značky starého formátu popsané v části 2.1.1 a je pojmenována „staré“. V poslední kategorii jsou zahraniční registrační značky a je tedy označena jako „zahraniční“. Na obrázku 4.4 jsou uvedeny příklady z jednotlivých kategorií.



Obrázek 4.4: Příklad snímků z jednotlivých kategorií datové sady.

Pro vyhodnocení úspěšnosti modulu detekce registrační značky byl vytvořen anotační soubor obsahující název snímku, počet registračních značek a jejich umístění ve snímku. Umístění je vyjádřeno pozicí levého horního rohu a pravého dolního rohu registrační značky.

K vyhodnocení úspěšnosti modulu segmentace znaků byl vytvořen obdobný anotační soubor. Místo pozice rohů registrační značky jsou v něm však uvedeny pozice rohů jednotlivých znaků.

Vyhodnocení modulu rozpoznání znaků je provedeno nad vyextrahovanými znaky registračních značek z testovací sady. Znaky jsou rozříděny do složek, které reprezentují abecedu znaků používanou na registračních značkách.

Pro vyhodnocení celého systému byl vytvořen anotační soubor, který obsahuje cestu k snímku, počet registračních značek ve snímku a jejich text bez mezery.

4.3 Detekce registrační značky

Pro detekci registračních značek byla zvolena kaskáda klasifikátorů, která je popsána v sekci 3.1. V první části této sekce je popsáno trénování kaskády klasifikátorů a porovnání výsledků pro různé parametry zvolené při trénování. Další část rozebírá samotnou detekci registrační značky a hodnoty parametrů, které mají vliv na její úspěšnost. V poslední části je pak modul detekce registrační značky vyhodnocen.

4.3.1 Trénování kaskády klasifikátorů

Pro trénování kaskády klasifikátorů byla použita datová sada popsaná v části 4.2.1. Pro zvýšení různorodosti této datové sady byly vygenerovány další snímky. Ke generování snímků byl použit program `opencv_createsamples` [13], který je přiložen ke knihovně OpenCV. Tento program vytváří nové snímky změnou perspektivy snímků z originální datové sady. Hlavním přínosem tohoto programu je rotace původních snímků okolo všech os. Maximální rotace původního snímku byla nastavena na 45° .

Trénování kaskády klasifikátorů zajišťuje program `opencv_traincascade` [13], který je také přiložen ke knihovně OpenCV. Pro trénování byl zvolen algoritmus Gentle AdaBoost a příznaky LBP, které jsou popsány v části 3.1.1. Dále bylo potřeba zvolit vhodné parametry trénování. Za tímto účelem bylo provedeno několik experimentů. U experimentů byla sledována úspěšnost a přesnost detekce. Přesnost detekce udává poměr správně a chybně nalezených oblastí registračních značek. Výsledky vybraných experimentů jsou uvedeny v tabulce 4.3.

poz. snímky	neg. snímky	mHR	MFA	TP	FP	FN	úspěšnost	přesnost
1000	700	0,995	0,5	259	44	33	88,7%	85,5%
5000	5000	0,995	0,5	278	39	14	95,2%	87,7%
10000	5000	0,995	0,5	281	25	11	96,2%	91,8%
10000	100000 ³	0,995	0,5	280	70	12	95,9%	80,0%
10000	5000	0,9995	0,2	279	12	13	95,5%	95,9%

Tabulka 4.3: Vliv parametrů trénování kaskády klasifikátorů na její úspěšnost. Testovací sada obsahuje 292 registračních značek na 192 snímcích. Význam zkratk je následující: mHR - minimální požadovaná míra správně nalezených oblastí pro každý stupeň, MFA - maximální požadovaná míra chybně nalezených oblastí pro každý stupeň, TP - správně nalezené registrační značky, FP - nalezené oblasti, v kterých není registrační značka, FN - nenalezené registrační značky

4.3.2 Detekce pomocí kaskády klasifikátorů

Před samotnou detekcí registrační značky je vstupní snímek předzpracován pomocí funkcí `cvtColor()` a `GaussianBlur()`. Detekce pomocí kaskády klasifikátorů se spouští pomocí metody `detectMultiScale()`, kterou je možné nalézt ve třídě `CascadeClassifier` [12].

