

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 VOZIDLA PRO ANALÝZU DOPRAVY

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. TEREZA ČERNÁ

BRNO 2015



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 VOZIDLA PRO ANALÝZU DOPRAVY

LICENSE PLATE DETECTION AND RECOGNITION FOR TRAFFIC ANALYSIS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. TEREZA ČERNÁ

VEDOUCÍ PRÁCE

SUPERVISOR

Doc. Ing. ADAM HEROUT, Ph.D.

BRNO 2015

Abstrakt

Tato diplomová práce se zabývá návrhem a vývojem systému pro detekci a rozpoznání registračních značek vozidel. Práce je rozdělena do tří základních částí: detekce registračních značek, nalezení pozic znaků, rozpoznání znaků. Pro účely práce byla pořízena nová datová sada, která obsahuje 2814 registračních značek pro účely trénování klasifikátorů a 2620 značek pro vyhodnocení úspěšnosti. Pro detekci registračních značek byl natrénován kaskádový klasifikátor, který dosahuje úspěšnosti až 97,8 %. Ve všech nalezených pozicích jsou vyhledány pozice znaků. Pokud nejsou nalezeny, pak daný výřez není registrační značkou. Úspěšnost detekce po nalezení všech pozic znaků je až 88,5 %. Rozpoznání znaků probíhá pomocí natrénovaného SVM klasifikátoru. Systém úspěšně rozpozná bez chyby až 97,7 % všech správně nalezených registračních značek.

Abstract

This thesis describes the design and development of a system for detection and recognition of license plates. The work is divided into three basic parts: licence plates detection, finding of character positions and optical character recognition. To fulfill the goal of this work, a new dataset was taken. It contains 2814 license plates used for training classifiers and 2620 plates to evaluate the success rate of the system. Cascade Classifier was used to train detector of licence plates, which has success rate up to 97.8 %. After that, positions of individual characters were searched in detected positions of licence plates. If there was no character found, detected position was not the licence plate. Success rate of licence plates detection with all the characters found is up to 88.5 %. Character recognition is performed by SVM classifier. The system detects successfully with no errors up to 97.7 % of all licence plates.

Klíčová slova

Detekce registračních značek vozidel, Optické rozpoznání znaků, Česká registrační značka vozidla, Kaskádový klasifikátor, Lineární klasifikátor SVM, MSER, Zpracování obrazu, Počítačové vidění

Keywords

Licence plate detection, Optical Character Recognition, Czech Licence plate, Cascade classifier, Linear classifier SVM, MSER, Image Processing, Computer Vision

Citace

Tereza Černá: Detekce a rozpoznání registrační značky vozidla pro analýzu dopravy, diplomová práce, Brno, FIT VUT v Brně, 2015

Detekce a rozpoznání registrační značky vozidla pro analýzu dopravy

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně, s použitím uvedených zdrojů, pod vedením pana Doc. Ing. Adama Herouta, Ph. D.

.....
Tereza Černá
26. května 2015

Poděkování

Ráda bych poděkovala svému vedoucímu práce Doc. Ing. Adamu Heroutovi, Ph.D. za jeho cenné rady, přátelský přístup a odborné vedení diplomové práce. Mé poděkování patří také Ing. Michalu Hradišovi, Ph.D. a Ing. Romanu Juránkovi, Ph.D. za poskytnuté konzultace týkající se použití kaskádového klasifikátoru. Dále bych chtěla poděkovat svým rodičům a blízkým, kteří mi vytvořili potřebné zázemí po celou dobu mého studia.

© Tereza Černá, 2015.

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	3
2	Existující přístupy k detekci a rozpoznání znaků registrační značky	4
2.1	Analýza dopravy ze záběrů stacionárních kamer	4
2.2	Metody detekce registračních značek	7
2.3	Metody klasifikace znaků	12
2.4	Vlastnosti českých registračních značek	15
3	Použité algoritmy počítačového vidění	17
3.1	Kaskádový klasifikátor	17
3.2	Klasifikátor SVM	21
3.3	Detektor MSER	22
4	Nově vytvořená datová sada	24
4.1	Sběr dat	24
4.2	Datová sada pro trénování detektoru registračních značek	26
4.3	Datová sada pro trénování klasifikátoru znaků	27
5	Návrh řešení systému	29
5.1	Analýza problému	29
5.2	Návrh systému	30
6	Pomocné aplikace vytvořené pro tento systém	38
6.1	Příprava dat pro trénování detektoru registračních značek	40
6.2	Příprava datové sady znaků	43
6.3	Tvorba anotací testovací datové sady	43
6.4	Aplikace pro vyhodnocení úspěšnosti	44
7	Implementace systému a provedené experimenty	46
7.1	Trénování detektoru registračních značek	46
7.2	Trénování lineárního klasifikátoru SVM pro rozpoznání znaků	47
7.3	Výsledný systém detekce a rozpoznání registrační značky vozidla	48
7.4	Experimentální vyhodnocení detektoru registračních značek	49
7.5	Experimentální vyhodnocení detekce registračních značek po odstranění falešných detekcí	51
7.6	Experimentální vyhodnocení klasifikace znaků	52
7.7	Experimentální vyhodnocení rozpoznání registračních značek	53
8	Závěr	58

A Seznam použitých zkratek	62
B Obsah DVD	63

Kapitola 1

Úvod

Detekce registračních značek vozidel se v dnešní době používá v mnoha oblastech kontroly dopravy. Takový systém je možné použít pro bezpečnostní kontroly, sledování provozu, získávání statistik, automatické platby mýtného nebo poplatku za parkování, aj.

Většina stávajících detekčních algoritmů má vynikající výsledky pouze za určitých podmínek. Omezení se často vztahují na kvalitu snímaného obrazu kamerou, která závisí na jasu a kontrastu. Některé algoritmy vyžadují čisté pozadí, vysoké rozlišení a dobrou kvalitu poznávací značky. Nicméně algoritmy detekující dopravní značky by měly brát v potaz různé faktory, které mohou ovlivnit přesnost detekce. Těmi jsou například šum na pozadí, špatná kvalita obrazu vlivem pohybu auta nebo špatných povětrnostních podmínek při snímání, nerovnoměrné osvětlení i různé velikosti značek a jejich natočení.

Cílem této diplomové práce bylo seznámit se s možnostmi analýzy dopravy ze záběrů ze stacionárních kamer a prostudovat problematiku detekce a rozpoznání registračních značek vozidel. V rámci práce měl být navržen algoritmus detekce a rozpoznání značek při znalosti úběžníků pohybu vozidel. Znalost úběžníků se ukázala pro navržený systém nepotřebná, proto nebyla v práci nakonec zahrnuta a bylo implementováno obecné řešení bez znalosti úběžníků. Pro potřeby práce, vývoj a vyhodnocení, byla pořízena nová datová sada snímků z dopravy. V závěru práce bylo provedeno vyhodnocení vytvořeného řešení, zhodnoceny dosažené výsledky a navrženo budoucí pokračování práce.

Práce je rozdělena do osmi kapitol. Po úvodu následuje kapitola 2, kde jsou probrány některé existující přístupy analýzy dopravy ze záběrů stacionárních kamer, detekce a rozpoznání registračních značek vozidel a specifika české státní poznávací značky. V 3. kapitole jsou popsány některé oblasti z problematiky počítačového vidění a strojového učení, které byly využity při tvorbě systému. V následující 4. kapitole je popsán proces pořízení nové datové sady a její úprava pro použití v navrženém systému. V kapitole 5 je rozebrána analýza problému detekce a rozpoznání registrační značky vozidla a dále jsou popsány jednotlivé kroky navrženého řešení. Obsahem další kapitoly je popis pomocných aplikací pro vytvoření datových sad, tvorbu anotací testovacích snímků a vyhodnocení úspěšnosti systému. Následující 7. kapitola obsahuje popis implementace navrženého systému a provedené experimenty při vyhodnocení úspěšnosti. V závěrečné kapitole jsou shrnuty dosažené výsledky aplikace a možnosti budoucí práce.

S touto prací jsem se zúčastnila Studentské konference inovací, technologií a vědy v IT Excel@FIT 2015 a vystoupila s ní na veřejné prezentaci. Práce byla ohodnocena 4. místem v kategorii Inovační potenciál.

Kapitola 2

Existující přístupy k detekci a rozpoznání znaků registrační značky

Tato kapitola pojednává o analýze dopravy ze záběrů stacionárních kamer, existujících přístupech k detekci a rozpoznání znaků registrační značky. Jednotlivé metody jsou zde ve zkratce představeny. V závěru kapitoly jsou popsána specifika české registrační značky.

2.1 Analýza dopravy ze záběrů stacionárních kamer

Automatické dohledové systémy jsou užitečné pro organizaci dopravy – sběr statistických údajů, okamžité ovládání dopravních signálů apod. Existuje mnoho metod zabývajících se tímto tématem. Některé metody vyžadují zásah uživatele ve formě zadání informací o pruzích vozovky, šířce mezi pruhy, průměrné velikosti a rychlosti auta, pozici kamery aj. Společným rysem mnoha metod je detekce úběžníků odpovídající směru pohybu vozidla. Tato sekce popisuje dvě zajímavé metody analýzy dopravy.

2.1.1 Kalibrace kamery založená na detekci jízdních pruhů

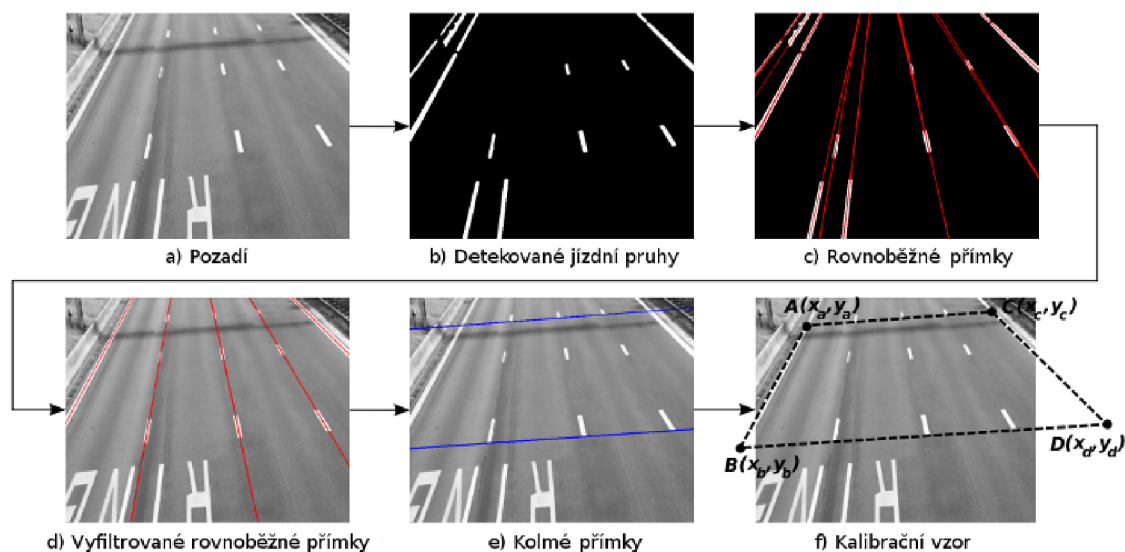
Metodu kalibrace kamery založené na detekci jízdních pruhů zveřejnili ve své práci Diaz a spol. [5]. Kalibrační model je založen na silničním značení jízdních pruhů. Pro dobré výsledky metody je nutné mít obraz dobré kvality. Ideální snímek obsahuje pouze pozadí scény, tj. vozovku, jízdní pruhy a blízké okolí silnice (chodníky, tráva aj.). Tato metoda umí získat snímek pozadí za použití filtru $\Sigma - \Delta$. Jedná se o nelineární metodu odčítání pozadí [13]. Snímek pozadí je spočítán z časové a místní mapy aktivit.

Základním předpokladem je, že jízdní pruhy jsou téměř rovnoměrné a k sobě se přibližující rovné čáry. Pro detekci jízdních pruhů je nad snímkem pozadí provedena binarizace. Následně jsou měřeny některé vlastnosti tvaru nalezených bílých komponent binárního obrazu jako je povrch, šířka, výška, těžiště aj. Mnoho komponent je vyřazeno, nesplňují-li požadované vlastnosti. Ostatní jsou považovány za pruhy jízdního značení (viz obr. 2.1b).


Následně je pro každou ponechanou komponentu nalezena přímka procházející těžištěm, a která má stejnou orientaci jako příslušný objekt (viz obr. 2.1c). Tyto rovnoběžné přímky jsou filtrovány a jsou získány výsledné přímky odpovídající reálnému silničnímu značení. Nejdříve jsou slučovány přímky, jejichž těžiště a orientace jsou blízko u sebe. Dále je zkou-

máno, zda se na přímkách nachází jasné objekty (jízdní pruhy). Pokud je těchto jasných objektů málo, pak je přímka odstraněna. Posledním krokem nalezení jízdních pruhů je kontrola vzdáleností mezi sousedními přímkami. Na základě přímek označujících rovnoběžné jízdní pruhy lze najít kolmé přímky.

Po detekci jízdních pruhů a všech přímek jsou nalezeny průniky rovnoběžných a kolmých přímek a jsou získány čtyři body. Tyto body tvoří rovnoběžník, který je použit jako vzor pro kalibraci kamery (viz obr. 2.1f). Následně vstupní snímek na základě kalibračního vzoru transformován do roviny. Tato projekce je zobrazena na obrázku 2.2. Z obrazu zkalibrované kamery lze získávat informace o rychlosti vozidel, jejich velikosti aj.



Obrázek 2.1: Ukázka jednotlivých kroků metody kalibrace kamery na základě detekce jízdních pruhů. Převzato z [5].



Obrázek 2.2: Projekce obrazu na základě kalibračního vzoru. Převzato z [5].


2.1.2 Automatická kalibrace kamery a sledování vozidel

Systém pro automatickou kalibraci kamery a analýzu dopravy publikovala Markéta Dubská a spol. [7]. Metoda umožňuje automatickou kalibraci kamery stanovením tří úběžníků, které definují proud vozidel. Jednotlivá vozidla jsou poté uzavřena do 3D ohraničujících boxů.


Pro detekci prvního úběžníku jsou nalezeny příznaky, které jsou sledovány i v následujícím snímku videa. Body, které byly úspěšně sledovány a vykazovaly výrazný pohyb, jsou považovány za lineární fragmenty trajektorií vozidel. Následně jsou všechny sledované body posuzovány v diamantovém prostoru akumulátoru [8] a nejvíce odpovídající bod je považován za první úběžník. Druhý úběžník odpovídá směru rovnoběžném s povrchem vozovky, který je kolmý ke směru prvního úběžníku. Opět je použita technika diamantového prostoru pro jeho přesnou detekci. Na základě obou nalezených úběžníků lze určit třetí úběžník, který je k oběma existujícím kolmý. Model obsahující hrany pozadí je použit pro nalezení hran hýbajících se objektů – pravděpodobných vozidel.

Dalším krokem systému je tvorba 3D ohraničujících boxů okolo sledovaných vozidel. Siluety vozidel je možné extrahovat modelováním pozadí a detekcí popředí. Tento přístup je založen na pozorování, že pohybující se vozidla mají některé hrany velmi stabilní a neměnné. Na obrázku 2.3 je zobrazena konstrukce 3D ohraničujícího boxu. Z úběžníků jsou získány tečny vozidla, ze kterých jsou odvozeny další tečny a výsledně je získán 3D box ohraničující vozidlo.

Použití výsledného systému je zobrazeno na obrázku 2.4, kde jsou ukázány také nalezené úběžníky a ohraničující 3D boxy vozidel. Ze získaných informací je možné určit rychlost pohybujícího se vozidla a jeho rozměry. Dále mohou probíhat analýzy hustoty provozu aj.



Obrázek 2.3: Konstrukce 3D ohraničujícího boxu vozidla. (I) Tečny a jejich průsečíky A, B, C. (II) Odvozené tečny a jejich průsečíky D, E, F. (III) Další odvozené tečny a jejich průsečíky G, H. (IV) Zkonstruovaný 3D box vozidla. Převzato z [7].



Obrázek 2.4: Automatické nalezení úběžníků a konstrukce 3D ohraničujících boxů (vlevo). Automatické určení měřítka kamery ze získaných statistik rozměrů vozidel, které slouží např. pro určení rozměrů a rychlosti vozidel (uprostřed) a analýzu hustoty provozu (vpravo). Převzato z [7].

2.2 Metody detekce registračních značek

Existuje mnoho rozličných metod pro detekci registračních značek. Detekce značek může být provedena na základě porovnání částí obrazu se šablonou, pomocí detekce MSER regionů, detekce hran za použití vlnkové transformace nebo fuzzy logiky, kombinace Houghovy transformace a analýzy kontur. Jiné metody jsou založeny na komponentách a konstruují podmíněná náhodná pole nebo extrahují příznaky SIFT. V následujících podsekcích jsou tyto metody ve zkratce představeny.

2.2.1 Detekce založená na analýze barev

Metodu detekce íránských značek založenou na analýze barev pixelů a matematickém přizpůsobení šablony publikovali Ashtari a kol. [3]. S drobnou modifikací je tato metoda použitelná i pro nový standard evropských registračních značek obsahující modrý pruh v levé části značky.

