




VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**
ÚSTAV AUTOMATIZACE A MĚŘICÍ TECHNIKY
FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF CONTROL AND INSTRUMENTATION

ROZPOZNÁVÁNÍ SPZ

LPR RECOGNITION

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Ondřej Trkal

VEDOUČÍ PRÁCE

SUPERVISOR

Ing. Karel Horák, Ph.D.

BRNO 2016



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav automatizace a měřicí techniky

Diplomová práce

magisterský navazující studijní obor **Kybernetika, automatizace a měření**

Ústav automatizace a měřicí techniky

Student: Bc. Ondřej Trkal

ID: 146982

Ročník: 2

Akademický rok: 2015/16

NÁZEV TÉMATU:

Rozpoznávání SPZ

POKYNY PRO VYPRACOVÁNÍ:

1. Nastudujte metody zpracování obrazu s přihlédnutím k rozpoznávání SPZ.
2. Pořďte si vlastní galerii snímků vozidel a konsolidujte ji vhodným způsobem s dodanými.
3. Implementujte několik typově rozdílných metod pro lokalizaci oblastí značky a proveďte jejich vyhodnocení na celé galerii.
4. Implementujte několik typově rozdílných metod pro převod obrazu oblastí značky do textové podoby a opět proveďte jejich vyhodnocení na celé galerii.
5. Vyhodnoťte chování jednotlivých kombinací algoritmů detekce SPZ a OCR a zdůrazněte klíčové vlastnosti každého z nich určující podmínky použití.

DOPORUČENÁ LITERATURA:

1. GONZALES, R.C., WOODS, R.R.: Digital image processing (3rd edition). Prentice-Hall, Inc., 2008. 954 pages. ISBN 978-0131687288.
2. YOUNG, I.T., GERBRANDS, J.J., VLIET, L.J.: Fundamentals of Image Processing. TU Delft, 1998. 113 pages. ISBN 9075691017.
3. SZELINSKI, R.: Computer Vision: Algorithms and Applications. Springer, 2010. ISBN 978-1848829343.

Termín zadání: 8.2.2016

Termín odevzdání: 16.5.2016

Vedoucí práce: Ing. Karel Horák, Ph.D.

Konzultant diplomové práce:

doc. Ing. Václav Jirsík, CSc., předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Fakulta elektrotechniky a komunikačních technologií, Vysoké učení technické v Brně / Technická 3058/10 / 616 00 / Brno

Abstrakt

Diplomová práce se zabývá analýzou a návrhem systému pro automatickou lokalizaci a rozpoznávání státní poznávací značky na snímku. Vstupní snímky pochází z různých zdrojů a obsahují velké scénické i povětrnostní rozdíly. Cílem bylo vytvořit systém schopný najít registrační značku na snímku a rozpoznat její alfanumerický údaj. V diplomové práci je kladen důraz především na analýzu a implementaci lokalizačních a OCR metod. Srovnávány jsou čtyři převzaté lokalizační metody a jedna vlastní. Pro rozpoznávání znaků jsou použity a porovnány tři klasifikátory. Jednotlivé metody jsou otestovány na dostupných reálných datech a vyhodnocovány dle vypočtených hodnotících parametrů. Součástí práce je i srovnání vlastních výsledků a citlivostní analýza navrženého systému.

Klíčová slova

SPZ, státní poznávací značky, automatické rozpoznávání registračních značek, lokalizace, klasifikace, naivní bayesovský klasifikátor, k-NN, srovnání se šablonou, počítačové vidění

Abstract

The thesis deals with analysis and design of system for automatic localization and recognition of the license plate. The input images are from different sources, and contain large scenic and weather variations. The aim was to create a system able to find the licence plate on the image and recognize its alphanumeric figure. In this work, there is a focus on analysis and implementation of localization and optical character recognition methods. One own and four other localization methods are compared. There are also compared three classifiers for optical character recognition. Localization and OCR methods are tested on real data and evaluated in accordance with the calculated evaluation parameters. The work also contains sensitivity analysis of the proposed system.

Keywords

LP, license plates, automatic license plate recognition, localization, classification, Naive Bayesian classifier, k-NN, template matching, computer vision

Bibliografická citace:

TRKAL, O. *Rozpoznávání SPZ*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2016. 88 s. Vedoucí diplomové práce Ing. Karel Horák, Ph.D.

Prohlášení

„Prohlašuji, že svou diplomovou práci na téma Rozpoznávání SPZ jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne: **12. května 2016**

.....
podpis autora

Poděkování

Děkuji vedoucímu diplomové práce Ing. Karlu Horákovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne: **12. května 2016**