Kromě vstupního snímku je možné této metodě také zadat několik parametrů. Pro výslednou úspěšnost detekce jsou zajímavé parametry `minNeighbors` a `scaleFactor`. Parametr `minNeighbors` udává minimální počet sousedních oblastí nutný pro označení oblasti jako kandidátní. Parametr `scaleFactor` pak udává poměr zmenšení snímku pro každý stupeň. Hodnota těchto parametrů byla určena experimentálně a v tabulce 4.4 jsou tyto experimenty uvedeny.

4.3.3 Vyhodnocení modulu detekce

Výsledná kaskáda klasifikátorů dosahuje úspěšnosti 95,5% a přesnosti 95,9%. Pro trénování této kaskády bylo použito 22 000 vygenerovaných pozitivních vzorků o velikosti 60×16 pi-

³Originální negativní snímky jsou nařezány na velikost 60×16 pixelů, což odpovídá velikosti pozitivních snímků.

xelů a 3900 negativních vzorků. Parametr detekce *minNeighbors* je 3 a parametr *scaleFactor* je 1,1. V tabulce 4.5 je uvedena úspěšnost a přesnost pro jednotlivé kategorie testovací datové sady, které jsou popsány v sekci 4.2.3.

MN	SF	TP	FP	FN	úspěšnost	přesnost
1	1,05	283	179	9	96,9%	61,3%
1	1,1	281	70	11	96,2%	80,1%
1	1,2	278	41	14	95,2%	87,1%
1	1,3	271	34	21	92,8%	88,9%
2	1,05	282	77	10	96,6%	78,6%
2	1,1	280	26	12	95,9%	91,5%
2	1,2	273	13	19	93,5%	95,5%
2	1,3	265	15	27	90,8%	94,6%
3	1,05	280	44	12	95,9%	86,4%
3	1,1	279	12	13	95,5%	95,9%
3	1,2	270	9	22	92,5%	96,8%
3	1,3	257	12	35	88,0%	95,5%
4	1,05	280	37	12	95,9%	88,3%
4	1,1	277	7	15	94,9%	97,5%
4	1,2	268	8	24	91,8%	97,1%
4	1,3	252	11	40	86,3%	95,8%

Tabulka 4.4: Úspěšnost kaskády klasifikátorů v závislosti na změně hodnot parametrů *minNeighbors* a *scaleFactor*. Testovací sada obsahuje 292 registračních značek. Význam použitých zkratk je následující: MN - parametr *minNeighbors*, SF - parametr *scaleFactor*, TP - správně nalezené registrační značky, FP - nalezené oblasti, v kterých není registrační značka, FN - nenalezené registrační značky, přesnost - poměr správně a špatně nalezených oblastí registračních značek

kategorie	počet RZ	úspěšnost	přesnost
normální	191	100,0%	96,5%
otočené	58	82,8%	90,6%
staré	33	100,0%	100,0%
zahraniční	10	70,0%	100,0%
celkem	292	95,5%	95,9%

Tabulka 4.5: Úspěšnost výsledné kaskády klasifikátorů. Přesnost udává poměr správně a špatně nalezených oblastí registračních značek

4.4 Segmentace znaků

Pro vyhledání kandidátních oblastí znaků byly vyzkoušeny dva přístupy. Prvním z nich je kaskáda klasifikátorů, která je detailněji popsána v sekci 3.1.1. Druhým přístupem je vyhledávání kontur znaků, které je popsáno v sekci 3.2.2. Dále je v této kapitole popsáno třídění nalezených oblastí a nakonec je celý modul vyhodnocen.