Tento přístup prohledává originální obraz pixel po pixelu a hledá modrý obdélník nacházející se v levé části registrační značky. Na obrázku 2.5 je vidět, že modrý pruh íránské značky obsahuje v horní části barevnou vlajku státu. Na základě těchto informací je vstupní snímek prohledáván postupně shora dolů, pokud index narazí na modré pixely, následně na zelený, bílý a červený pruh pixelů o stejné velikosti a nakonec opět na modrý pruh $11 \times$ delší než modrý pruh pixelů na začátku, pak je toto místo považováno za kandidátní místo registrační značky. Šablona íránské značky je natolik specifická, že zřídka jsou nalezeny kandidátní místa, které označují jiné objekty. Na základě poměrů hran ve značce je nalezena hlavní část registrační značky obsahující samotnou identifikaci vozidla.

Mezi hlavní výhody této metody patří detekce minima kandidátních ploch, schopnost rozeznat více registračních značek v obraze, nezávislost na různých velikostech značky a detekce všech typů značek nezávisle na barvě jejich pozadí.



Obrázek 2.5: Standardní poměry v modrém obdélníku íránské značky. Převzato z [3].

2.2.2 Lokalizace registračních značek pomocí MSER detektoru

Tato metoda detekce, kterou publikovali Wang a kol. [22], je založena na detekci MSER regionů (více v kapitole 3.3) a redukci oblastí na základě základních vlastností registračních značek. Metoda využívá toho, že registrační značky jsou složeny z barev pozadí a popředí, které mají velký kontrast, např. černá nebo modrá na bílém pozadí, černá na žlutém pozadí aj.

Vstupní snímek dopravy je převeden do šedotónového obrázku a je zpracován metodou *gray stretching*, jejíž cílem je odstranit hrany o nízkém rozdílu jasu. Nad upraveným snímkem je provedena detekce MSER regionů (viz obrázek 2.6). Některé regiony jsou rozděleny do menších regionů pomocí morfologického otevření. Poté proběhne vyřazení nevhodných regionů MSER podle následujících pravidel:


- Rozdíl jasu mezi popředím a pozadím registrační značky se pohybuje v určitém rozsahu a lze odstranit MSER regiony, kde je jasový rozdíl mezi popředím a pozadím menší než je stanovený minimální rozdíl.

- Kamera je v prostředí dopravy umístěna fixně a snímané registrační značky se mohou objevovat pouze v rozsahu o určité velikosti. V důsledku toho, lze odstranit MSER regiony, které nesplňují požadavek na velikost značky.
- Poměr šířky a výšky registrační značky se pohybuje v určitém rozsahu hodnot. Není-li tento poměr splněn, MSER region je odstraněn z posuzování.



Obrázek 2.6: Detekce MSER regionů. Vlevo jsou zakresleny MSER regiony do vstupního snímku. Vpravo jsou regiony zakresleny do binárního obrazu. Převzato z [22].

Horizontální pozice značky lze získat na základě počtu bílých pixelů a frekvence černo-bílých přechodů na řádku binárního obrazu. Tím se vytipují místa, kde by se mohla registrační značka nacházet. Na obrázku 2.7 je zobrazen postup horizontální lokalizace. Ze získané horizontální projekce byla získána finální poloha registrační značky pomocí vertikální projekce.



Obrázek 2.7: Ukázka kroků horizontální lokalizace. Převzato z [22].

2.2.3 Detekce značky za použití fuzzy logiky

Metodu založenou na fuzzy logice představili Nijhuis a kol.[18]. Tato metoda je postavena na fuzzy pravidlech:

- Registrační značka je žlutý obdélník na autě, který obsahuje černé znaky.
- Registrační značka je většinou umístěna ve spodní části auta, a to vepředu i vzadu.

Kandidátní oblasti dané prvním pravidlem jsou získány za použití metod založených na histogramu. Nejdříve jsou analyzovány hodnoty RGB z ručně vytažených registračních značek a je sestavena tabulka výskytů. Pro každou hodnotu RGB je udán počet jejího výskytu na analyzované značce. Při hledání kandidátních míst v originálním obrázku je poté použita tato tabulka výskytů. Textura pixelu je zjištěna na základě jasových hodnot jeho osmiokolí.

Segmentace je prováděna fuzzy c-means klastrovacím algoritmem, kde žádoucí počet klastrů jsou 2, a to zda se jedná o registrační značku či nikoliv. Algoritmus preferuje klastry, které mají obdélníkový tvar se správným poměrem stran.

Následující krok segmentace klastrů zahrnuje vytažení samostatných znaků z registrační značky. Nejdříve je provedena binarizace obrazu na základně optimalizované hodnoty jasu. V binárním obraze jsou vyhledány všechny komponenty a je zkontrolována jejich minimální velikost, šířka a výška znaku. Pokud počet nalezených komponent odpovídá počtu znaků registrační značky, pak je tento klaster označen za registrační značku.

2.2.4 Metody založené na detekci hran

Mezi další možné metody detekce registračních značek patří detekce pomocí detekce hran. V této podsekcí jsou popsány dva podobné přístupy, které se odlišují metodou detekce hran. Oba přístupy pracují nad snímkem v odstínech šedi a jsou závislé na kvalitě osvětlení scény.

První metodu publikovali Musoromy a kol. [16] a je založena na detekci hran pomocí obrazových filtrů. Na základě hodnot jasu ve vstupním snímku je určen optimální práh. Následně je provedena detekce hran pomocí Sobelova, Kirschova, Laplaceova, Cannyho, Rothwellova a SUSAN filtru. Následně je zjištěna úspěšnost filtrů a je použit nejlepší z nich. V dalším kroku je provedena horizontální a vertikální projekce a v nalezených místech je provedena kontrola shody hodnoty jasu u znaku a pozadí. Místa s největší odezvou jsou považována za registrační značku.

Druhý přístup je od stejných autorů [15] a pro detekci hran používá Haarovu vlnkovou transformaci. Zbytek algoritmu je stejný.

2.2.5 Detekce založená na komponentách s podmíněným náhodným polem

Tato metoda, kterou publikovali Li a kol. [12], je založena na modelování komponent pro detekci objektů. Modely založené na komponentách využívají především informace o kontextu mezi jednotlivými částmi a berou v úvahu informace o struktuře a vzhledu objektu.


Potenciální znaky registrační značky jsou regiony se srovnatelnými hodnotami intenzity. Tyto potenciální oblasti jsou získány pomocí detektoru MSER (více v kapitole 3.3). Všechny získané oblasti jsou filtrovány na základě geometrických omezení jako je výška, šířka, jejich poměr a plocha. Oblasti, které projdou těmito filtry, jsou považovány za kandidátní znaky registrační značky a použijí se jako uzly pro výstavbu podmíněného náhodného pole (dále jen CRF, Conditional Random Field). Výsledky detekce kandidátních znaků je zobrazena na obrázku 2.8 a). Je vidět, že většina znaků registrační značky je extrahováno, nicméně je nalezeno množství znaků, které náleží do pozadí obrazu.

Při konstrukci CRF jsou hledány sady kandidátských znaků s podobným uspořádáním znaků. Pro každý kandidátní znak jsou prozkoumáni všichni ostatní kandidáti, zda nejsou jeho pravým sousedem. Pokud ano, pak vytvoří dvojici kandidátních znaků. Množina sousedících znaků je propojena do velkého sousedství. Obsahuje-li toto sousedství nejméně

4 znaky, pak je považováno za registrační značku aut, zbylé znaky jsou vyřazeny z posuzování. Každý konkrétní CRF je postaven z jednoho velkého sousedství a všechny kandidátní znaky představují uzly CRF.

Přidáním vazeb mezi uzly je vytvořena struktura CRF a sestaven graf se stromovou strukturou. Euklidovská vzdálenost mezi dvěma uzly je určena vahou jejich spojující hrany. Kostra s nejmenším součtem vah se uloží jako struktura CRF. Výsledky konstrukce CRF jsou znázorněny na obrázku 2.8 b). Většina kandidátních oblastí na pozadí byla úspěšně odstraněna.

Výsledky detekce jsou zobrazeny na obrázku 2.8 c) zeleným rámečkem. Je vidět, že všechny jasně viditelné poznávací značky byly úspěšně detekovány. Pokud některý znak nebyl zvolen uzlem CRF, jeho pozice bude odhadnuta podle standardního rozložení znaků na značce. Odhadnuté znaky jsou na obrázku 2.8 d) zobrazeny obalujícím boxem označeným červenou přerušovanou čarou. Tento obrázek zobrazuje detail na detekované MSER regiony a uzly CRF.




Obrázek 2.8: Ukázka detekce registrační značky: Detekce kandidátních oblastí (a). Konstrukce CRF (b). Výsledek detekce registrační značky (c). Přibližovaná registrační značka (d). Kandidátní znaky jsou označeny červenými a modrými obdélníky. Žluté tečky a čáry označují uzly a vazby na CRF. Zelený obdélník obaluje nalezenou registrační značku. Převzato z [12].

2.2.6 Metoda kombinující Houghovu transformaci a detekci kontur

Dalším přístupem k detekci registračních značek je metoda kombinující Houghovu transformaci a detekci kontur, kterou publikovali Tran Duc Duan a kol. [6].

Vstupní obraz je převeden do odstínů šedi a dojde v něm k vyrovnání kontrastu. Na upravený snímek je aplikován Sobelův hranový detektor a jeho výsledek je zobrazen do binárního obrazu. Následně je použit algoritmus detekce kontur pro nalezení uzavřených objektů. V obraze s konturami jsou vyhledány dvojice rovnoběžných přímek. Pokud prostor ohraničený těmito přímkami odpovídá poměru šířky a výšky značky, pak je prohlášen za registrační značku. Nicméně touto metodou mohou být nalezeny i jiné objekty jako jsou skla, světla aj. Mezi další nevýhody této metody patří větší časová náročnost výpočtu Houghovy transformace. Na obrázku 2.9 je zobrazen výsledek správné i špatné funkcionality metody.



(a) Ukázka dobré detekce registrační značky.



(b) Ukázka špatné detekce, kdy jsou za registrační značky považována i světla vozidla.

Obrázek 2.9: Ukázka funkcionality metody založené na Houghově transformaci a detekci kontur. Převzato z [6].


2.2.7 Detekce založená na extrakci SIFT příznaků

Metodu založenou na extrakci SIFT příznaků publikovali Wengang Zhou a kol. [23]. Celý systém se skládá ze tří klíčových komponent – vytvoření popisu každého znaku registrační značky (dále jen PVW, Principal Visual Word), spojování příznaků s nadefinovanými PVW a lokalizace registrační značky.


Tento přístup používá extrakci SIFT příznaků, jejichž výhodou je neměnné chování vzhledem k osvětlení scény snímku, různým transformacím obrazu, velikosti i rotaci registrační značky. Je shromážděno množství trénovacích dat, které obsahují anotace o registračních značkách a pro každý znak značky jsou extrahovány SIFT příznaky. Pro každý znak jsou všechny jeho příznaky porovnány a je nalezena průměrná podoba všech vzorků, která udává jednoznačný popis PVW daného znaku (viz obrázek 2.10).

Samotná detekce registrační značky je založena na vyhledání všech SIFT příznaků ve vstupním snímku a každý příznak je porovnáván s PVW všech natrénovaných znaků. Příznak je považován za kandidáta pokud je minimální vzdálenost deskriptoru k PVW daného znaku menší než stanovená hraniční hodnota.

Jakmile jsou identifikovány příznaky v testovacím snímku, které odpovídají nadefinovaných PVW popisům, lze využít geometrických souvislostí mezi jednotlivými znaky registrační značky pro její nalezení. Samotnou značku tvoří pouze ty příznaky, které leží blízko u sebe a mají stejnou rotaci i velikost jako jejich sousední příznaky. Ze získaných příznaků lze lehce zjistit výška potenciální registrační značky, ze které lze pak odhadnout také její šířku. Finální značku tvoří jen ty příznaky, které lze uzavřít do jejich stanovených rozměrů. Na obrázku 2.11 je znázorněn postup při vyhledání registrační značky ve vstupním snímku. Pomocí této metody lze lehce rozpoznat i samotné znaky registrační značky.



Obrázek 2.10: Ukázka SIFT příznaků. Převzato z [23].



(a) Nalezené SIFT příznaky označeny červenými šipkami.

(b) Identifikace příznaků znaků. Zakresleny žlutě.

(c) Detekce horní a dolní hranice příznaků.

(d) Detekovaná registrační značka uzavřená do červeného obdélníku.

Obrázek 2.11: Ukázka nalezení registrační značky pomocí extrakce SIFT příznaků. Převzato z [23].

2.3 Metody klasifikace znaků

Existuje mnoho metod řešících rozpoznání znaků. Registrační značky obsahují jednotné písmo, což dělá úkol rozpoznání jednodušší. V této sekci jsou představeny některé metody klasifikace znaků, které jsou přiměřeně jednoduché a dostačující pro řešený problém. Jsou zde popsány metody založené na porovnání s předdefinovanými šablonami, trénující SVM klasifikátor a neuronové sítě.

2.3.1 Porovnání znaků s předdefinovanými šablonami

Metodu porovnání znaků s předdefinovanými šablonami publikoval Petr Cíka a kol. [4]. Tato metoda se skládá ze dvou hlavních částí – porovnání s předdefinovanou šablonou a analýza regionu symbolu.

Vstupním předpokladem této metody je izolovaný znak registrační značky, který je upraven na stejnou velikost jako předdefinované šablony. Předdefinovaný model je složen z obrázků všech znaků registrační značky o jednotné velikosti. Podobnost porovnávaného symbolu je určena pomocí normalizované křížové korelace (dále jen NCC, Normalized Cross Correlation):


$$NCC = \frac{\sum_{i=0}^{I-1} \sum_{j=0}^{J-1} O_{i,j} E_{i,j}}{\sum_{i=0}^{I-1} \sum_{j=0}^{J-1} O_{i,j}^2}, \quad (2.1)$$

kde I, J definuje velikost obrázku aktuálního symbolu a O, E určuje originální a aktuální symbol.


Hlavní myšlenkou je rozdělení aktuálního symbolu do šestnácti regionů (viz obrázek 2.13). Každý region je porovnán s odpovídajícím regionem šablon technikou charakteristických vektorů. Charakteristický vektor bílých pixelů je vypočítán pro každou šablonu a uložen do databáze. Samotné porovnání poté probíhá s předdefinovanými šablonami, což urychluje zpracování. Poté, co je vypočítán vektor bílých pixelů, následuje určení vektoru vzdálenosti pro každou šablonu z databáze, který je spočítán takto:

$$D = \sqrt{\sum_{i=0}^N (V_{P_i} - V_{A_i})}, \quad (2.2)$$

kde D je vektor vzdálenosti, N je počet regionů, V_{P_i} je počet šablon v regionu a V_{A_i} je počet bílých pixelů v regionu aktuálně analyzovaném symbolu.



Obrázek 2.12: Předdefinované normalizované šablony. Převzato z [4].



Obrázek 2.13: Rozdělení symbolu do regionů. Převzato z [4].

2.3.2 Trénování SVM klasifikátorů pro rozpoznání znaků


Tento přístup publikoval Lukáš Neumann v rámci své diplomové práce na ČVUT v Praze [17]. Jeho práce se zabývá rozpoznáním textu ve vstupní scéně.

Ve vstupním snímku jsou pomocí detektoru MSER (více v kapitole 3.3) nalezeny potenciální oblasti textu. Pro každou nalezenou oblast je rozhodnuto zda se jedná o znak či nikoliv. Pro toto rozhodnutí je natrénován SVM klasifikátor (více v sekci 3.2), jehož příznaky jsou složeny z následujících informací:

- poměr výšky k šířce,
- relativní výška,
- kompaktnost,
- poměr plochy konvexní obálky k ploše oblasti
- rozptyl barev vyříznutého obrazu,
- barevná konzistence znaku,
- barevná konzistence okolí znaku,
- barevný odstup mezi znakem a jeho pozadím,
- relativní velikost kostry a
- počet děr.

Velikost každé MSER oblasti označené natrénovaným detektorem za znak je upravena na velikost 35×35 pixelů a převedena do binárního obrazu. Na těchto bitmapách jsou měřeny 2 sady příznaků.

První sadu příznaků tvoří hodnoty získané na základě 8-směrového chain-code obvodových pixelů znaku. Pro každý směr je vytvořena jedna bitmapa o velikosti masky. Aby byl výsledný detektor robustnější vůči šumu, jsou všechny získané bitmapy vzorkovány Gaussovou konvoluční maskou o velikosti 5×5 pixelů. Celkem bylo získáno 8 bitmap, jejichž hodnoty jsou uloženy za sebe do jednoho vektoru.




Obrázek 2.14: Příznaky založené na chain-code znaku: Vstupní znak s červeně vyznačenými hraničními pixely (a). Bitmapy všech osmi směrů konvulované s Gaussovou maskou 5×5 pixelů (b)-(i). Převzato z [17].

Druhá sada příznaků je složena z informací získatelných z bitmapy:

- vzdálenost prvního pixelu od levého okraje,
- vzdálenost posledního pixelu od pravého okraje,
- počet přechodů černá/bílá.

Získané hodnoty jsou vzorkovány jednorozměrnou Gaussovou maskou o velikosti 3 pixely.



Obrázek 2.15: Ukázka druhé sady příznaků: Vstupní znak (a). Vzdálenost prvního pixelu od levého okraje (b). Vzdálenost posledního pixelu od pravého okraje (c). Počet přechodů černá/bílá (d). Převzato z [17].

Ná základě těchto příznaků byly natrénovány SVM klasifikátory pro každou dvojici tříd. Při výsledném rozpoznání byl vektor příznaků vyhodnocen všemi klasifikátory a třída s nejvyšší hodnotou pravděpodobnosti byla zvolena za výstup klasifikátoru.