4.4.1 Kaskáda klasifikátorů


Kaskáda klasifikátorů pro detekci znaků byla trénována obdobným způsobem jako je popsán v sekci 4.3. Jako pozitivní sada snímků byly použity snímky jednotlivých znaků připravených pro trénování neuronové sítě. Negativní snímky tvoří negativní datová sada použitá při trénování kaskády klasifikátorů pro detekci registrační značky. Tyto datové sady jsou popsány v sekci 4.2. Použité pozitivní snímky mají velikost 16×10 pixelů, která vychází z poměru stran znaků.

4.4.2 Extrakce registrační značky

Pro extrakci registrační značky ze vstupního snímku byl použit algoritmus Watershed, který je popsán v části 3.2.2. Před jeho použitím je nejprve potřeba označit oblasti snímku, z kterých se bude zaplavovat. Oblast pozadí je označena na levém okraji snímku a oblast registrační značky uprostřed snímku. Algoritmus Watershed následně rozdělí snímek na dvě oblasti dle zvolených bodů. Pro oblast registrační značky je získán otočený obalový obdélník. Tento obdélník udává úhel otočení oblasti registrační značky. Oblast je následně otočena do vodorovné polohy a vyříznuta ze vstupního snímku. Tento postup je znázorněn na obrázku 3.8.

4.4.3 Hledání kontur

Před samotným vyhledáním kontur bylo potřeba vstupní snímek zpracovat. Zpracování spočívá ve zvýraznění hledaných objektů, kterými jsou v tomto případě znaky. Pro tento účel bylo vyzkoušeno několik různých metod prahování a detekce hran.



Obrázek 4.5: Výstup různých metod zvýraznění znaků - prahování s pevným prahem, adaptivní prahování, prahování metodou Otsu, Cannyho detektor hran, Sobelův operátor pro detekci hran

V takto zpracovaném snímku jsou vyhledány kontury objektů. Pro jednotlivé kontury jsou získány obalové obdélníky, které jsou dále považovány za kandidátní oblasti znaků.



Obrázek 4.6: Ukázka nalezených kontur znaků a jejich obalových obdélníků

4.4.4 Třídění znaků

Nalezené oblasti jsou tříděny pomocí sekvence algoritmů, které vyřazují oblasti neodpovídající zadaným kritériím. Tato kritéria vycházejí z vlastností registračních značek jako je poměr stran, umístění či počet znaků. Hodnoty těchto parametrů jsou jednoznačně definovány, ale při změně úhlu pohledu či perspektivy již neplatí. Z tohoto důvodu bylo potřeba experimentálně určit vhodné rozsahy použitých parametrů.

Nejdříve jsou vyřazeny oblasti, které nespádají do definovaného rozsahu poměrů stran. Minimální poměr stran je 0,1 a maximální 0,9. Tento rozsah je značně široký z důvodu rozdílné šířky znaků. Dále jsou vyřazeny oblasti s příliš malou či příliš velkou plochou. Minimální plocha je 160 pixelů a maximální plocha odpovídá 15% velikosti vstupního snímku registrační značky. Spodní mez vychází z minimální velikosti znaku pro rozpoznání a horní mez z celkového počtu znaků registrační značky.

Následuje spojení prolínajících se oblastí. Prolínající se oblasti jsou hledány na základě pozic rohů. Oblasti jsou považovány za prolínající se pokud se roh jedné oblasti nachází mezi protilehlými rohy jiné oblasti. Před samotným spojením těchto oblastí je zkontrolováno, zda výsledná oblast spadá do rozsahu poměrů stran a plochy.

Další třídění je založeno na výšce jednotlivých oblastí. Oblasti jsou na základě výšky rozděleny do skupin. Skupiny jsou vytvořeny dle rozsahu, který je vypočítán z výšky jednotlivých oblastí se započtením odchylky 17%. Oblasti, které nespádají do skupiny s největším počtem prvků, jsou vyřazeny.

Pokud je celkový počet vytříděných oblastí menší než pět, je tento snímek vyřazen z dalšího zpracování. Tímto krokem se vyřadí většina chybně detekovaných oblastí registračních značek. Nakonec jsou oblasti seřazeny dle vzdálenosti od počátku horizontální osy. Tím se docílí správného pořadí znaků registrační značky.

4.4.5 Vyhodnocení modulu segmentace znaků

Pro vyhledání znaků byla vyzkoušena kaskáda klasifikátorů a vyhledání kontur. Dále bylo vyzkoušeno několik metod zpracování vstupního snímku pro zvýraznění objektů před vyhledáním kontur. Výsledky jednotlivých experimentů jsou uvedeny v tabulce 4.6. Nejúspěšnějším přístupem je vyhledání kontur s použitím adaptivního prahování, který dosahuje úspěšnosti 93,3% a přesnosti 96,5%. Modul segmentace znaků byl testován nad jednotlivými znaky. Lze tedy předpokládat, že úspěšnost pro celý text registrační značky bude nižší.

metoda	TP	FP	FN	úspěšnost	přesnost
pevný práh	1484	44	452	76,65%	97,12%
adaptivní prahování	1807	65	129	93,34%	96,53%
Otsu prahování	1752	62	184	90,50%	96,58%
Sobelův operátor	1520	91	416	78,51%	94,35%
Cannyho det. hran	1792	83	144	92,56%	95,57%
kaskáda klasifikátorů	1662	143	274	85,85%	92,08%

Tabulka 4.6: Porovnání úspěšnosti metod použitých při segmentaci znaků. Testovací datová sada obsahuje 1936 znaků. Význam použitých zkratk: TP - správně nalezené oblasti znaků, FP - nalezené oblasti, v kterých není znak, FN - nenalezené znaky

4.5 Rozpoznání znaků

Pro rozpoznání znaků byla zvolena neuronová síť, která je detailněji rozebrána v sekci 3.3. První část této sekce popisuje zpracování a přípravu snímků z pořízené datové sady. V další části je popsáno trénování neuronové sítě a uvedeny experimenty vedoucí k volbě vhodných parametrů učení. V poslední části je modul rozpoznání znaků vyhodnocen.

4.5.1 Příprava dat

Vytvořená datová sada znaků, která je popsána v sekci 4.2.2, neobsahuje dostatečný počet vzorků pro každý znak. Z toho důvodu bylo potřeba vygenerovat další znaky pro kategorie s nedostatečným počtem kusů. Další snímky byly generovány na základě již existujících pomocí drobných změn natočení, intenzity či posunutí.

Ze všech snímků je dále oříznut přebytečný bílý okraj a poté je změněna jejich velikost na 16×10 pixelů. Zvolená velikost snímku byla určena na základě poměru stran znaků a několika experimentů uvedených v tabulce 4.7.

velikost snímku	úspěšnost	
	procent	počet
16×10	98,4%	1803
16×16	98,3%	1801
26×16	85,4%	1565

Tabulka 4.7: Vliv velikosti snímku znaku na úspěšnost neuronové sítě. Testovací datová sada obsahuje 1833 snímků

4.5.2 Trénování neuronové sítě

V této práci je použita dopředná neuronová síť, která je dostupná v knihovně OpenCV. Pro každý vstupní snímek jsou získány tři příznaky (obrázek 4.7). Tyto příznaky jsou získány pomocí prahování a Sobelova operátoru pro detekci horizontálních a vertikálních hran (viz. sekce 3.3). Příznaky jsou dále převedeny do číselných řetězců, které jsou zaslány neuronové síti. Na základě těchto příznaků se neuronová síť naučí rozeznávat jednotlivé třídy znaků. Pro optimální natrénování neuronové sítě byla provedena řada experimentů, pomocí kterých byly zvoleny vhodné parametry učení. Několik experimentů je uvedeno v tabulce 4.8.



Obrázek 4.7: Ukázka příznaků pro znaky 0, 9 a B

Výsledná neuronová síť je trénována pomocí učícího algoritmu Back-Propagation a symetrické sigmoidální přenosové funkce. Maximální počet iterací trénování je 2000 a minimální rozdíl vah mezi iteracemi je 0.00001 epsilon. Neuronová síť je složena ze tří vrstev.