2.3.3 Klasifikace znaků pomocí neuronových sítí

Metodu klasifikace znaků za použití neuronových sítí publikovali Nijhuis a kol. [18]. Vstupem jsou binární výřezy znaků registrační značky. V této metodě jsou použity dva rozdílné typy neuronových sítí pro rozpoznání znaků. Klasifikace je provedena na základě informací formou příznaků.

Prostřednictvím DTCNN neuronové sítě (Discrete-Time Cellular Neural Networks) byly generovány čtyři různé typy příznaků:

- horizontální projekce,
- vertikální projekce,
- počet horizontálně propojených komponent a
- počet vertikálně propojených komponent.

Pro každý typ příznaků byla vytvořena neuronová síť, jejímž vstupem byly binární obrázky znaků o výšce 15 px a k ní přímo úměrné šířce.

Každý z těchto příznaků je transformován do pěti vstupů MLPNN neuronové sítě. Výsledná síť byla natrénována na 24 vstupních, 15 skrytých a 36 výstupních neuronech, kde každý výstup odpovídá jednomu znaku registrační značky. Rozpoznávaný znak je určen, pokud hodnota na odpovídajícího výstupu přesahuje 0,85 a všechny ostatní výstupní neurony mají hodnotu pod 0,25.

2.4 Vlastnosti českých registračních značek

V České republice platí několik typů registračních značek. Všechny typy a jejich podoby jsou specifikovány ve vyhlášce Ministerstva dopravy 243/2001 Sb. [2]. Nejvíce rozšířeny jsou značky motorových vozidel typu 101 (viz obrázek 2.16). Tento typ má rozměry 520 mm x 110 mm a obsahuje 7 černých znaků na bílém poli.



Obrázek 2.16: Registrační značka typu 101

Na obrázku 2.17¹ jsou zobrazeny typy registračních značek od roku 1994. Starší typ značky obsahoval na prvních dvou pozicích zkratku okresu, kde bylo vozidlo registrováno. Třetí znak je libovolný znak povolené abecedy. Zbývající čtyři znaky jsou číslice. V roce 2001 vyšla v platnost nová podoba registrační značky, která na druhé pozici obsahuje písmeno kraje (viz tabulku 2.1), kde je vozidlo registrováno. Na první a třetí pozici se mohou vyskytovat písmena i číslice. Na posledních čtyřech pozicích se mohou vyskytovat pouze číslice. Roku 2004 přibyl v levé části značky modrý pruh znázorňující členství v Evropské Unii.

Registrační značky mohou obsahovat všechny číslice od 0 do 9. Omezena jsou některá písmena kvůli podobnosti, např. číslice 0 a písmeno O. Povolené znaky abecedy jsou A, B, C, D, E, I, J, K, L, M, N, P, R, S, T, U, V, X, Y, Z.

¹Obrázek převzat z webu o českých registračních značkách. Dostupné z odkazu: http://www.3260.cz/typy_poznavacich_znacek.htm

Znak	Kraj	Sídlo	Znak	Kraj	Sídlo
A	Hl. m. Praha	Praha	L	Liberecký	Liberec
B	Jihomoravský	Brno	M	Olomoucký	Olomouc
C	Jihočeský	České Budějovice	P	Plzeňský	Plzeň
E	Pardubický	Pardubice	S	Středočeský	Praha
H	Královéhradecký	Hradec Králové	T	Moravskoslezský	Ostrava
J	Vysočina	Jihlava	U	Ústecký	Ústí nad Labem
K	Karlovarský	Karlovy Vary	Z	Zlínský	Zlín

Tabulka 2.1: Výpis znaků na druhé pozici nového typu registrační značky

Párové značky /v cm, číselné označení/					
vzor	Osobní automobily			Nákladní	
	2× 52×11	2× 28×20	52×11, 28×20	52×11, 34×20	
	101	105	106	103	
2004					
2001					
Osobní 94					
Nákladní 94					

Obrázek 2.17: Podoby registračních značek od roku 1994.

Kapitola 3

Použité algoritmy počítačového vidění

Pro detekci a rozpoznání registračních značek vozidel se často používají algoritmy strojového učení. V této práci byl použit kaskádový klasifikátor a lineární klasifikátor SVM pro vytvoření detektorů registračních značek a pro úlohu optického rozpoznání znaků. Dále byl použit detektor MSER regionů pro tvorbu jednoduchého detektoru značek a nalezení pozic písmen v registrační značce. V této kapitole jsou popsány všechny tři metody počítačového vidění.

3.1 Kaskádový klasifikátor

Kaskádový klasifikátor obsahuje algoritmy pro robustní a rychlou detekci objektů v obraze. Tento přístup publikovali Viola a Jones [21] na příkladu detekce obličeje, ale lze jej použít i pro jiné objekty. Použití kaskádového klasifikátoru poskytuje velkou snímkovou rychlost.

V této práci byly použity tři hlavní nosné myšlenky. První myšlenkou je nová reprezentace obrazu zvaná integrální obraz, která umožňuje velmi rychlé vyhodnocení funkce. Systém detekce nepracuje přímo s obrazovou intenzitou, místo toho je použita sada rysů, které připomínají Haarovy příznaky. Aby bylo možné spočítat tyto příznaky velmi rychle pro mnoho úrovní, byla zavedena integrální reprezentace obrazu.

Druhým přínosem je metoda konstrukce klasifikátoru výběrem malého množství důležitých rysů algoritmu AdaBoost. Uvnitř každého podokna obrazu je celkový počet Haarových příznaků velmi velký, mnohem větší než počet pixelů. V zájmu zajištění rychlé klasifikace musí proces učení vyloučit velkou většinu možných objektů a zaměřit se na malý soubor zásadních rysů. Výběr správné funkce je dosažen jednoduchou úpravou algoritmu AdaBoost: slabý klasifikátor může záviset pouze na jednom ryse. Za výsledek každé etapy procesu posilování klasifikátoru, který zvolí nový slabý klasifikátor, lze považovat selektivní funkci procesu. AdaBoost poskytuje efektivní učící algoritmus a silné hranice při zobecnění výkonu.

Třetím přínosem je způsob kombinování postupně složitějších klasifikátorů v kaskádové struktuře, která výrazně zvyšuje rychlost detektoru zaměřením pozornosti na slibné oblasti obrazu. Často lze velmi rychle určit, kde by se mohl hledaný objekt v obraze nacházet. Komplexní zpracování pak probíhá nad těmito potenciálními plochami. Klíčovým opatřením takového přístupu je měření míry false negative nad zkoumaným procesem.

Trénování klasifikátoru probíhá „pod dohledem“, což odkazuje na skutečnost, že pozor-

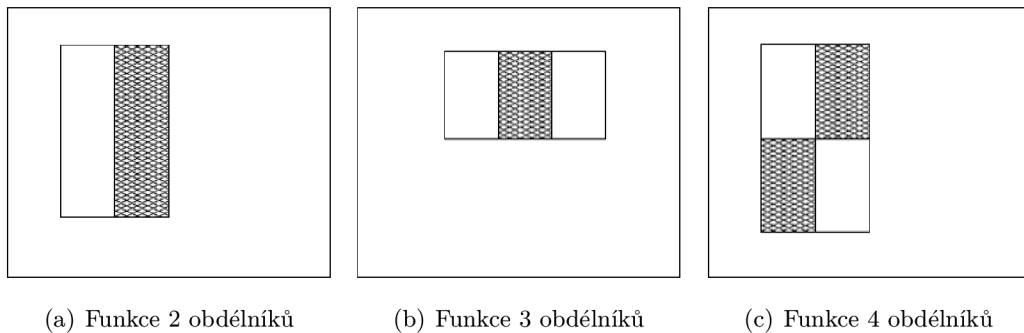
nost operátoru je trénována k detekci příkladů určité třídy. Použitím klasifikátoru vyrobeného ze dvou Haarových příznaků lze dosáhnout méně než 1 % false negatives a 40 % false positives. Tento filtr redukuje o více než polovinu počet potenciálních míst, na kterých bude finální klasifikátor hodnotit.

Potenciální oblasti, které nebyly vyřazeny iniciálním klasifikátorem, jsou zpracovávány sledem klasifikátorů, kde každý další je o trochu složitější než ten před ním. Pokud některý klasifikátor odmítne potenciální oblast, pak se již žádné další zpracování nad touto oblastí neprovádí. Struktura kaskádové detekce je generování rozhodovacího stromu.

Hlavní rysy

Tento postup detekce objektů třídí snímky na základě hodnot jednoduchých rysů obrazu. Existuje mnoho důvodů pro využití různých poznatků získatelných z obrazu, než jen práce s hodnotami pixelů. Nejčastějším důvodem je, že rysy mohou sloužit k zakódování domény znalostí, které je obtížné naučit použitím konečného množství trénovacích dat. Přístupy založené na zkoumání rysů pracují mnohem rychleji než systém založený na zkoumání pixelů.

Kaskádový klasifikátor využívá Haarovy příznaky (viz obrázek 3.1). Hodnota příznaku dvou obdélníků je definována jejich rozdílem. Hodnota příznaku 3 obdélníků je dána součtem vnějších obdélníků odečtených od obdélníku uprostřed. Hodnota příznaku 4 obdélníků je definována rozdílem dvojic obdélníků na diagonálách. Všechny obdélníky mají stejnou velikost a tvar a sousedí spolu horizontálně nebo vertikálně. Základní velikost obdélníků v detektoru je 24×24 pixelů.




Obrázek 3.1: Ukázka Haarových příznaků

Tento klasifikátor umí pracovat nejen s Haarovými příznaky, ale také s příznaky LBP, HOG a dalšími. LBP příznaky neboli příznaky místních binárních vzorů jsou získány pro všechny pixely v obraze. Pro každý pixel je spočítán váhový součet okolních pixelů po prahování. Příznaky jsou zobrazeny na obrázku 3.2.

Integrální obraz

Obdélníkové příznaky lze spočítat rychle pomocí střední reprezentace obrazu, zvané integrální obraz. Integrální obraz na souřadnicích x, y obsahuje součet pixelů nad a vlevo od těchto souřadnic:

$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y'), \quad (3.1)$$



Obrázek 3.2: Ukázka LBP příznaků

kde $ii(x, y)$ je integrální obraz a $i(x, y)$ je originální obraz. Použitím následující dvojice rekurzivních funkcí:

$$s(x, y) = s(x, y - 1) + i(x, y), \quad (3.2a)$$

$$ii(x, y) = ii(x - 1, y) + s(x, y), \quad (3.2b)$$

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

Učení klasifikátoru

Vzhledem k sadě příznaků a trénovací sadě pozitivních a negativních obrázků může být použit libovolný počet přístupů strojového učení pro nalezení klasifikační funkce. V tomto systému je pro trénink použita varianta AdaBoost.

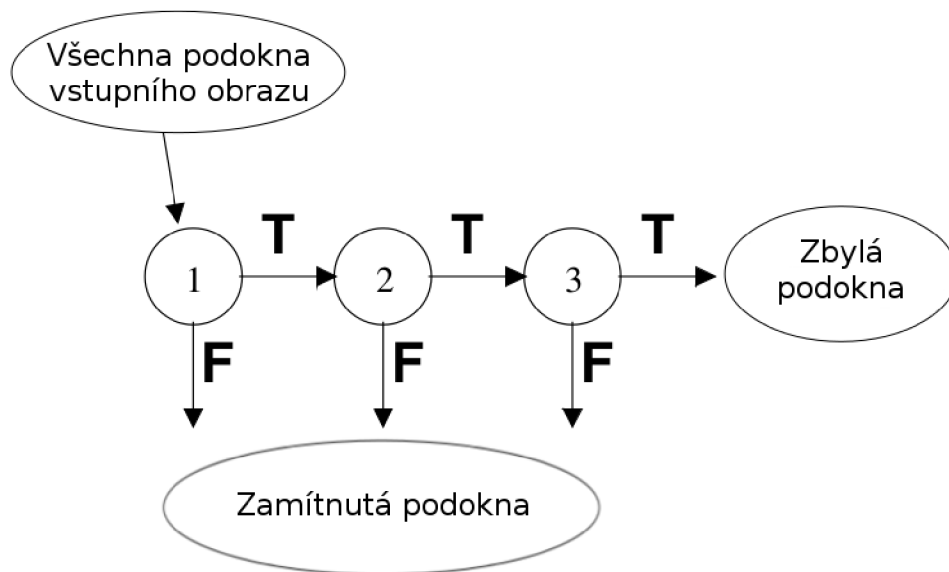
Velmi malý počet příznaků může být zkombinován pro vytvoření efektivního klasifikátoru. Slabý učící algoritmus je navržen pro výběr jednoho obdélníkového příznaku, který nejlépe oddělí pozitivní a negativní příklady. Pro každý příznak je určena optimální prahová klasifikační funkce tak, že minimální počet příkladů zůstane neklasifikován. Slabý klasifikátor $h_j(x)$ se skládá z příznaku f_j , prahovací funkce θ a parity p_j označující směr nerovnosti. Parametr x je podokno vstupního obrazu o defaultní velikosti 24×24 pixelů. Funkce slabého klasifikátoru:

$$h_j(x) = \begin{cases} 1 & \text{pokud } p_j f_j(x) < p_j \theta_j \\ 0 & \text{jinak} \end{cases} \quad (3.3)$$

Konstrukce kaskádového klasifikátoru

Konstrukce kaskády klasifikátoru zajistí zvýšenou výkonnost detekce a zároveň snižuje výpočetní čas. Klíčovou myšlenkou je konstrukce malých, ale výkonějších, klasifikátorů, které odmítají mnoho negativních podoken vstupního obrazu. Jednodušší klasifikátory jsou použity k odmítnutí většiny podoken, složitější klasifikátory snižují míru negativních případů.

Celková podoba procesu detekce je konstrukce rozhodovacího stromu, který je nazýván kaskáda (viz obrázek 3.3). Série klasifikátorů postupně zpracovává všechna podokna vstupního obrazu. Iniciální klasifikátor eliminuje velký počet negativních podoken s velmi krátkou dobou zpracování. Následující klasifikátor odstraňuje další negativní podokna, ale vyžaduje delší zpracování. Po několika stupních kaskády je počet podoken radikálně snížen. Kaskádou projdou pouze pozitivní podokna.



Obrázek 3.3: Schématický popis kaskádového klasifikátoru.

Trénování kaskády

Ve většině případů dosahují klasifikátory s více stupni v kaskádě vyšší míry detekce pozitivních vzorků a nižší míry detekce falešných vzorků. Klasifikátory s více příznaky potřebují více času pro výpočet. To vyžaduje různé optimalizace, ve kterých se definuje:

- počet klasifikačních stupňů,
- počet příznaků v každé fázi,
- prahová hodnota každého stupně.

Tyto hodnoty jsou vyměřeny tak, aby se minimalizoval počet hodnocených příznaků.

Výsledky kaskádového klasifikátoru

Kaskádový klasifikátor byl prvně použit pro detekci obličejů v obraze. Úspěšnost tohoto klasifikátoru je zobrazena v tabulce 3.1. Klasifikátor byl spuštěn nad 130 obrázky obsahující 507 obličejů.

Počet negativních detekcí						
10	31	50	65	78	95	167
76,1%	88,4%	91,4%	92,0%	92,1%	92,9%	93,9%

Tabulka 3.1: Výsledky kaskádového klasifikátoru

3.2 Klasifikátor SVM

Support Vector Machines (dále jen SVM) je algoritmus strojového učení. SVM je široce používán v mnoha aplikacích nejen počítačového vidění. Tento klasifikátor byl poprvé navržen v knize *The Nature of Statistical Learning Theory* [20]. Při psaní této sekce bylo čerpáno z diplomové práce Jakuba Sochora [19] a technické zprávy Jana Faigla a kol. [9]. SVM je možné využít pro klasifikaci i regresi. Klíčovou myšlenkou klasifikace je hledání nadroviny, která v prostoru příznaků optimálně rozděljuje trénovací data.

Lineární SVM

Základním předpokladem této metody je, že objekty jsou lineárně oddělitelné. Lineární SVM klasifikátor rozděljuje prvky do dvou tříd $\mathbb{Y} = \{-1, 1\}$.

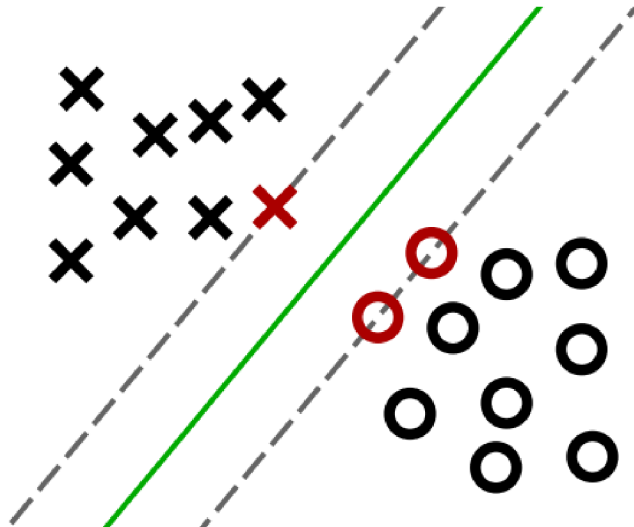
Hlavní myšlenkou je rozdělení objektů pomocí nadroviny. Tato nadrovina je použita pro klasifikaci ve formě normálového vektoru w a skalárního prahu b . Vektor x je klasifikován jako výsledek $w \cdot x - b$, kde skalární součin je definován následujícím vzorcem:

$$w \cdot x = w^T x \quad (3.4)$$

Nadrovina je nazývána optimální nadrovinou pokud vektor x_i je separován bez chyb pomocí rovnic (3.5) a (3.6) a vzdálenost nejbližšího vektoru od nadroviny je maximální. Ukázka optimální nadroviny je zobrazena na obrázku 3.4. Nejbližší vektory nadroviny jsou nazývané *support vectors*.

$$w \cdot x_i - b \geq +1 \quad \text{pro } y_i = +1 \quad (3.5)$$

$$w \cdot x_i - b \leq -1 \quad \text{pro } y_i = -1 \quad (3.6)$$



Obrázek 3.4: Optimální rozdělující nadrovina (zelená přímka) a support vectors (červené prvky). Převzato z [19].