Vstupní vrstva je složena ze 480 vstupních neuronů, což odpovídá velikosti tří příznaků snímku o velikosti 16×10 pixelů. Skrytá vrstva obsahuje 64 neuronů a výstupní vrstva je složena z 32 výstupních neuronů, kde každý reprezentuje třídu abecedy znaků.

počet neuronů skryté vrstvy	epsilon	počet iterací	úspěšnost	
			procent	počet
64	1×10^{-4}	55	98,2%	1800
64	1×10^{-5}	153	98,4%	1803
64	1×10^{-6}	428	98,2%	1800
64	1×10^{-7}	1192	98,2%	1800
128	1×10^{-4}	65	97,5%	1788
128	1×10^{-5}	207	97,8%	1792
128	1×10^{-6}	417	97,5%	1787
128	1×10^{-7}	1203	97,9%	1794
256	1×10^{-4}	184	97,3%	1784
256	1×10^{-5}	315	97,6%	1789
256	1×10^{-6}	603	97,7%	1791
256	1×10^{-7}	1149	97,5%	1788

Tabulka 4.8: Experimenty s parametry trénování neuronové sítě

4.5.3 Vyhodnocení modulu rozpoznání znaků

Modul rozpoznání znaků dosahuje úspěšnosti 98,4% nad testovací datovou sadou. Vyhodnocení modulu probíhalo nad jednotlivými znaky a lze tedy předpokládat, že pro řetězce znaků bude úspěšnost modulu nižší. V testovací datové sadě je nedostatečný počet většiny písmen. Výsledná úspěšnost tedy platí především pro číslice a písmena, která jsou zastoupená v dostatečném množství. Chybná rozpoznání jsou většinou zapříčiněna podobnými znaky jako jsou dvojice B a 8 a D a 0. Tyto znaky lze velmi lehce zaměnit i při drobné změně perspektivy. V tabulce 4.9 je zobrazena matice záměn znaků.

4.6 Vyhodnocení celého systému

Propojením jednotlivých modulů vznikne systém pro detekci a rozpoznání registrační značky. Pro vyhodnocení systému bylo použito několik rozdílných metod použitých v modulu segmentace znaků (viz. 4.4). Nejúspěšnější metodou je kombinace prahování pomocí metody Otsu a adaptivního prahování. Tato metoda dosahuje úspěšnosti 81,5% pro korektní rozpoznání celého textu registrační značky. Výsledky dalších metod jsou uvedeny v tabulce 4.10.

Rozpoznání registrační značky z celé detekované oblasti dosahuje vyšší úspěšnosti než rozpoznání znaků z vyextrahované oblasti pomocí algoritmu Watershed. Z tohoto důvodu není extrakce pomocí algoritmu Watershed použita ve výsledném systému.

	0	1	2	3	4	5	6	7	8	9	A	B	C	D	E	F	H	I	J	K	L	M	N	P	R	S	T	U	V	X	Y	Z	
0	122	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0
1	1	163	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
2	0	0	158	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
3	0	0	0	158	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	165	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	135	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	141	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	167	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
8	1	0	0	0	0	0	0	0	146	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	0	137	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
A	0	0	0	0	0	0	0	0	0	0	22	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
B	0	0	0	0	0	0	0	0	0	1	0	191	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
C	0	0	0	0	0	0	0	1	0	0	0	0	6	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
D	0	0	0	0	0	0	1	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0
E	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
F	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
H	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
I	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	1	2	0	0	0	0	0	0	0	0	0	0	1	2	0	0	0
J	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0
K	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	0	0	0	0	0	0
L	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0
M	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	4	0	0	0	0	0	0	0	0	0	0
N	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0
P	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	0	0
R	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
S	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0
T	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	12	0	0	0	0	0
U	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
V	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
X	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Y	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
Z	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	17