3.3 Detektor MSER


Maximálně stabilní extrémní regiony (Maximally Stable Extremal Regions, dále jen MSER) jsou novým typem obrazových elementů. Tyto elementy – regiony – jsou definovány intenzitou v regionu a na jejich vnější hranici.[14] Regiony MSER jsou tvořeny plochami pixelů z prahovací funkce s malou velikostí změny napříč různými prahy. Počet prahů, pro kterou je region stabilní, se nazývá rozpětí regionu.[11]

MSER detektor postupně provádí prahovací funkci nad obrazem pro všechny hodnoty intenzity. S rostoucím prahem přibývají černé skvrny odpovídající místním minimům intenzity. Průběžně dochází k propojení sousedních černých skvrn. Množina všech nalezených regionů přes větší rozsah prahových hodnot je množinou maximálních regionů. Minimální regiony by byly získány stejným postupem aplikovaným na obraz s obrácenou intenzitou všech pixelů.[14]

U mnoha obrazů je binarizace stabilní ve velkém rozsahu prahových hodnot v určitých regionech. Tyto oblasti jsou předmětem zájmu a mohou splňovat následující vlastnosti:

- Invariance na afinní transformaci obrazu intenzit.
- Kovariance na přilehlost zachování transformace $T : D \rightarrow D$ na obrazové doméně.
- Stabilita extrémních regionů, které jsou neměnné pro větší rozsah vybraných prahových hodnot.
- Detekce v maximálním měřítku. Nedochozí k žádnému vyhlazení regionu, je detekována velmi jemná a velmi velká struktura.
- Množina všech extrémních regionů může být vyčíslena složitostí $O(n \log \log n)$, kde n je počet pixelů v obraze.

Výčet extrémních oblastí probíhá následujícím způsobem. Pixely jsou seřazeny podle intenzity, jejíž hodnoty jsou typicky v rozsahu intervalu $\langle 0, 255 \rangle$. Po seřazení jsou pixely postupně vkládány do obrazu (seznam nalezených oblastí a jejich ploch je udržován pomocí algoritmu hledajícího soulad s oblastmi získanými jinými prahy). Složitost tohoto algoritmu je $O(n \log \log n)$.



Obrázek 3.5: Ukázka výstupu MSER detektoru. Levý obrázek zobrazuje elipsy aproximující k nalezeným regionům. Pravý obrázek zobrazuje detail na elipsy nalezených MSER regionů.

Tento proces vytváří datovou strukturu pro ukládání dat jednotlivých nalezených oblastí jako funkce intenzity. Sloučení dvou oblastí je považováno za ukončení existence malých oblastí a vložení všech jejich pixelů do větší komponenty. Úrovně intenzity, které jsou lokální minima, jsou vybrány jako prahy produkující MSER regiony. Výstup detektoru je reprezentován polohou minimálních místních intenzit a hodnotou prahu. Na obrázku 3.5 je zobrazena detekce MSER regionů.¹

¹Obrázek převzat z prezentace o MSER detekci. Dostupné z odkazu: http://courses.cs.washington.edu/courses/cse576/07sp/notes/MSER_white.pdf

Kapitola 4

Nově vytvořená datová sada

Pro účely této práce bylo potřeba pořídit rozsáhlou datovou sadu. V této kapitole je popsáno pořízení sady a jak byly datové sady upraveny pro tvorbu detektorů registračních značek a klasifikátoru znaků. V kapitole 6 jsou popsány vytvořené programy, kterými byly tyto datové sady zpracovány a získány.

4.1 Sběr dat

Datová sada použitá v této práci byla natočena na území města Brna. Videá byla nahrána kamerou Panasonic DHC-TM700 s rozlišením obrazu 1920×1080 px a snímkovou rychlostí 50 snímků za sekundu. Čas závěrky byl nastaven na $1/350$ s. Na obrázku 4.1 je zobrazena ukázka nasbírané datové sady.



Obrázek 4.1: Snímky dopravy nasbírané datové sady.

Datové sady se liší místem snímání a pozicí kamery vůči vozidlům. Kamera byla umístěna:

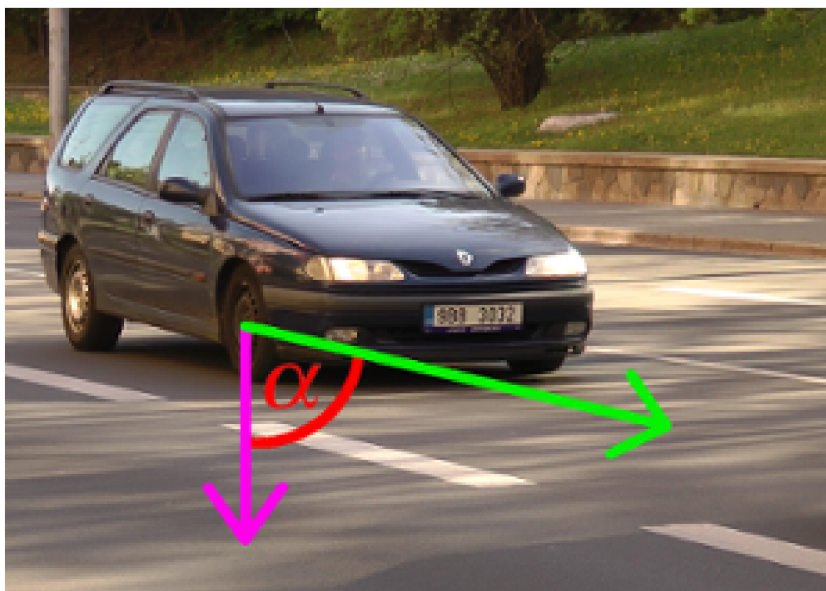
- na úrovni aut s mírným úhlem k pruhu vozovky,
- nad úrovní aut (lávky, mosty) přímo proti pruhu vozovky a
- nad úrovní aut (lávky, mosty) s mírným úhlem k pruhu vozovky.

Celkem bylo natočeno 35 použitelných videí, z nichž 23 bylo použito pro trénování detektoru a 12 videí bylo vyčleněno pro vyhodnocení úspěšnosti. Videi byla natočena v délce od 30 s do 200 s. Průměrná délka jednoho videa byla 1 min 50 s.

Jelikož by byla práce se všemi snímky nasbíraných videí zbytečná, tak z nich byl vybrán každý 20 snímek, který pak byl na vstupu učení detektoru. Ze získaných snímků byly vymazány ty, na kterých se nevyskytovalo žádné vozidlo. Tím došlo k omezení velmi shodných snímků se stejnými informacemi. Výsledná datová sada obsahuje celkem 2745 snímků.

Pro vyhodnocení systému detekce a rozpoznání bylo vyhrazeno 12 videí ze tří míst, která byla odlišná od míst natočení trénovací datové sady. Jednotlivá místa se od sebe liší úhlem pohledu kamery ke směru vozovky (viz obrázek 4.2):

- Datová sada Úvoz – kamera umístěna na úrovni aut pod úhly $47^\circ - 72^\circ$, auta snímána zepředu,
- Datová sada Zvonařka – kamera umístěna v nadhledu pod úhly $45^\circ - 72^\circ$, auta snímána zepředu za přímého slunečního svitu,
- Datová sada Vaňkovka – kamera umístěna v nadhledu pod úhly $5^\circ - 59^\circ$, auta snímána zezadu.




Obrázek 4.2: Úhel pohledu kamery ke směru vozovky. Růžový vektor udává směr ke kameře. Zelený vektor kopíruje směr vozovky. Tyto vektory svírají úhel α .

4.2 Datová sada pro trénování detektoru registračních značek


Pořízenou trénovací datovou sadu snímků z dopravy bylo potřeba zpracovat pro její použití při vytváření detektoru registračních značek. Pozitivní datová sada obsahovala shodné snímky jako originální sada. K ní byl vytvořen soubor s anotacemi o počtu a umístění registračních značek v každém snímku. Negativní sada obsahovala stejné snímky jako pozitivní sada, jen s tím rozdílem, že registrační značky aut byly začerněny. Soubor s anotacemi negativního setu obsahoval pouze seznam cest k obrázkům. Tato datová sada je zobrazena na obrázku 4.3. V tabulce 4.1 jsou udány počty této datové sady. Jelikož se pozadí v jedné scéně nemění, došlo k omezení negativní sady o množství duplicitních snímků.

Datová sada	Počty snímků
pozitivní	2745
negativní	236

Tabulka 4.1: Počty souborů v datové sadě



(a) Snímek pozitivní datové sady



(b) Snímek negativní datové sady

Obrázek 4.3: Ukázka pozitivní a negativní sady snímků z dopravy.

Tato datová sada byla dále upravena a připravena pro práci s výřezy z jejích snímků (viz obrázek 4.4). Pozitivní datová sada obsahovala výřezy registračních značek. Negativní sada byla vytvořena z výřezů negativních obrázků, které obsahovaly prvky silnice, karoserií aut, světel, zeleně podél vozovky apod. Tato sada výřezů byla použita pro natrénování kaskádového klasifikátoru pro detekci registračních značek. Počty nasbíraných výřezů jsou uvedeny v tabulce 4.2.

Datová sada	Počty výřezů
pozitivní	2814
negativní	2820

Tabulka 4.2: Počty výřezů datové sady



(a) Pozitivní výřezy s registračními značkami

(b) Negativní výřezy ze scény dopravy

Obrázek 4.4: Pozitivní a negativní výřezy pro trénování kaskádového klasifikátoru.



Obrázek 4.5: Datová sada znaku 5.

4.3 Datová sada pro trénování klasifikátoru znaků


Datová sada pro vytvoření klasifikátoru znaků obsahuje pro každý znak jeden obrázek. Tento obrázek je tvořen mnoha výřezy daného znaku z registračních značek trénovací datové sady. Datová sada znaku 5 je zobrazena na obrázku 4.5.

Pořízené sady jednotlivých znaků obsahovaly znaky různé kvality zobrazení, proto byly všechny znaky roztrženy do tří kategorií – dobré, střední a špatné. Rozdíl mezi těmito kategoriemi je zobrazen na obrázku 4.6.

V tabulce 4.3 jsou uvedeny počty vyextrahovaných znaků z registračních značek testovací datové sady. Na území města Brna se nepodařilo nasbírat dostatečný počet všech písmen abecedy. Pro tato písmena nebude možné natrénovat kvalitní klasifikátor, a proto nejsou ani uvedena v tabulce.

Pro úplnost zde uvádím i datovou sadu pro natrénování kaskádového klasifikátoru, která nakonec nebyla použita. Natrénovaný kaskádový klasifikátor se neosvědčil a jeho výsledky byly téměř náhodné. Nicméně by tato datová sada mohla být užitečná i pro jiné použití.

Pozitivní datová sada obsahuje již výše popsané výřezy jednotlivých znaků uložené do jednoho velkého obrázku (viz obrázek 4.5). Pro každý znak je vytvořena negativní datová sada, která se skládá z výřezů registračních značek v nichž je vždy daný znak začerněn. Negativní sada je zobrazena na obrázku 4.7.



Obrázek 4.6: Ukázka rozdělení datové sady znaku 5 do kategorií dle kvality.



Obrázek 4.7: Negativní datová sada znaku 5 pro trénink kaskádového klasifikátoru.

Znak	Počty znaků			
	celkem	dobré	střední	špatné
0	969	441	365	163
1	1158	680	383	95
2	1154	536	266	352
3	1184	573	289	322
4	1300	642	317	341
5	1209	705	175	329
6	1095	483	314	298
7	1352	580	358	414
8	1111	489	275	347
9	1235	783	118	334
A	256	124	49	83
B	1531	683	409	439

Tabulka 4.3: Počty vyextrahovaných znaků

Kapitola 5

Návrh řešení systému

Cílem této diplomové práce bylo navrhnout a vytvořit systém pro detekci registračních značek v obraze a rozpoznání jejích znaků. V této kapitole jsou stanoveny prostředky, jak tohoto cíle dosáhnout. Jsou zde vybrány detekční metody a rozebrán návrh řešení.

5.1 Analýza problému

Detekce a rozpoznání registračních značek je aktuální problém řešený v mnoha výzkumech. Tento systém je používán pro bezpečnostní kontroly, sledování provozu, získávání statistik, automatické platby mýtného nebo poplatků za parkování, aj.

Zásadní vliv na úspěšnost detekce a rozpoznání registračních značek má kvalita vstupního obrazu. Ta je závislá z velké části na technické úrovni použité záznamové techniky. Důležitými parametry digitálních kamer jsou především: kvalita optické soustavy, rozlišení záznamu a rychlost závěrky (expoziční čas). Čím kratší je čas expozice, tím ostřejší je výsledný obraz i u rychle jedoucích aut. Snižování expozičního času má za následek úbytek množství světla dopadajícího na obrazový senzor kamery, a tudíž snížení jasů videa. Je tedy nutné zvolit kompromis mezi časem závěrky a světelnými podmínkami okolí.

Na úspěšnost detekce a rozpoznání registrační značky má velký vliv samotné umístění snímacího zařízení. Umístěním kamery přímo proti vozidlům jsou získány snímky, kde je spodní hrana registrační značky rovnoběžná se spodní hranou snímku. Je-li mezi pohledem kamery a směrem vozovky větší úhel, pak jsou registrační značky často natočené a také vizuálně užší než při pohledu zepředu.

Výhodou při snímání provozu je relativně jednoduché pozadí, které obsahuje převážně vozovku, silniční pruhy, chodníky, zábradlí apod. Tato výhoda je patrná hlavně při umístění kamery z nadhledu, kdy jsou viditelné převážně tyto jednoduché textury. Při umístění kamery na úrovni aut je často její pohled nasměrován do dálky a pozadí snímaného obrazu je již členitější. Obsahuje textury omítek domů, okna, výlohy obchodů, směrovací cedule a reklamy. Toto prostředí již může detekčním algoritmům způsobovat problémy.

Registrační značka vozidla má zákonem daný rozměr a poměr stran je častým ověřovacím kritériem kontroly nalezené značky. Je-li kamera umístěna na silnicích a dálnicích mimo město, kde vozidla udržují dostatečné rozestupy, získané snímky obsahují ve většině případů celou registrační značku. Problém nastává ve městech, kde jsou rozestupy mezi vozidly mnohem menší a doprava není plynulá vlivem zastavování na dopravních semaforech. Na snímcích je často viditelná jen část registrační značky, která často nemusí postačovat k přesné identifikaci vozidla. Tento problém je možné zmírnit vhodným umístěním kamery,

např. z nadhledu přímo nad snímaným pruhem vozovky.

Prostředí, ve kterém je doprava snímána, je relativně jednoduché, ale není neměnné. Liší se v závislosti na denní době, ročním období a samotném počasí. Nejčastější je rozdíl při změně osvětlení, které se mění často v závislosti na tom, jestli je den či noc. I ve dne se vyskytuje mnoho druhů osvětlení. Směr slunečních paprsků se v průběhu dne mění a registrační značky aut mohou být ve stínu nebo přímo nasvíceny sluncem. V takovém případě jsou někdy nečitelné kvůli odrazu slunečních paprsků. Na kvalitu scény má velký vliv samotné počasí, které je v průběhu roku velmi proměnlivé. V případě padajícího deště nebo sněhu je úloha detekce a rozpoznání registračních značek mnohem obtížnější. Snímaný obraz je zasažený šumem a informace o značce a její podobě jsou hůře čitelné.

Nejčastěji používaný rozměr registrační značky je 520×110 mm, umístěný na automobilech, autobusech a nákladních vozidlech. Nicméně se mohou vyskytovat také jiné rozměry registračních značek (např. na motorkách, kde je značka rozdělena do dvou řádků). Problémy může přinášet i samotná deska registrační značky. Ta může být zaprášená nebo špinavá a viditelnost značky i samotných znaků je velmi omezená. Značky starších vozidel bývají také pomačkány a samotný text bývá mnohdy narušen.

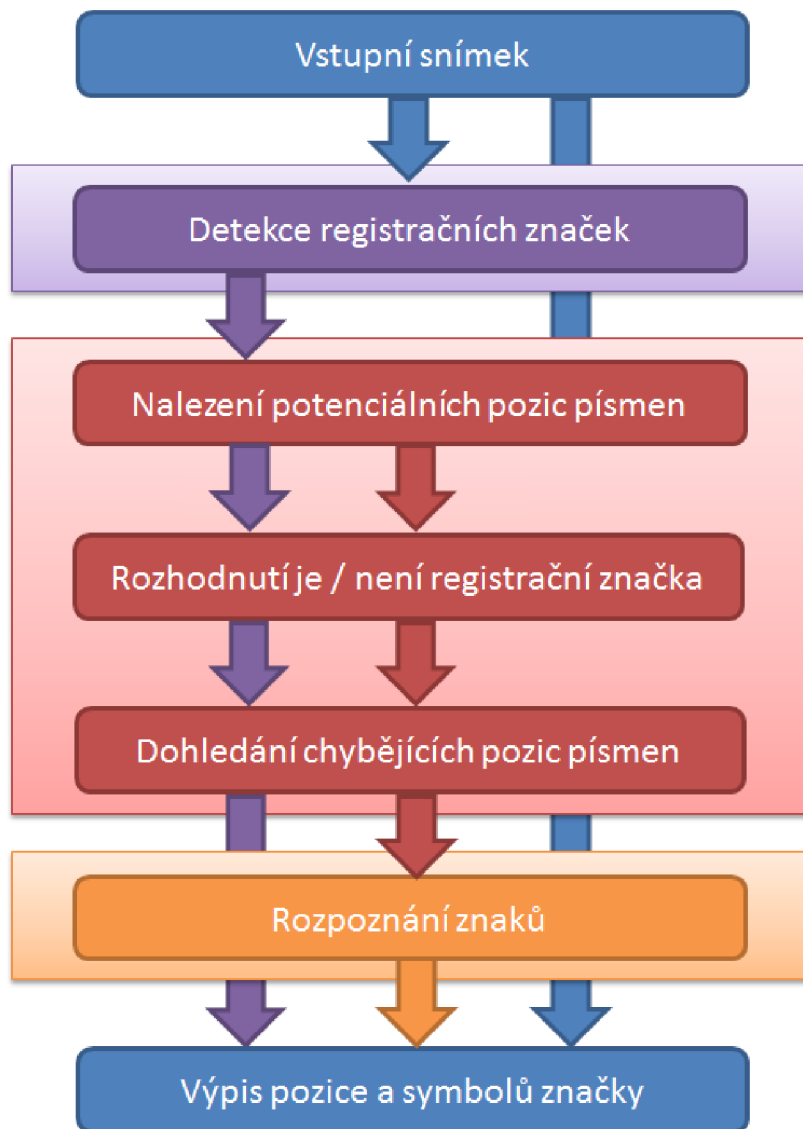
Tato práce počítá s dobrou kvalitou vstupních snímků, které jsou ostré nebo lehce rozostřené. Nicméně znaky registrační značky jsou stále relativně dobře čitelné. Obraz je snímán z různých pohledů, kamera je umístěna na úrovni aut nebo v nadhledu přímo proti autům a pod různými úhly pohledu ke směru vozovky. Obraz je získán za jasného nebo oblačného počasí, v potaz není brán déšť, sníh a jiné znečištění scény. Detekce je zaměřena na značky nejčastějšího rozměru 520×110 mm a uvažuje všechna možná znečištění a poškození samotné desky.

5.2 Návrh systému

Systém detekce a rozpoznání registračních značek se skládá ze tří základních částí, které na sebe postupně navazují:

- detekce registrační značky,
- nalezení pozic znaků a
- rozpoznání znaků.

Na obrázku 5.1 je znázorněno schéma navrženého systému. Vstupem je snímek dopravy, ve kterém jsou vyhledány potenciální pozice registračních značek. V těchto místech se pokusí algoritmus vyhledat znaky registrační značky. Vytipované pozice jsou kontrolovány, zda odpovídají velikostně, svým umístěním a celkovým počtem registrační značce. V průběhu zpracování je mnoho pozic znaků vyřazeno a dochází k rozhodnutí, zda vytipovaná plocha je nebo není registrační značkou. Na pozitivních místech probíhá další zpracování. Pokud registrační značce chybí pozice jednoho znaku, je tato pozice dohledána. Následně proběhne rozpoznání znaků registrační značky, jejich výpis na obrazovku počítače a zakreslení do originálního snímku. Následující podsekcce popisují jednotlivé části navrženého a implementovaného systému.



Obrázek 5.1: Schéma systému detekce a rozpoznání registrační značky vozidla. Barevné boxy označují tři základní části – detekce registrační značky (fialová), nalezení pozic znaků (červená), rozpoznání znaků (oranžová). Barevné šipky označují typ informace, které se mezi jednotlivými kroky přenáší – vstupní obrázek (modrá), plochy nalezené detektorem registračních značek (fialová), výřezy symbolů registrační značky (červená), řetězec s rozpoznanými symboly (oranžová).

5.2.1 Detekce registračních značek

Pro detekci registračních značek byl zvolen kaskádový klasifikátor (více v sekci 3.1), jehož velkou výhodou je vysoká snímková rychlost.

Vstupem pro trénování klasifikátoru byla datová sada pozitivních a negativních výřezů registračních značek popsaná v sekci 4.2. Vzorky trénovacích dat jsou ve stejném poměru jako je rozměr registrační značky. Trénování proběhlo v deseti iteracích za použití příznaků LBP a algoritmu Gentle AdaBoost. Výsledný detektor byl natrénován na minimální velikost značky 60×16 pixelů, aby byly zachovány dostatečné informace o podobě znaků registrační značky.

Výstupem kaskádového klasifikátoru je seznam pozic, kde se nachází registrační značky. Mezi těmito výstupy se objevují i chybné výřezy (false positives), ale ty jsou v následujících částech systému vyřazeny. Výsledky detektoru jsou zobrazeny na obrázcích 5.2.




Obrázek 5.2: Detekce registračních značek pomocí kaskádového klasifikátoru.

5.2.2 Nalezení potenciálních pozic písmen a rozhodnutí je/není registrační značka

Vstupem této části jsou výřezy dané detektorem registračních značek. Tyto výřezy obsahují registrační značky i falešné detekce. Proto je nutné najít potenciální pozice písmen a na základě umístění těchto pozic ve výřezu určit, zda se jedná o registrační značku či nikoliv. Pokud pozice neodpovídají, pak je chybný výřez zahozen a snižuje se tím i míra false positives. Pro nalezení pozic byly použity dva různé způsoby – detekce MSER regionů a detekce blobů.

Prvním způsobem nalezení pozic písmen je detekce MSER regionů. Každý nalezený region je obalen do obdélníku. Obdélníky, které nesplňují minimální šířku a výšku, jsou vyřazeny. Pokud je pozic méně než 4, pak tento výřez není registrační značka. Následně je ze všech zbývajících obdélníků získána hodnota mediánu výšky. Výřezy, jejichž výška



Obrázek 5.3: Detekce blobů. Každý nalezený segment je reprezentován jednou číslicí.

není v intervalu medián $\pm x$, kde x je povolená odchylka, jsou opět vyřazeny. Může se stát, že do jednoho obdélníku je zabaleno více znaků. Pokud je obdélník moc široký, pak je rozdělen na dva až čtyři užší obdélníky v závislosti na poměru výšky ku šířce. Jelikož detekce MSER regionů může poskytovat pro jedno místo více regionů, je třeba tyto duplicity omezit. Všechny regiony, které jsou na podobných pozicích, jsou seskupeny a získána jejich průměrná hodnota. Tímto dojde k omezení mnoha duplicitních obdélníků a zůstane vždy jeden obdélník pro jednu nalezenou pozici. Výsledné pozice obdélníků jsou seřazeny od nejlevějšího po nejpravější.

Druhý způsob je založen na vyhledání blobů. Potenciální výřez registrační značky je převeden do binárního obrazu metodou OTSU. V tomto obrázku jsou pro všechny černé pixely vyhledány spojitě segmenty pomocí algoritmu záplavového vyplňování. Tyto segmenty jsou zobrazeny na obrázku 5.3, kde každý segment je udán jednou číslicí. Každý segment je poté uzavřen do obalujícího obdélníku a je zkontrolována jeho minimální velikost. Stejně jako u předchozího způsobu nalezení znaků je kontrolována výška obdélníků. Pokud jsou obdélníky moc široké, opět dojde k jejich rozdělení na více obdélníků. Dále probíhá kontrola mezer mezi sousedními obdélníky a jejich vzdáleností od krajů. Pokud je tato vzdálenost větší než půlka originálního výřezu, pak se nejedná o registrační značku. Stejná kontrola probíhá i ve vertikálním směru. Nakonec jsou výsledné pozice seřazeny od nejlevějšího po nejpravější prvek.

Na obrázku 5.4 jsou zobrazeny výstupy obou zmíněných metod vyhledání pozic znaků ve výřezu registrační značky. Levý sloupec obsahuje originální výřez dané detektorem registračních značek. V prostředním sloupci jsou zobrazeny nalezené pozice znaků pomocí detekce MSER. Pravý sloupec obsahuje výsledné pozice nalezené metodou detekce blobů. V zobrazených příkladech jsou ukázány i případy, kdy selže jedna nebo druhá metoda a nejsou dohledány všechny pozice znaků.

5.2.3 Dohledání chybějících pozic písmen

V minulém kroku byly vyhledány pozice písmen v registrační značce. Je-li nalezeno sedm pozic, pak je možno přejít k samotnému rozpoznání samotných znaků. Pokud je těchto pozic pět a méně, tak daný výřez není registrační značka a je vyřazen z posuzování. V případě, že je nalezeno pouze šest pozic, probíhá dohledání chybějící pozice.



Obrázek 5.4: Nalezení pozic písmen. Sloupec a) obsahuje originální výřez registrační značky. Ve sloupci b) jsou znázorněny výstupy pomocí detekce MSER regionů. Sloupec c) obsahuje výstup pomocí hledání blobů. V řádcích 1-3) jsou zobrazeny správné výstupy obou metod. V řádcích 4-6) je vidět, že metoda detekce blobů nefunguje správně. Ve zbývajících řádcích 7-8) jsou špatně nalezeny pozice metodou detekce MSER regionů.

Algoritmus dohledání chybějící pozice je založen na kontrole mezer mezi jednotlivými znaky. Celá registrační značka má formát 2 malých mezer, jedné střední mezery a 3 malých mezer. Malá mezera je široká většinou pár pixelů a nevleze se do ní žádný další znak. Do střední mezery se vleze právě jeden symbol a do velké se vlezou dva symboly. V tabulce 5.1 jsou vypsány kódy velikostí mezer mezi šesti nalezenými pozicemi znaků. Kódy jsou pro všechny případy jedinečné a lze podle nich jednoduše dohledat jednu chybějící pozici. Formát mezer je v tabulce udán čísly, kde 0 je malá mezera, 1 je střední mezera a 2 je velká mezera.

5.2.4 Rozpoznání znaků a sestavení výsledné registrační značky

Dalším krokem je již samotné rozpoznání znaků a sestavení výsledné registrační značky. V tuto chvíli jsou již ve většině případů vyřazeny výřezy, které nepředstavují registrační značku, a je nalezeno 7 pozic, na kterých by se měly vyskytovat jednotlivé symboly značky. Tyto pozice jsou seřazeny od nejlevější po nejpravější.

Rozpoznání znaků probíhá pomocí lineárního SVM klasifikátoru (více v sekci 3.2), který je natrénován pro symboly registrační značky. Byl zvolen typ MCSVM_CS, který umí řešit


Chybějící symbol	Kód velikosti mezer
1. pozice	0 1 0 0 0
2. pozice	1 1 0 0 0
3. pozice	0 2 0 0 0
4. pozice	0 0 2 0 0
5. pozice	0 0 1 1 0
6. pozice	0 0 1 0 1
7. pozice	0 0 1 0 0

Tabulka 5.1: Kódy velikostí mezer pro nalezení jednoho chybějícího symbolu

multi-třídní klasifikaci, a stopovací kritérium bylo nastaveno na hodnotu 0,00001. Vstupem učení klasifikátoru jsou příznaky získané z výřezů jednotlivých symbolů o fixní velikosti 20×40 pixelů popsané v podsekcí 4.3. Za příznaky byly zvoleny hodnoty jasu všech pixelů výřezu písmene a odezvy Sobelova hranového detektoru ve směrech x a y.

Vektor příznaků je získán následovně. Ze vstupního obrázku znaku registrační značky jsou získány hodnoty jasu. Jednotlivé řádky matice jsou poskládány postupně za sebe a vznikne vektor obsahující 800 prvků. Stejným způsobem jsou získány vektory hodnot Sobelova hranového detektoru v osách x a y. Všechny tři získané vektory jsou vloženy do jednoho vektoru obsahujícího postupně hodnoty jasu, odezvy hranového detektoru v ose x a odezvy hranového detektoru v ose y. Výsledný vektor má 2400 prvků.

Klasifikátor je natrénován nad obrázky znaků, které obsahují i informace o okolí symbolu. Při rozpoznání znaků registrační značky v popisovaném systému je pro každou nalezenou pozici znaku uvažováno i její nejbližší okolí, a to konkrétně okolí dané 30 % výšky symbolu. Tento výřez je poté transformován na velikost 20×40 pixelů a je pro ni získán vektor příznaků. Natrénovaný klasifikátor poté na základě dodaného vektoru příznaků rozpozná, o jaký symbol registrační značky se jedná. Jelikož jsou nalezené pozice znaků seřazeny od nejlevější po nejpravější, tak jsou v tomto pořadí předávány klasifikátoru a tím je jednoduše získána finální podoba registrační značky. Na obrázku 5.5 je ukázán výstup SVM klasifikátoru.



Obrázek 5.5: Ukázka správného výstupu SVM klasifikátoru

Samotné výsledky systému jsou vypisovány na standardní výstup terminálu v podobě:

```
x y width height ---> LP,
```

kde x, y udávají levý horní roh nalezené registrační značky a w, h udávají šířku a výšku značky. LP je řetězec obsahující rozpoznané znaky registrační značky. Výstupy jsou také vizuálně zobrazovány do okna počítače. Některé výstupy jsou ukázány na obrázcích 5.6 a 5.7.



Obrázek 5.6: Ukázka správných výstupů celého systému detekce a rozpoznání registrační značky vozidel.



Obrázek 5.7: Ukázka výstupů celého systému detekce a rozpoznání registrační značky vozidel. Tyto výstupy obsahují chyby zapříčiněné špatným rozpoznáním symbolu, nenatrénováním daného znaku abecedy nebo nenalezením registrační značky.

Kapitola 6

Pomocné aplikace vytvořené pro tento systém

V této kapitole jsou popsány aplikace, které byly vytvořeny v rámci práce pro tvorbu datových sad, zobrazení výstupů a vyhodnocení úspěšnosti systému. Je zde ve zkratce výpis všech aplikací, parametrů jejich spuštění a jaký je jejich výstup. Některé zásadnější programy jsou popsány podrobněji v následujících sekcích. Všechny aplikace byly napsány v jazyce C/C++ za použití knihovny OpenCV. Jedná se o konzolové aplikace spustitelné z příkazové řádky. Veškerý vývoj probíhal v operačním systému Fedora 20.

Název	Parametry	Popis
Zpracování vstupního videa		
processVideo	-i <input-video>	Vystřížení každého 25. snímku videa. Vstupem je video z dopravy. Výstupem jsou vystřížené snímky uložené do složky data.
Příprava dat pro trénování detektoru RZ pomocí kaskádového klasifikátoru		
find-LP	-d <images-list> -w <max-width-of-LP> -p <range-around-LP>	Jednoduchý detektor registračních značek. Vstupem je seznam obrázků dopravy, maximální možná šířka značky daná poměrem ku šířce snímku a velikost obalovacího pruhu okolo značky udaný v procentech. Výstupem jsou adresáře obsahující pozitivní a negativní snímky a k nim odpovídající seznamy. Více v podsekcí 6.1.
prepare-data	-d <LP-list>	Příprava dat pro kaskádový klasifikátor. Vstupem je seznam cest a pozic k registračním značkám. Program kontroluje, zda uživatel značku ponechal či smazal a tvoří odpovídající seznamy pozitivních i negativních vzorků.

Název	Parametry	Popis
create-negatives	-d <directory>	Vytvoření negativní datové sady výřezů (viz sekce 4.2). Vstupem je adresář obsahující negativní snímky vytvořené předchozím skriptem. Výstupem je mnoho výřezů těchto snímků uložené do adresáře negatives-final.

Zobrazení výstupů detektoru registračních značek

detect-LP	-i <input-image> -l <input-list> -d <detector-LP>	Zobrazení výstupu detektoru RZ pro jeden snímek nebo pro seznam snímků dopravy. Výstup nalezených ploch je zakreslen žlutým obdélníkem do originálního snímku a zobrazen.
-----------	---	---

Příprava datové sady znaků

extract-letters	-d <directory>	Aplikace pro tvorbu datové sady znaků. Vstupem je adresář obsahující výřezy registračních značek. Je vyžadována interakce s uživatelem, který musí naklikat pozice znaků. Výstupem je datová sada znaků popsaná v kapitole 4.3. Více v podsekcí 6.2.
sort-to-categories	-d <directory>	Rozdělení vytvořených datových sad znaků do tří kategorií – dobré, střední a špatné. Vstupem je pracovní adresář obsahující datovou sadu znaků. Výstupem jsou pro každý znak tři soubory obsahující znaky dané kategorie.