Tabulka 4.9: Matice záměn znaků

metoda	úspěšnost				
	normální	otočené	staré	zahraniční	celkem
Otsu prahování	85,86%	55,17%	69,70%	20,00%	75,68%
adaptivní prahování	81,68%	55,17%	78,79%	20,00%	73,97%
Otsu + adaptivní prahování	91,10%	62,07%	75,76%	30,00%	81,51%
Cannyho det. hran	83,25%	44,83%	75,76%	30,00%	67,47%
extrakce registrační značky	83,25%	51,72%	75,76%	10,00%	73,63%

Tabulka 4.10: Úspěšnost systému pro detekci a rozpoznání registrační značky. Datová sada a její rozdělení do kategorií je popsáno v části 4.2.3

Kapitola 5

Závěr

Cílem této práce bylo seznámit se s metodami pro detekci a rozpoznání registračních značek vozidel a na jejich základě navrhnout a implementovat systém pro detekci a rozpoznání registračních značek. Navržený systém je rozdělen do tří hlavních částí. Konkrétně se jedná o detekci registrační značky, segmentaci znaků a rozpoznání znaků. Jednotlivé moduly systému byly implementovány a otestovány. Pro tento účel byla vytvořena datová sada obsahující 3443 snímků registračních značek.

Modul detekce registrační značky je založen na kaskádě klasifikátorů a dosahuje úspěšnosti 95,5% při přesnosti 95,9%. Datová sada použitá pro testování obsahuje několik typů registračních značek, různý úhel pohledu a vzdálenost. Segmentace znaků byla provedena pomocí kaskády klasifikátorů a vyhledání kontur. Kaskáda klasifikátorů dosahuje úspěšnosti 85,9% s přesností 92,1%, zatímco vyhledávání kontur dosahuje úspěšnosti 93,3% s přesností 96,5% a je tedy v této práci použito. Rozpoznání znaků registrační značky je provedeno pomocí neuronové sítě a dosahuje úspěšnosti 98,4%. Výsledný systém složený z těchto modulů dosahuje úspěšnosti 81,5% pro korektní rozpoznání celého textu registrační značky.

Budoucí vývoj práce bude spočívat v rozšíření datové sady se zaměřením na znaky. Sada znaků je značně omezena počtem snímků písmen. Toto omezení je dáno sběrem snímků na území města Brna. Dále je možné se zaměřit na modul segmentace znaků, který je nejužším bodem celého systému. Toto rozšíření by mohlo být zaměřeno na určitý typ registrační značky. Tím by bylo možné ověřit pozice nalezených oblastí znaků či chybějící oblast znaku určit. Také by bylo možné ověřit, zda se rozpoznáný znak může na dané pozici nacházet.

Literatura

- [1] Camera, S. L.: Austria 2. online, 2014-09 [cit. 2016-03-18].
URL <http://www.plateshack.com/y2k/Austria2/austria2.html>
- [2] Dlagnekov, L.: License Plate Detection Using AdaBoost. Technická zpráva, Department of Computer Science & Engineering, University of California San Diego, 2004.
- [3] Duan, T. D.; Du, T. L. H.; Phuoc, T. V.; aj.: Building an Automatic Vehicle License-Plate Recognition System. *International Conference on Computer Sciences Research, Innovation & Vision for the Future*, 2005: s. 59–63.
- [4] Gilly, D.; Raimond, K.: License Plate Recognition - A Template Matching Method. *International Journal of Engineering Research and Applications*, ročník 3, č. 2, 2013: s. 1240–1245.
- [5] Kahraman, F.; Kurt, B.; Gökmen, M.: License Plate Character Segmentation Based on the Gabor Transform and Vector Quantization. *Computer and Information Sciences*, 2003: s. 381–388.
- [6] Kamat, V.; Ganesa, S.: An Efficient Implementation of the Hough Transform for Detecting Vehicle License Plates Using DSP's. *Real-Time Technology and Applications Symposium*, 1995: s. 58–59.
- [7] Kasaei, S. H.; Kasaei, S. M.; Kasaei, S. A.: New Morphology-Based Method for Robust Iranian Car Plate Detection and Recognition. *International Journal of Computer Theory and Engineering*, ročník 2, č. 2, 2010: s. 264–268.
- [8] Krokodyl, I.: Slovak registration. online, 2015-04-19 [cit. 2016-03-18].
URL <https://commons.wikimedia.org/w/index.php?curid=2541147>
- [9] Laganiere, R.: *OpenCV 2 Computer Vision Application Programming Cookbook*. Packt Publishing Ltd., 2011, iISBN 978-1-849513-24-1.
- [10] Martín, F.; García, M.; Alba, J. L.: New Methods for Automatic Reading of VLP's (Vehicle License Plates). *Signal Processing, Pattern Recognition, and Application*, 2002.
- [11] Ojala, T.; Pietikäinen, M.; Harwood, D.: A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, ročník 29, č. 1, 1996: s. 51–59.