Tvorba anotací testovací datové sady

create-annotation	-d <directory>	Příprava anotací k testovací datové sadě. Vstupem je adresář obsahující snímky dopravy. Uživatel postupně kliká vždy levý a poté pravý okraj RZ a poté zadá podobu RZ. Pro zadání další RZ stiskne mezerník, pro skok na další snímek enter. Výstupem je seznam vypsaný na standardní výstup v podobě: cesta-k-obrázku N x1 y1 x2 y2 TEXT ..., kde N je počet RZ v obraze, $x1$ a $y1$ udává souřadnice levého okraje RZ, $x2$ a $y2$ pravý okraj RZ a $TEXT$ znaky RZ.
-------------------	----------------	---

Vyhodnocení úspěšnosti

lp-evaluation	-a <annotations>	Aplikace pro vyhodnocení úspěšnosti kaskádového klasifikátoru. Vstupem je soubor s anotacemi a výstupem počet true a false positives a úspěšnost detektoru v procentech. Více sekci 6.4.
---------------	------------------	--

Název	Parametry	Popis
system-evaluation	-a <annotations> -r <results>	Automatické vyhodnocení úspěšnosti detekce registračních značek po vyřazení false positives výřezů. Dále probíhá vyhodnocení úspěšnosti klasifikace znaků. Vstupem je soubor s anotacemi a soubor s výsledky vygenerovaný samotným systémem. Výsledky jsou vypsány na standardní výstup do terminálu.

6.1 Příprava dat pro trénování detektoru registračních značek

Pro detekci registračních značek v obraze byl zvolen kaskádový klasifikátor (více v sekci 3.1). Tento klasifikátor vyžaduje pro trénování velkou sadu obrázků pozitivních a negativních případů a k nim odpovídající seznamy s cestami k obrázkům. Pro přípravu dat vznikly v rámci práce tři aplikace:

- **find-LP** – jednoduchý detektor registračních značek využívající detekci MSER regionů,
- **prepare-data** – příprava datových souborů pozitivní a negativní datové sady,
- **create-negatives** – vytvoření negativní datové sady výřezů.

Výstupem těchto dvou aplikací je datová sada zobrazená na obrázku 4.3 v sekci 4.2.

Příprava dat probíhá nad pracovním adresářem obsahujícím složku s obrázky z dopravy a soubor s absolutními cestami k jednotlivým obrázkům. Absolutní cesty jsou použity, aby bylo možné volat aplikace nad tímto seznamem z jakéhokoli místa počítače. V tabulce 6.1 je možné vidět obsah pracovního adresáře.


\$DATASET	vstupní datová sada
list.dat	seznam obrázků datové sady \$DATASET

Tabulka 6.1: Obsah pracovního adresáře

Aplikace **find-LP** je jednoduchým detektorem registračních značek, který má na vstupu seznam souborů datové specifikovaný v úvodu této sekce. Tento jednoduchý detektor je částečně inspirován detekční metodou popsanou v podsekci 2.2.2.

Na vstupní snímek je aplikován detektor MSER regionů (více v sekci 3.3), který vybere z obrázku zajímavá místa. Pro každý MSER region je zkontrolována jeho minimální a maximální velikost a poměr stran. Dále se kontroluje, zda jsou regiony vodorovné se spodním okrajem vstupního obrázku nebo jen mírně nakloněné, regiony s větším sklonem jsou z posuzování vyřazeny. Tímto je vyloučeno množství regionů, které nemohly představovat registrační značku vozidla. Následně je provedena analýza pixelů binárního výřezu registrační značky, při které dojde k součtu všech pixelů v každém sloupci obrazu. Na obrázku 6.1 jsou ukázány výstupy analýzy pixelů pro dva výřezy značek. V místech, kde se vyskytují

písmena na registrační značce, jdou vidět shluky černých pixelů. Pokud výřez obsahuje alespoň 3 takovéto shluky pixelů, pak je výřez považován za registrační značku. Číslo 3 bylo zvoleno na základě možné špatné kvality vstupních obrazů, kdy mohou být lehce rozostřeny a může dojít k propojení několika shluků dohromady. Výřezy z původního snímku, které prošly všemi testy, jsou prohlášeny za registrační značky.



Obrázek 6.1: Ukázka analýzy pixelů.

Výstupem této aplikace je adresář s uloženými nalezenými registračními značkami a seznam cest k těmto obrázkům. Obrázky výřezů byly uloženy v podobě `name-x-y-w-h.png`, kde `name` je jméno původního snímku, proměnné `x` a `y` určují pozici levého horního rohu značky v původním obraze a proměnné `w` a `h` určují šířku a výšku výřezu. V tabulce 6.2 jsou zobrazeny nově vytvořené soubory v pracovním adresáři.

LP-dataset	složka s obrázky s nalezenými registračními značkami
LP-list.dat	seznam souborů ve složce LP-dataset

Tabulka 6.2: Nové soubory v pracovním adresáři po jednoduché detekci registračních značek.

Aplikace **find-LP** se spouští se třemi parametry. Prvním parametrem je seznam obrázků z dopravy. Dále je možné specifikovat maximální možnou šířku registrační značky ve vstupním obraze, zadává se poměrem ku šířce vstupního obrazu. Poslední parametr specifikuje velikost obalovacího pruhu okolo registrační značky, který se bude uvažovat pro trénink klasifikátoru společně se značkou. Příkaz spuštění:

```
./find-LP -d <images-list> -w <max-size-LP> -p <range-around-LP>
```

Mezi získanými výřezy se nachází registrační značky vozidel, ale také mnoho false positives obrázků. Pro odstranění těchto mylných výřezů je potřeba, aby uživatel ručně prošel adresář `dataset-LP` a smazal všechny obrázky, které nepředstavují registrační značky aut.

Druhá aplikace s názvem **prepare-data**. Postupně se prochází seznam obrázků a kontroluje, zda byl obrázek uživatelem ponechán či smazán. Pro všechny ponechané obrázky představující registrační značky vozidel je vytvořen adresář `positive-dataset`, do něhož jsou uloženy původní obrázky s celou scénou, a soubor se seznamem pozitivních vzorků v podobě:

```
cesta-k-obrázku N x y šířka výška x y šířka výška ...,
```

kde `N` udává počet registračních značek v obraze, `x` a `y` představují pozici levého horního rohu značky v originálním obrázku a zbylé dvě hodnoty označují šířku a výšku registrační

značky. Dále je vytvořen adresář obsahující originální obrázky, ve kterých jsou registrační značky aut začerněny, pro trénování negativních případů, a seznam cest těchto obrázků. V tabulce 6.3 jsou vypsány nově vytvořené soubory v pracovním adresáři.

positive-dataset	složka s pozitivním setem obrázků
negative-dataset	složka s negativním setem obrázků, registrační značky jsou začerněny
pos-list.dat	seznam cest k souborům ve složce positive-dataset
neg-list.dat	seznam cest k souborům ve složce negative-dataset

Tabulka 6.3: Nové soubory v pracovním adresáři po přípravě trénovacích souborů.

Tato aplikace se spouští s jedním parametrem, který udává cestu k seznamu LP-list.dat. Příkaz spuštění:

```
./prepare-data -d <LP-list>
```

Jelikož jednoduchým detektorem nebyly nalezeny všechny registrační značky, je opět nutný zásah uživatele, který musí projít adresář negative-dataset a ručně začernit všechny zbývající viditelné značky, které by úspěšnost klasifikátoru výrazně zhoršily.

Poslední aplikace **create-negatives** slouží k vytvoření negativní datové sady výřezů. Hlavní myšlenkou je průchod obrazem pomocí sliding window, vyříznutí mnoha výřezů a jejich uložení do adresáře s názvem negatives-final. Vstupem této aplikace je adresář obsahující negativní sadu snímků vytvořenou v předchozím kroku. Příkaz spuštění:

```
./create-negatives -d <directory with negative dataset>
```

V tabulce 6.4 jsou zobrazeny všechny soubory pracovního adresáře po spuštění všech tří aplikací.

\$DATASET	vstupní datová sada
list.dat	seznam obrázků datové sady \$DATASET
LP-dataset	složka s obrázky s nalezenými registračními značkami
LP-list.dat	seznam souborů ve složce LP-dataset
positive-dataset	složka s pozitivním setem obrázků
negative-dataset	složka s negativním setem obrázků, registrační značky jsou začerněny
pos-list.dat	seznam cest k souborům ve složce positive-dataset
neg-list.dat	seznam cest k souborům ve složce negative-dataset
negatives-final	složka s negativní datovou sadou výřezů

Tabulka 6.4: Výpis všech souborů v pracovním adresáři po provedení všech tří aplikací.

6.2 Příprava datové sady znaků

Pro vytvoření klasifikátoru znaků bylo opět potřeba vytvořit velkou datovou sadu, na jejímž základě by bylo možné jej natrénovat. Pro tento účel byly vytvořeny dvě aplikace:

- **extract letters** – extrakce znaků z výřezů registračních značek a jejich uložení do odpovídajících obrázků náležejících danému znaku,
- **sort-to-categories** – rozřídění nasbírané datové sady každého znaku do tří kategorií dle kvality obrazu.

Výstupem těchto aplikací je datová sada popsaná v sekci 4.3.

Vstupem aplikace **extract-letters** je adresář obsahující výřezy registračních značek. Je nutné, aby byly tyto výřezy větší než je samotná registrační značka, aby při extrakci znaků nebyla překročena hranice výřezu. Tato aplikace představuje ulehčení pro tvorbu datové sady, ale vyžaduje přímou interakci s uživatelem. Na obrazovku jsou postupně ukazovány výřezy registračních značek. Uživatel musí manuálně zadat pomocí myši středy všech symbolů značky a poté zadat na klávesnici jednotlivé symboly. Po stisknutí klávesy enter nebo mezerníku dojde k vyříznutí všech znaků a jejich upravení na fixní velikost 20×40 pixelů. Poté jsou tyto symboly uloženy do příslušných obrázků náležejících daným znakům do adresáře *letter-images* (viz obrázek 4.5). Současně je vytvářena i negativní datová sada. Pro každý extrahovaný symbol je jeho pozice v původním výřezu registrační značky začerněna a poté je tento upravený výřez uložen do odpovídajícího adresáře negativní datové sady daného znaku. Je-li původní výřez registrační značky zpracován, je smazán, uživatel tedy může práci na tvorbě datové sady přerušit, vrátit se k ní později a pokračovat od místa, kde skončil. Aplikace se spouští příkazem:

```
./extract-letters -d <directory with LP>
```

Datová sada znaků byla vytvořena ze snímků pořízených na různých místech a za různých podmínek. Nasbírané znaky se lišily osvětlením, sklonem i kvalitou obrazu. Proto byla vytvořena aplikace **sort-to-categories**. Tato aplikace třídí datovou sadu daného znaku do tří kategorií – dobré, střední a špatné. Uživateli je ukázán celý snímek obsahující danou datovou sadu. V tomto snímku je právě posuzovaný znak uzavřen do zeleného obdélníku. Uživatel pro aktuální znak zadá 1 v případě, že se jedná o znak dobré kvality, 2 v případě střední kvality a 3 v případě špatné kvality. Výsledné datové sady jsou uloženy do adresáře *categories* a každý obraz obsahuje příponu *-1*, *-2* a *-3* v závislosti na tom, o jakou kategorii se jedná. Aplikace se spouští příkazem:

```
./sort-to-categories -d <directory with positive letter samples>
```

6.3 Tvorba anotací testovací datové sady

Aby bylo možné vytvořit automatické vyhodnocení úspěšnosti celého systému, bylo třeba získat anotace ke vstupním snímkům s informacemi o pozicích registračních značek a jaké symboly jsou na nich napsány. K tomu byla vytvořena aplikace **create-annotation**, která umožňuje uživateli vytvořit soubor s anotacemi.

Vstupním parametrem aplikace je adresář obsahující snímky z dopravy testovací datové sady. Postupně jsou na obrazovku počítače zobrazovány snímky a uživatel klikne vždy na

levý horní okraj začátku znaků registrační značky a poté na pravý dolní okraj (viz obrázek 6.2). Následně zadá na klávesnici znaky registrační značky. Pro zadání další značky v rámci stejného snímku je potřeba stisknout na klávesnici mezerník nebo enter v případě přechodu na další snímek. Po zpracování daného snímku dojde k jeho smazání. Tímto je možné práci v průběhu tvorby anotací přerušit a vrátit se k ní později na stejné místo, kde byla dříve přerušena. Anotace jsou vypisovány na standardní výstup terminálu v podobě:

```
NAME N x1 y1 x2 y2 ...,
```

kde *NAME* je název obrázku, *N* udává počet registračních značek v obraze, *x1* a *y1* jsou hodnoty souřadnice levé hranice znaků značky a *x2* a *y2* hodnoty souřadnice pravé hranice znaků značky.

Příkaz spuštění aplikace:

```
./create-annotation -d <directory>
```



Obrázek 6.2: Ukázka zadání souřadnic při anotaci registrační značky.

6.4 Aplikace pro vyhodnocení úspěšnosti

Pro automatické vyhodnocení úspěšnosti byly vytvořeny dvě aplikace:


- **lp-evaluation** – vyhodnocení natrénovaného kaskádového klasifikátoru pro detekci registračních značek
- **system-evaluation** – vyhodnocení výsledného systému, úspěšnost nalezení registračních značek a rozpoznání znaků značky

Vstupem aplikace **lp-evaluation** je cesta k souboru s anotacemi. Postupně jsou v každém anotovaném snímku nalezeny všechny pozice registračních značek pomocí kaskádového klasifikátoru a dochází k jejich porovnání s anotovanými pozicemi. Anotovaná pozice je dána úsečkou od levého horního kraje značky po pravý dolní okraj a kaskádový klasifikátor poskytuje výstupy v podobě obdélníku. Kontrolují se pak následující možnosti:

- úsečka je uvnitř některého obdélníku – správně nalezená registrační značka (TP – true positive),

- úsečka není uvnitř žádného obdélníku – registrační značka nebyla nalezena (FN – false negative),
- uvnitř obdélníku není žádná úsečka – špatně nalezená plocha (FP – false positive).

Tyto možnosti jsou znázorněny i vizuálně na obrázku 6.3. Po zpracování všech obrázků jsou získány počty TP, FP a FN, které jsou vypsány na standardní výstup do terminálu. Dále je vypsán celkový počet registračních značek ve všech snímcích a procentuální úspěšnost jejich nalezení.



Obrázek 6.3: Možnosti umístění anotací vzhledem k nalezeným pozicím registračních značek při vyhodnocení úspěšnosti.

Příkaz spuštění aplikace:

```
./lp-evaluation -a <list with annotations>
```

Druhá aplikace **system-evaluation** slouží k vyhodnocení úspěšnosti celého systému. Po detekci registračních značek následuje vyhledání pozic jednotlivých symbolů značky a rozhodnutí, zda se jedná nebo nejedná o registrační značku. Tímto je vyřazeno mnoho špatně nalezených pozic (FP) a stejným způsobem jako u předchozí aplikace jsou zjištěny hodnoty TP, FP a FN, které jsou následně vypsány do terminálu.

V rámci této aplikace je také provedeno vyhodnocení úspěšnosti rozpoznání znaků registrační značky, které probíhá pouze ve správně nalezených značkách. Postupně jsou porovnávány jednotlivé znaky rozpoznané registrační značky s odpovídajícím řetězcem anotovaného snímku. Zaznamenává se počet chyb v daném řetězci. Jelikož se pro výsledný systém nepodařilo natrénovat klasifikátor všech symbolů abecedy, bylo provedeno dvojí vyhodnocení:

- vyhodnocení v rámci celé abecedy,
- vyhodnocení pouze natrénovaných písmen.

Obě vyhodnocení jsou vypsána na standardní výstup do terminálu a to počtetně i v procentech.

Příkaz spuštění aplikace:

```
./system-evaluation -a <list with annotations> -r <list with results>
```

Kapitola 7

Implementace systému a provedené experimenty

Tato kapitola obsahuje způsob natrénování kaskádového klasifikátoru pro detekci registračních značek a popis implementace lineárního SVM klasifikátoru pro rozpoznání znaků. Je zde představena aplikace výsledného systému. Vše bylo implementováno v C++ za použití knihoven OpenCV a LIBLINEAR. Druhá část kapitoly je zaměřena na popis experimentálních výsledků detektoru registračních značek, klasifikátoru znaků i celého systému.

7.1 Trénování detektoru registračních značek

Pro detekci registračních značek byl zvolen kaskádový klasifikátor (více v sekci 3.1). Aplikace pro trénování klasifikátoru jsou v základu knihovny OpenCV. Byly použity programy **opencv_createsamples** a **opencv_traincascade** [1]. Pro trénování byla zvolena datová sada výřezů popsaná v sekci 4.2.

Příprava vzorků

Program **opencv_createsamples** vytváří pozitivní vzorky z jednoho obrázku či kolekce obrázků. Rozměry vzorků jsou dány ve stejném poměru jako je rozměr registrační značky. Výsledný detektor byl natrénován na minimální velikost značky 60×16 pixelů. Ve výřezech této velikosti zůstanou dostatečné informace o podobě znaků registrační značky.

Vstupem tohoto programu je 2745 výřezů registračních značek, které obsahují soubor s anotacemi v podobě: *cesta-k-obrázku* *N x y šířka výška x y šířka ...*, kde proměnné *x*, *y*, *šířka* a *výška* určují přesnou pozici registrační značky v obraze a proměnná *N* udává počet registračních značek v obraze.

V tomto případě byl program spuštěn s následujícími parametry:

```
./opencv_createsamples
  -info /$PATH/positive-list.dat
  -vec /$PATH/samples.vec
  -w 60 -h 16
  -num 2745
```

Trénování kaskády

Samotné trénování proběhlo spuštěním programu **opencv_traincascade**. Trénování kaskády proběhlo v deseti iteracích a do každé iterace šlo 1000 pozitivních a 1000 negativních vzorků. Pro trénování byl použit algoritmus Gentle AdaBoost a příznaky LBP (local binary pattern).

Použitý příkaz pro spuštění:

```
./opencv_traincascade
  -data /$PATH/classifier
  -vec /$PATH/samples.vec
  -bg /$PATH/negative-list.dat
  -numPox 1000 -numNeg 1000
  -numStages 10
  -w 60 -h 16
  -featureType LBP
```

7.2 Trénování lineárního klasifikátoru SVM pro rozpoznání znaků

Pro vytvoření klasifikátoru znaků byl zvolen lineární klasifikátor SVM knihovny LIBLINEAR [10]. Jelikož nebylo možné nasbírat na území Brna dostatečný počet vzorků všech znaků abecedy používaný v registračních značkách, byl výsledný SVM klasifikátor natrénován pouze na všechny číslice a znaky A a B.

Tréninkem klasifikátoru se zabývá aplikace **trainSVM**. Vstupním parametrem je odkaz na adresář obsahující datovou sadu znaků popsanou v sekci 4.3 a soubor obsahující počty extrahovaných prvků všech symbolů. Pro každý znak datové sady dojde k extrakci příznaků (více v podsekcí 5.2.4). Po naplnění pole příznaků všemi trénovacími daty je zavolána funkce pro natrénování klasifikátoru. Použit byl typ řešení pro multi-třídní klasifikaci MCSVM_CS se stopovacím kritériem 0,00001. Natrénovaný klasifikátor byl uložen do souboru.

Aplikace trénování klasifikátoru se spouští s jedním parametrem, udávajícím cestu k pracovnímu adresáři. Tento adresář obsahuje datovou sadu znaků popsanou v sekci 4.3 a soubor obsahující počty extrahovaných prvků pro každý znak. Výstupem je soubor *classifier*, ve kterém je uložen natrénovaný SVM klasifikátor.

Příkaz spuštění aplikace:

```
./trainSVM -d <directory with letters for training>
```

Současně byla vytvořena také aplikace pro vyhodnocení klasifikátoru **testSVM**. Jejím vstupem je opět pracovní adresář, ve stejné podobě jako u aplikace trénování, který obsahuje znaky určené pro otestování klasifikátoru. Výstupem je výpis úspěšnosti každého znaku. Tento výpis obsahuje počty true positives a false positives, úspěšnosti v procentech a celkový počet testovaných znaků. Dalším výstupem je tabulka confusion matrix. Více o výsledcích klasifikátoru znaků v sekci 7.6.

Příkaz spuštění aplikace:

```
./testSVM -d <directory with letters for testing>
```

7.3 Výsledný systém detekce a rozpoznání registrační značky vozidla

Cílem této práce bylo vytvořit aplikaci pro detekci a rozpoznání registračních značek vozidel. Byla implementována aplikace **recognize**, ve které došlo k využití natrénovaného kaskádového klasifikátoru pro detekci registračních značek a lineárního SVM klasifikátoru pro rozpoznání znaků.

Vstupem celého systému je adresář se snímky z dopravy nebo přímo jeden konkrétní snímek. V případě vstupu formou cesty k adresáři snímků jsou postupně načítány jednotlivé obrázky a pomocí natrénovaného kaskádového klasifikátoru jsou v nich vyhledány pozice registračních značek. Tato nalezená místa obsahují mnoho registračních značek, ale také se mezi nimi vyskytují falešné detekce, které je nutné odstranit. Tyto falešné detekce jsou odstraněny pomocí analýzy obsahu všech výřezů původního snímku.

Vyřazení falešných detekcí probíhá na základě vyhledání pozic znaků registrační značky ve všech výřezech. V rámci práce byly implementovány dvě metody vyhledání pozic znaků – detekce MSER regionů a hledání blobů (více v podsekcí 5.2.2). Volba metody probíhá pomocí vstupního parametru `-t`. Pokud tento parametr není zadán, je automaticky zvolena metoda hledání blobů. Všechny nalezené potenciální pozice znaků jsou posuzovány, zda se opravdu jedná o symboly registrační značky. Jsou kontrolovány rozměry symbolů, jejich šířka, výška a poměry obou hodnot. Dále se sleduje, zda jsou symboly v linii aj. Symboly, které nespĺňují požadovaná kritéria, jsou vyřazena z posuzování. Vlivem rozostření obrazu mohou být symboly detekovány jako jeden, proto je-li získaný potenciální symbol velmi široký, dojde k jeho rozdělení na více prvků. Za registrační značku je prohlášen ten výřez, který obsahuje šest nebo sedm symbolů. V případě šesti symbolů dojde k dohledání chybějící pozice.

Všechny vyhledané pozice znaků registrační značky jsou seřazeny od nejlevější po nejpravější. Pro každý symbol je vyříznuto z originálního snímku i jeho nejbližší okolí a poté je výřez upraven na fixní velikost 20×40 pixelů. Pro tento upravený výřez je získán vektor příznaků (více v podsekcí 5.2.4), který je předán funkci pro rozpoznání symbolu registrační značky pomocí natrénovaného SVM klasifikátoru znaků. Funkce vrací symbol s nejvyšší pravděpodobností podobnosti a po rozpoznání všech symbolů je získána samotná podoba registrační značky.

Výstupy aplikace jsou vizuálně zobrazeny do okna počítače (viz 7.1). Výsledné pozice registračních značek a jejich symbolů jsou vypisovány na standardní výstup do terminálu v podobě: `x y width height ---> LP`, kde první čtyři hodnoty určují přesnou pozici registrační značky a `LP` obsahuje řetězec rozpoznávaných symbolů značky. Aplikace také ukládá výstupy do textového souboru jehož název se definuje parametrem `-o`. Není-li název zadán, je soubor pojmenován `output.dat`. Tento soubor je uložen do složky `results`. Obsah textového souboru je formátován v podobě: `img-name N x y w h X . . .`, kde `img-name` je jméno obrázku, `N` udává počet nalezených registračních značek, `x` a `y` udává levý horní roh nalezené registrační značky, `w` a `h` její výšku a šířku a `X` je řetězec rozpoznané registrační značky. Tento soubor je možné použít v aplikaci pro vyhodnocení úspěšnosti celého systému.

Příkaz spuštění aplikace:

```
./recognize -i <image> -d <directory> -t <type=MSER|BLOB>
-o <output file>
```



Obrázek 7.1: Ukázka vizuálního zobrazení výsledků aplikace **recognize**

7.4 Experimentální vyhodnocení detektoru registračních značek

Při snímání dopravy se stává, že část registrační značky je zakryta jiným vozidlem. Pro vyhodnocení úspěšnosti bylo třeba stanovit hranici, které značky budou posuzovány a které ne. Bylo rozhodnuto, že vyhodnocení bude probíhat pouze nad registračními značkami, kde jsou viditelné všechny její symboly.

Detekce registračních značek probíhala pomocí kaskádového klasifikátoru. Při volání funkce `detectMultiScale` knihovny OpenCV bylo nutné specifikovat dva základní parametry vstupu, a to level zamítnutí (`rejectLevel`) a level váhy (`levelWeights`). Pro zvolení vhodných hodnot proběhly experimenty na různých datových sadách. Pro ukázkou jsou v tabulce 7.1 popsány výsledky na datové sadě Úvoz, kdy osa pohledu kamery svírala s vozovkou úhel 47° . Tabulka obsahuje výsledky detektoru při změně parametrů `rejectLevel` a `levelWeights`. Na základě porovnání úspěšnosti a poměru TP/FP byly pro výsledný systém stanoveny následující hodnoty parametrů: `rejectLevel` = 1.3 a `levelWeights` = 6.

levelWeight	rejectLevel	TP	FN	FP	TP/FP	Úspěšnost
5	1,1	136	0	10354	0,013	100,0 %
5	1,2	135	1	5129	0,026	99,3 %
5	1,3	133	3	1666	0,080	97,8 %
5	1,4	117	19	915	0,128	86,0 %
5	1,5	127	9	1284	0,099	93,4 %
6	1,1	136	0	8573	0,016	100,0 %
6	1,2	135	1	4037	0,033	99,3 %
6	1,3	133	3	1056	0,126	97,8 %
6	1,4	112	24	591	0,190	82,4 %
6	1,5	126	10	803	0,157	92,6 %

Tabulka 7.1: Výsledky detekce registračních značek pomocí kaskádového klasifikátoru v závislosti na změně parametrů `rejectLevel` a `levelWeight`. Celkem bylo 136 posuzovaných registračních značek z datové sady Úvoz, kde obraz byl snímán pod úhlem 47° . Zkratky TP, FP a FN jsou vysvětleny v sekci 6.4.


Vyhodnocení úspěšnosti registračních značek probíhalo na třech datových sadách popsaných v sekci 4.1. Dosažené výsledky jsou znázorněny v tabulce 7.2. Výsledky se liší v závislosti na vzdálenosti od snímávaných vozidel a úhlu pohledu kamery. Na datové sadě Vaňkovka je vidět, že zlomový úhel, kdy detekce selhává, je zhruba 55° .

Datová sada Úvoz					
Pozice kamery	Celkem	TP	FN	FP	Úspěšnost
47°	136	133	3	1056	97,8 %
50°	238	220	18	1313	92,4 %
63°	218	211	7	1476	96,8 %
72°	42	39	3	188	92,9 %

Datová sada Zvonařka					
Pozice kamery	Celkem	TP	FN	FP	Úspěšnost
45°	233	217	16	639	93,1 %
62°	193	161	32	651	83,4 %
72°	193	175	18	489	90,7 %

Datová sada Vaňkovka					
Pozice kamery	Celkem	TP	FN	FP	Úspěšnost
5°	281	232	49	763	82,6 %
10°	244	167	77	298	68,4 %
44°	260	246	14	927	94,6 %
52°	235	205	30	625	87,2 %
59°	347	188	159	867	54,2 %

Tabulka 7.2: Výsledky detekce registračních značek kaskádovým klasifikátorem.



Obrázek 7.2: Ukázka snímků datových sad – Úvoz (a-d), Zvonařka (e-g), Vaňkovka (h-l).

7.5 Experimentální vyhodnocení detekce registračních značek po odstranění falešných detekcí

Po detekci registračních značek natrénovaným kaskádovým klasifikátorem probíhala analýza všech získaných ploch a rozhodnutí, zda se jedná o značku či chybně nalezenou plochu. Plocha byla prohlášena za registrační značku, pokud v ní byly nalezeny pozice symbolů značky. Vyhledání pozic znaků proběhlo dvěma způsoby – hledáním blobů a hledáním MSER regionů. Výsledky byly opět vyhodnoceny na testovacích datových sadách zmíněných v předchozí sekci a jsou zobrazeny v tabulce 7.3.

Datová sada Úvoz			
Pozice kamery	Úspěšnost kaskádového klasifikátoru	Úspěšnost po nalezení pozic metodou MSER	Úspěšnost po nalezení pozic metodou blobů
47°	97,8 %	69,9 %	63,2 %
50°	92,4 %	61,8 %	76,9 %
63°	96,8 %	67,9 %	88,5 %
72°	92,9 %	57,1 %	45,2 %

Datová sada Zvonařka			
Pozice kamery	Úspěšnost kaskádového klasifikátoru	Úspěšnost po nalezení pozic metodou MSER	Úspěšnost po nalezení pozic metodou blobů
45°	93,1 %	74,7 %	74,2 %
62°	90,7 %	71,5 %	83,4 %
72°	90,7 %	64,8 %	76,2 %

Datová sada Vaňkovka			
Pozice kamery	Úspěšnost kaskádového klasifikátoru	Úspěšnost po nalezení pozic metodou MSER	Úspěšnost po nalezení pozic metodou blobů
5°	82,6 %	34,5 %	55,5 %
10°	68,4 %	18,9 %	33,6 %
44°	94,6 %	66,5 %	60,4 %
52°	87,2 %	54,5 %	36,2 %
59°	54,2 %	24,5 %	20,2 %

Tabulka 7.3: Výsledky detekce registračních značek po odstranění falešných detekcí.

Na uvedených výsledcích je zřejmé, že hledání pozic symbolů registrační značky je úzkým hrdlem systému. V tomto kroku došlo k úspěšnému odstranění falešných detekcí, ale v mnoha registračních značkách nebyly pozice symbolů nalezeny a ty byly poté odstraněny z posuzování. Vyřazeny byly ve většině případů registrační značky, jejichž symboly byly vlivem pohybu auta rozmazány. Obě metody poskytují podobné výsledky. Na datové sadě Vaňkovka je vidět, že pro malé úhly pohledu kamery ke směru vozovky pracuje lépe metoda hledání blobů, zatímco při větším úhlu poskytuje lepší výsledky metoda detekce

MSEER. Metoda hledání blobů funguje lépe ve snímcích dopravy, kde jsou registrační značky ve větším rozlišení. To je například v datové sadě Zvonařka s úhly kamery k vozovce 62° a 72°. Detekce často selhává na snímcích, které jsou vlivem pohybu vozidel rozostřené. Lepší úspěšnost by byla zaručena lepší kvalitou vstupních snímků.

7.6 Experimentální vyhodnocení klasifikace znaků

Vyhodnocení úspěšnosti natrénovaného SVM klasifikátoru probíhalo nad testovací datovou sadou znaků tvořenou výřezy jednotlivých znaků z registračních značek. Tato sada byla vytvořena ze testovací datové sady stejným způsobem jako trénovací datová sada. Výsledky byly získány skriptem `testSVM` popsáním v sekci 7.2.

Úspěšnost klasifikace znaků je znázorněna na tabulce 7.4. Graf zobrazuje procentuální úspěšnost rozpoznání všech natrénovaných znaků na dané testovací sadě. Je vidět, že nejlepší úspěšnosti poskytují znaky, které jsou svým vzhledem poměrně unikátní, jako jsou např. symboly A, 7 a 4. Naopak velmi malé úspěšnosti poskytují 6, 8 a B, které jsou si velmi podobné. Výsledky klasifikátoru byly také zaneseny do tzv. matice záměn (confusion matrix), ta je zobrazena v tabulce 7.5. Tato matice obsahuje ke každému rozpoznávanému znaku informaci o jeho úspěšnosti rozpoznání, kolik prvků bylo rozpoznáno správně, a se kterými symboly docházelo k nejčastějším záměnám.

Symbol	TP	FP	Celkem	Úspěšnost
0	70	2	72	97,2 %
1	108	5	113	95,6 %
2	77	2	79	97,4 %
3	81	3	84	96,4%
4	74	1	75	98,7 %
5	100	2	102	98,0 %
6	89	8	97	91,8 %
7	117	1	118	99,2 %
8	90	12	102	88,2 %
9	77	3	80	96,3 %
A	12	0	12	100,0 %
B	140	12	152	92,1 %

Tabulka 7.4: Výsledky klasifikátoru znaků aplikací testSVM

	0	1	2	3	4	5	6	7	8	9	A	B
0	70	0	0	0	0	0	0	0	0	0	1	1
1	0	108	0	2	0	0	0	0	0	0	1	2
2	0	0	77	1	0	0	1	0	0	0	0	0
3	0	1	0	81	1	0	0	1	0	0	0	0
4	0	0	0	0	74	1	0	0	0	0	0	0
5	0	0	0	0	0	100	0	0	0	2	0	0
6	0	1	0	0	0	3	89	0	0	0	0	4
7	0	0	1	0	0	0	0	117	0	0	0	0
8	1	1	1	0	4	0	0	0	90	0	2	3
9	0	0	1	0	0	0	0	0	1	77	0	1
A	0	0	0	0	0	0	0	0	0	0	12	0
B	0	0	0	1	0	1	1	0	9	0	0	140

Tabulka 7.5: Matice záměn výsledků SVM klasifikátoru

7.7 Experimentální vyhodnocení rozpoznání registračních značek

Po sestavení celého systému zbývá vyhodnotit poslední část, a to úspěšnost rozpoznání registračních značek vozidel. Vyhodnocení probíhalo dvojí:

- úspěšnost rozpoznání všech symbolů abecedy a
- úspěšnost rozpoznání natrénovaných symbolů abecedy.


Pro úplnost jsou zde uvedeny obě varianty, ale pro vyhodnocení úspěšnosti celého systému jsou uvažovány výsledky rozpoznání pouze natrénovaných symbolů abecedy.

Hlavním kritériem pro vyhodnocení je počet chyb v rozpoznávaném řetězci znaků registrační značky. Výsledky vyhodnocení na datové sadě Zvonařka jsou zobrazeny v tabulce 7.6 a graficky formou histogramů na obrázcích 7.3 a 7.4. Vyhodnocení proběhlo také na datové sadě Úvoz. Výsledky jsou uvedeny v tabulce 7.7 a graficky na obrázcích 7.5 a 7.6.