- [12] OpenCV: Cascade Classification. online, 2016-04-24 [cit. 2016-04-24].
URL http://docs.opencv.org/2.4/modules/objdetect/doc/cascade_classification.html
- [13] OpenCV: Cascade Classifier Training. online, 2016-04-24 [cit. 2016-04-24].
URL http://docs.opencv.org/2.4/doc/user_guide/ug_traincascade.html
- [14] OpenCV: Local Binary Patterns Histograms. online, 2016-04-24 [cit. 2016-04-24].
URL http://docs.opencv.org/2.4/modules/contrib/doc/facerec/facerec_tutorial.html#local-binary-patterns-histograms
- [15] OpenCV: Neural Networks. online, 2016-04-24 [cit. 2016-04-24].
URL http://docs.opencv.org/2.4/modules/ml/doc/neural_networks.html
- [16] Oz, C.; Ercal, F.: Automatic Vehicle License Plate Recognition using Artificial Neural Networks. *Intelligent Systems Design and Applications*, ročník 23, 2003: s. 23–31.
- [17] Parasuraman, K.; Subin, P.: SVM Based License Plate Recognition System. *International Conference on Computational Intelligence and Computing Research*, 2010.
- [18] Česká republika: Vyhláška č. 291/2004 Sb., kterou se mění vyhláška č. 243/2001 Sb., o registraci vozidel, ve znění pozdějších předpisů. *Sbírka zákonů České republiky*, ročník 98, 2004: s. 6202–6215.
URL <http://www.feudal.cz/spz/dokumenty/sb0952004.pdf>
- [19] Česká republika: Vyhláška č. 343/2014 Sb., o registraci vozidel. *Sbírka zákonů České republiky*, ročník 136, 2014: s. 4474–4560.
URL <http://www.psp.cz/sqw/sbirka.sqw?cz=343&r=2014>
- [20] Česká republika: Vyhláška, kterou se mění vyhláška č. 343/2014 Sb., o registraci vozidel. *Sbírka zákonů České republiky*, ročník 164, 2015: str. 5374.
URL http://www.epravo.cz/_dataPublic/sbirky/2015/sb0164-2015.pdf
- [21] Shellycoat, E.: British vehicle registration plate EU. online, 2010-04-28 [cit. 2016-03-18].
URL <https://commons.wikimedia.org/w/index.php?curid=10187240>
- [22] Viola, P.; Jones, M.: Rapid Object Detection using a Boosted Cascade of Simple Features. *Conference on Computer Vision and Pattern Recognition*, ročník 1, 2001: s. 511–518.
- [23] Willtron: German license plate. online, 2008-08-23 [cit. 2016-03-18].
URL https://commons.wikimedia.org/wiki/File:German_license_plate.svg
- [24] Willtron: Polish license plate. online, 2008-10-11 [cit. 2016-03-18].
URL https://commons.wikimedia.org/wiki/File:Polish_license_plate.svg
- [25] Zhao, Y.; Liu, J.; Li, H.; aj.: Improved Watershed Algorithm for Dowels Image Segmentation. *Proceedings of the 7th World Congress on Intelligent Control and Automation*, 2008: s. 7644–7648.