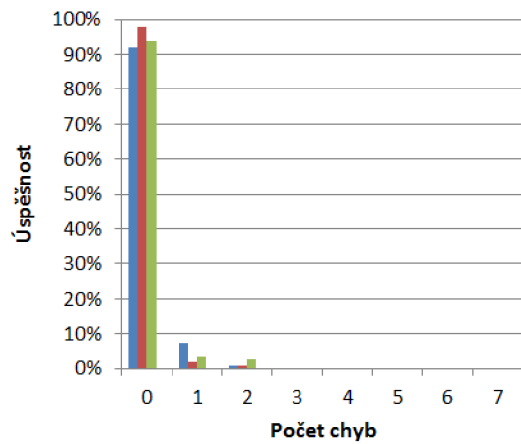
Datová sada Zvonařka metoda hledání blobů						
Počet chyb	Vyhodnocení nad celou abecedou			Vyhodnocení natré- novaných znaků		
	45°	62°	72°	45°	62°	72°
0	76,9 %	84,6 %	68,7 %	91,9 %	97,7 %	93,9 %
1	18,5 %	12,0 %	23,8 %	7,5 %	1,7 %	3,4 %
2	4,6 %	1,1 %	5,4 %	0,6 %	0,6 %	2,7 %
3	0 %	2,3 %	1,4 %	0 %	0 %	0 %
4	0 %	0 %	0,7 %	0 %	0 %	0 %
5	0 %	0 %	0 %	0 %	0 %	0 %
6	0 %	0 %	0 %	0 %	0 %	0 %
7	0 %	0 %	0 %	0 %	0 %	0 %

Datová sada Zvonařka metoda detekce MSER regionů						
Počet chyb	Vyhodnocení nad celou abecedou			Vyhodnocení natré- novaných znaků		
	45°	62°	72°	45°	62°	72°
0	67,8 %	81,9 %	61,6 %	83,9 %	98,7 %	87,2 %
1	17,2 %	13,8 %	28,0 %	11,5 %	4,3 %	8,8 %
2	9,8 %	2,2 %	5,6 %	1,7 %	0 %	0,8 %
3	2,3 %	2,2 %	0,8 %	0,6 %	0 %	2,4 %
4	0 %	0 %	3,2 %	0,1 %	0 %	0 %
5	1,7 %	0 %	0 %	0,6 %	0 %	0 %
6	0,6 %	0 %	0 %	0,6 %	0 %	0,8 %
7	0,6 %	0 %	0,8 %	0 %	0 %	0 %

Tabulka 7.6: Výsledky rozpoznání registračních značek pro datovou sadu Zvonařka.




(a) Vyhodnocení nad celou abecenou

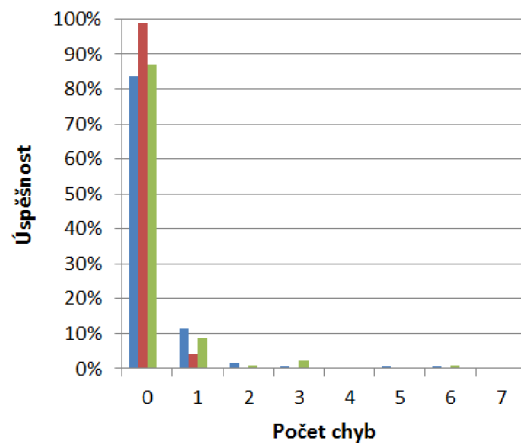


(b) Vyhodnocení natrénovaných znaků

Obrázek 7.3: Vyhodnocení rozpoznání registračních značek na datové sadě Zvonařka za použití metody hledání blobů pro nalezení pozic symbolů. Jednotlivé úhly pohledu kamery jsou v grafu znázorněny barevně – 45° (modrá), 62° (červená), 72° (zelená).



(a) Vyhodnocení nad celou abecenou




(b) Vyhodnocení natrénovaných znaků

Obrázek 7.4: Vyhodnocení rozpoznání registračních značek na datové sadě Zvonařka za použití metody detekce MSER regionů pro nalezení pozic symbolů. Jednotlivé úhly pohledu kamery jsou v grafu znázorněny barevně – 45° (modrá), 62° (červená), 72° (zelená).


Datová sada Úvoz metoda hledání blobů								
Počet chyb	Vyhodnocení nad celou abecedou				Vyhodnocení natré- novaných znaků			
	47°	50°	63°	72°	47°	50°	63°	72°
0	58,1 %	67,8 %	67,9 %	47,4 %	88,4 %	92,9 %	86,0 %	68,4 %
1	39,5 %	27,9 %	26,9 %	31,6 %	9,3 %	6,6 %	10,9 %	10,5 %
2	1,2 %	3,8 %	2,1 %	10,5 %	2,3 %	0 %	0 %	21,1 %
3	1,2 %	0 %	0,5 %	5,3 %	0 %	0 %	1,6 %	0 %
4	0 %	0 %	1 %	0 %	0 %	0 %	1,0 %	0 %
5	0 %	0 %	1 %	5,3 %	0 %	0 %	0 %	0 %
6	0 %	0 %	0 %	0 %	0 %	0,5 %	0,5 %	0 %
7	0 %	0,5 %	0,5 %	0 %	0 %	0 %	0 %	0 %

Datová sada Úvoz metoda detekce MSER regionů								
Počet chyb	Vyhodnocení nad celou abecedou				Vyhodnocení natré- novaných znaků			
	47°	50°	63°	72°	47°	50°	63°	72°
0	58,1 %	67,8 %	67,9 %	47,4 %	86,3 %	89,1 %	85,8 %	66,7 %
1	39,5 %	27,9 %	26,9 %	31,6 %	6,2 %	4,8 %	8,8 %	20,8 %
2	1,2 %	3,8 %	2,1 %	10,5 %	1,1 %	0 %	1,4 %	4,2 %
3	1,2 %	0 %	0,5 %	5,3 %	2,1 %	0,7 %	0 %	0 %
4	0 %	0 %	1 %	0 %	2,1 %	0 %	2,7 %	8,3 %
5	0 %	0 %	1 %	5,2 %	1,1 %	2,7 %	1,4 %	0 %
6	0 %	0 %	0 %	0 %	1,1 %	2,7 %	0 %	0 %
7	0 %	0,5 %	0,5 %	0 %	0 %	0 %	0 %	0 %

Tabulka 7.7: Výsledky rozpoznání registračních značek pro datovou sadu Úvoz.




(a) Vyhodnocení nad celou abecenou




(b) Vyhodnocení natrénovaných znaků

Obrázek 7.5: Vyhodnocení rozpoznání registračních značek na datové sadě Úvoz za použití metody hledání blobů pro nalezení pozic symbolů. Jednotlivé úhly pohledu kamery jsou v grafu znázorněny barevně – 47° (modrá), 50° (červená), 63° (zelená), 72° (fialová).



(a) Vyhodnocení nad celou abecenou



(b) Vyhodnocení natrénovaných znaků

Obrázek 7.6: Vyhodnocení rozpoznání registračních značek na datové sadě Úvoz za použití metody detekce MSER regionů pro nalezení pozic symbolů. Jednotlivé úhly pohledu kamery jsou v grafu znázorněny barevně – 47° (modrá), 50° (červená), 63° (zelená), 72° (fialová).

Kapitola 8

Závěr

V rámci této práce byl navrhnout a implementován systém detekce a rozpoznání registračních značek vozidel ve snímcích z dopravy. Algoritmus je schopen nalézt registrační značky o minimální velikosti 60×16 px v jakémkoli místě vstupního snímku. Tato práce počítá s dobrou kvalitou vstupních snímků, které jsou ostré nebo mírně rozostřené a bez šumu v podobě deště a sněhu. Detekce je zaměřena na značky nejčastějšího rozměru 520×110 mm a uvažuje znečištění a drobná poškození samotné desky.

Pro účely práce byla pořízena rozsáhlá datová sada. Bylo natočeno celkem 35 videí z různých míst města Brna. Trénovací datová sada obsahuje 2745 snímků dopravy a 2814 výřezů registračních značek. Datová sada obsahuje pozitivní a negativní snímky dopravy, výřezy registračních značek a negativní výřezy obsahující textury silnice, vegetace, karoserií aj. Pořízené datové sady neobsahovaly dostatek znaků celé abecedy, proto proběhlo natrénování klasifikátoru na všechny číslice a znaky A a B. Datová sada pro trénování klasifikátoru znaků obsahuje průměrně 1100 prvků na jeden natrénovaný symbol abecedy.

Navržený algoritmus rozděluje činnost do tří kroků – detekce registračních značek, nalezení pozic symbolů a rozpoznání symbolů. Pro detekci registračních značek byl natrénován kaskádový klasifikátor. Nalezení pozic symbolů bylo implementováno pomocí dvou metod – detekce MSER regionů a hledání blobů. Rozpoznání symbolů probíhá pomocí natrénovaného lineárního SVM klasifikátoru. Celý systém byl vyhodnocen na třech datových sadách obsahujících celkem 2620 registračních značek ve více než 1800 snímcích dopravy.

Bylo provedeno několik experimentů pro zjištění úspěšnosti navržené metody. Na datové sadě Úvoz obsahující čtyři různé pohledy kamery ke směru vozovky byla dosažena úspěšnost detekce registračních značek pomocí kaskádového klasifikátoru 92,9 % - 97,8 %. Na datové sadě Vaňkovka byl hledán zlomový úhel, kdy detekce začne selhávat. Tento úhel pohledu kamery ku směru vozovky je zhruba 55° . Zlomový úhel se liší v závislosti na nastavení kamery, přiblížení obrazu, umístění aj. Na jiných datových sadách, kde bylo zvoleno větší přiblížení, zvládá systém i úhly přes 70° .

Kaskádový klasifikátor generuje mnoho falešných detekcí, které jsou zamítnuty v následujícím kroku hledání pozic symbolů registrační značky. Obě implementované metody poskytují podobné výsledky. Na datové sadě Vaňkovka poskytuje metoda blobů lepší výsledky pro malé úhly pohledu kamery ku směru vozovky, zatímco při větším úhlu poskytuje lepší výsledky metoda detekce MSER regionů. Metoda blobů pracuje lépe nad snímky dopravy, kde jsou registrační značky ve větším rozlišení. To je například na datové sadě Zvonařka s úhly pohledu kamery k vozovce 62° a 72° . Registrační značky jsou vlivem většího úhlu pohledu kamery rozostřené a pozice symbolů se nepodaří vždy objevit. Po odstranění falešných detekcí metodou hledání blobů dosahuje systém úspěšnosti až 88,5 %. Úspěšnost

metody detekce MSER regionů je až 74,7 %.

Natrénovaný klasifikátor znaků byl experimentálně vyhodnocen na testové sadě obsahující vyextrahované znaky registračních značek. Na těchto datech dosahoval úspěšnosti od 88,2 % až po 100 %. Nejlepší úspěšnosti poskytují znaky, které jsou svým vzhledem unikátní, jako jsou např. symboly A, 4 a 7. Naopak nižší úspěch vykazovaly znaky 6, 8 a B, které jsou si velmi podobné.

Poslední experiment se týkal vyhodnocení rozpoznání registračních značek. Hlavním kritériem pro vyhodnocení byl počet chyb v rozpoznání řetězci znaků. Pro všechny pohledy kamery na datové sadě Zvonařka bylo bez chyby rozpoznáno průměrně 94,5 % všech nalezených registračních značek. Jednu chybu obsahovalo 4,2 % značek a dvě chyby 1,3 %. Tyto výsledky poskytovaly pozice symbolů registrační značky nalezené metodou blobů. Metoda detekce MSER regionů poskytovala na stejné datové sadě průměrnou úspěšnost 89,9 % rozpoznání celého řetězce bez chyby.

Budoucí práce bude zaměřena na získání pozic písmen registrační značky, které je nejužším hrdlem celého systému. V průběhu hledání pozic je správně odstraněno mnoho falešně nalezených ploch, ale také je zamítnuto poměrně velké procento správně nalezených registračních značek. Dále by bylo možné rozšířit pro detekci a rozpoznání registrační značky vozidla za deště či lehkého sněžení.

S touto prací jsem se zúčastnila Studentské konference inovací, technologií a vědy v IT Excel@FIT 2015. Práce byla ohodnocena 4. místem v kategorii Inovační potenciál.

Literatura

- [1] Cascade Classifier Training.
http://docs.opencv.org/doc/user_guide/ug_traincascade.html, [cit. 2015-01-06].
- [2] Česká republika. Vyhláška Ministerstva dopravy a spojů o registraci vozidel 243/2001 Sb. <http://aplikace.mvcr.cz/sbirka-zakonu/ViewFile.aspx?type=c&id=3670>.
- [3] Ashtari, A. H.; Nordin, M. J.; Kahaki, S. M. M.: A new reliable approach for Persian license plate detection on colour images. In *ICEEI*, 2011, s. 1–5.
- [4] Cika, P.; Zukal, M.; Sebela, M.: Detection and Recognition of License Plates of Czech Vehicles. In *ElektroRevue*, ročník 2, December 2011, ISSN 1213-1539, doi:doi.
- [5] Diaz, J. C. T.; Houben, Q.; Czyz, J.; aj.: A Camera Auto-calibration Algorithm for Realtime Road Traffic Analysis. In *VISAPP (1)*, 2009, ISBN 978-989-8111-69-2, s. 626–631.
- [6] Duan, T. D.; Duc, D. A.; Du, T. L. H.: Combining Hough Transform and Contour Algorithm for detecting Vehicles Licence Plates. In *International Symposium on Intelligent Multimedia, Video and Speech Processing*, 2004, s. 747–750.
- [7] Dubská, M.; Sochor, J.; Herout, A.: Automatic Camera Calibration for Traffic Understanding. In *Proceedings of BMVC 2014*, 2014, s. 1–10.
- [8] Dubská, M.; Herout, A.: Real Projective Plane Mapping for Detection of Orthogonal Vanishing Points. In *Proceedings of the British Machine Vision Conference*, BMVA Press, 2013.
- [9] Faigl, J.; Svoboda, L.; Žoldák, M.: *Support Vector Machine*. 2001.
URL http://cmp.felk.cvut.cz/cmp/courses/recognition/zapis_prednasky/zapis_01/8-9-11/rpz8-9-11.pdf
- [10] Fan, R.-E.; Chang, K.-W.; Hsieh, C.-J.; aj.: LIBLINEAR: A Library for Large Linear Classification. *Journal of Machine Learning Research*, ročník 9, 2008: s. 1871–1874.
- [11] Forssén, P.-E.: Maximally Stable Colour Regions for Recognition and Matching. In *IEEE Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, Minneapolis, USA: IEEE, June 2007.
- [12] Li, B.; Tian, B.; Li, Y.; aj.: Component-Based License Plate Detection Using Conditional Random Field Model. *IEEE Transactions on Intelligent Transportation Systems*, ročník 14, č. 4, 2013: s. 1690–1699.

- [13] Manzanera, A.: Sigma-Delta Background Subtraction and the Zipf Law. In *Progress in Pattern Recognition, Image Analysis and Applications (CIARP'07)*, ročník 4756, Lecture Notes in Computer Science - Springer Verlag, Nov. 2007, s. 42–51.
- [14] Matas, J.; Chum, O.; Urban, M.; aj.: Robust Wide Baseline Stereo from Maximally Stable Extremal Regions. In *In British Machine Vision Conference*, 2002, s. 384–393.
- [15] Musoromy, Z.; Bensaali, F.; Ramalingam, S.; aj.: Comparison of real-time DSP-based edge detection techniques for license plate detection. In *Information Assurance and Security (IAS), 2010 Sixth International Conference on*, Aug 2010, s. 323–328.
- [16] Musoromy, Z.; Ramalingam, S.; Bekooy, N.: Edge detection comparison for license plate detection. In *Control Automation Robotics Vision (ICARCV), 2010 11th International Conference on*, Dec 2010, s. 1133–1138.
- [17] Neumann, L.: Vyhledání a rozpoznání textu v obrazech reálných scén, diplomová práce, Praha, ČVUT. 2010 [cit. 2015-03-29].
- [18] Nijhuis, J.; ter Brugge, M.; Helmholt, K.; aj.: Car license plate recognition with neural networks and fuzzy logic. In *Neural Networks, 1995. Proceedings., IEEE International Conference on*, ročník 5, Nov 1995, s. 2232–2236 vol.5.
- [19] Sochor, J.: *Analýza dopravy z videa*. Diplomová práce, Vysoké Učení Technické v Brně, 2014.
- [20] Vapnik, V. N.: *The Nature of Statistical Learning Theory*. 1995, ISBN 0-387-94559-8.
- [21] Viola, P.; Jones, M.: Rapid object detection using a boosted cascade of simple features. In *Accepted Conference on Computer Vision and Pattern Recognition*, 2001, s. 511–518.
- [22] Wang, W.; Jiang, Q.; Zhou, X.; aj.: Car license plate detection based on MSER. In *Consumer Electronics, Communications and Networks (CECNet), 2011 International Conference on*, April 2011, s. 3973–3976.
- [23] Zhou, W.; Li, H.; Lu, Y.; aj.: Principal Visual Word Discovery for Automatic License Plate Detection. *IEEE Transactions on Image Processing*, ročník 21, č. 9, 2012: s. 4269–4279.

Příloha A

Seznam použitých zkratk

RZ Registrační značka

TP True Positive

FP False Positive

TN True Negative

FN False Negative

MSER Maximally Stable Extremal Region

SVM Support Vector Machine

LBP Local Binary Pattern

CRF Conditional Random Field

PVW Principal Visual Word

NCC Normalized Cross Correlation

DTCNN Discrete-Time Cellular Neural Networks

MLPNN Multi-Layer Perceptron Neural Network

SIFT Scale-Invariant Feature Transform

SUSAN Smallest Univalued Segment Assimilating Nucleus

Příloha B

Obsah DVD

Obsah DVD č. 1:

- Technická zpráva
 - Technická zpráva ve formátu PDF
 - Zdrojové kódy
- Prezentační materiály
 - Plakát
 - Video
- Zdrojové kódy
 - Systém detekce a rozpoznání RZ vozidla
 - Pomocné programy
- Trénovací datová sada
 - Datová sada originálních snímků
 - Datová sada negativních snímků
 - Sada pozitivních výřezů RZ
 - Sada negativních výřezů RZ
 - Datová sada znaků
 - Roztříděná datová sada znaků
 - Negativní datová sada znaků

Obsah DVD č. 2:

- Testovací datová sada
 - Datová sada Úvoz
 - Datová sada Vaňkovka
 - Datová sada Zvonařka