.....
podpis autora

Obsah

1	Úvod.....	11
2	Registrační značky a možnosti jejich rozpoznávání	13
2.1	Podoby registračních značek.....	13
2.1.1	Registrační značky v České republice	13
2.1.2	Registrační značky v Evropské unii.....	14
2.1.3	Registrační značky ve světě.....	16
2.1.4	Shrnutí.....	17
2.2	Možnosti automatického rozpoznávání registračních značek.....	18
2.2.1	Možné oblasti využití.....	18
2.2.2	Slabiny systémů	18
2.2.3	Umístění kamery.....	19
3	Databáze snímků s RZ	20
3.1	Vlastní galerie	20
3.1.1	Galerie db_parkoviste_zatazeno	20
3.1.2	Galerie db_parkoviste_slunecno.....	20
3.1.3	Galerie db_slunecno	21
3.1.4	Galerie db_destivo	21
3.1.5	Galerie db_tma.....	22
3.2	Převzaté galerie	22
3.2.1	Galerie mpov_1.....	22
3.2.2	Galerie mpov_2.....	23
3.2.3	Galerie mpov_3.....	23
3.2.4	Galerie camea	23
3.3	Anotátor.....	24
4	Lokalizace registrační značky.....	26
4.1	Rozdělení lokalizačních metod	26
4.2	Metoda Mahini	27
4.3	Metoda Zhai	31
4.4	Metoda Tarabek	33
4.5	Metoda Trkal_bp.....	37
4.6	Metoda Trkal_dp.....	40
4.7	Výstupy lokalizace	42
5	Rozpoznávání znaků.....	43
5.1	Předzpracování výřezu s registrační značkou	44
5.1.1	Korekce kontrastu	44
5.1.2	Korekce natočení	45
5.1.3	Odstranění okrajů.....	46
5.2	Separace znaků.....	47
5.2.1	Separace pomocí geometrických podmínek	47
5.2.2	Separace pomocí amplitudové projekce	48

5.2.3	Normování znaku.....	50
5.3	Klasifikace znaků.....	51
5.3.1	Tréninková množina.....	51
5.3.2	Naivní bayesovský klasifikátor.....	53
5.3.3	Klasifikátor k-NN.....	54
5.3.4	Template matching.....	55
6	Experimentální část.....	57
6.1	Implementace.....	57
6.1.1	Implementace lokalizačních metod.....	57
6.2	Implementace rozpoznávání znaků.....	59
6.3	Testovací skript.....	59
6.4	Testování lokalizace.....	61
6.4.1	Celková úspěšnost lokalizace.....	61
6.4.2	Problémové scény.....	67
6.4.3	Shrnutí lokalizace.....	71
6.5	Testování rozpoznávání znaků.....	71
6.5.1	Celková kvalita rozpoznávání znaků.....	71
6.5.2	Problémové znaky.....	76
6.5.3	Shrnutí klasifikace znaků.....	78
6.6	Citlivostní analýza.....	79
7	Závěr.....	83
7.1	Zhodnocení.....	83
7.2	Budoucí vývoj.....	84

Seznam obrázků

Obr. 2.1: Příklad standardních tabulek	14
Obr. 2.2: Příklady speciálních registračních značek.....	14
Obr. 2.3 Současně používaná podoba RZ ve Francii.....	15
Obr. 2.4 Starší podoby RZ ve Francii, přední (vlevo) a zadní tabulka	15
Obr. 2.5 Německá registrační značka	16
Obr. 2.6 Italská registrační značka.....	16
Obr. 2.7 Podoby belgických registračních značek.....	16
Obr. 2.8 Dánská registrační značka	16
Obr. 2.9 Americké registrační značky	17
Obr. 2.10 Kanadské registrační značky	17
Obr. 2.11 Ruská registrační značka	17
Obr. 3.1: Příklad snímků z databáze db_parkoviste_zatazeno	20
Obr. 3.2: Příklad snímků z databáze db_parkoviste_slunecno	21
Obr. 3.3: Příklad snímků z databáze db_slunecno.....	21
Obr. 3.4: Příklad snímků z databáze db_destivo	21
Obr. 3.5: Příklad snímků z databáze db_tma	22
Obr. 3.6: Příklad snímků z databáze mpov_1	22
Obr. 3.7: Příklad snímků z databáze mpov_2.....	23
Obr. 3.8: : Příklad snímků z databáze mpov_3.....	23
Obr. 3.9: Příklad snímků z databáze camea.....	24
Obr. 3.10: Anotátor, vlevo průběh anotování, vpravo již anotovaná značka	24
Obr. 3.11: Způsob uložení anotací v *.csv souboru.....	25
Obr. 4.1: Ověřovací snímek.....	27
Obr. 4.2: Výsledný obraz po operaci bottom-hat (vlevo) a obraz vertikálních hran	29
Obr. 4.3: Obraz po filtraci šumu (vlevo) a obraz C_1 po konvoluci s jednotkovou maticí	29
Obr. 4.4: Obraz C_2 (vlevo) a obraz C_3 zvýrazňující světlé oblasti	30
Obr. 4.5: Sloučení C_1 , C_2 a C_3 (vlevo), binární maska, obraz kandidátů (vpravo).....	30
Obr. 4.6: Top-hat obraz (vlevo), binární obraz a obraz s odstraněnými detaily (vpravo)	32
Obr. 4.7: Binární maska možných kandidátů (vlevo) a její aplikace.....	33
Obr. 4.8: Obraz vertikálních hran (vlevo) a jeho binární podoba.....	34
Obr. 4.9: Rozdělení oblastí v plovoucím okně, dle kterých se testuje uniformita hustoty vertikálních hran	36
Obr. 4.10: Uložené polohy plovoucích oken po hrubé detekci (vlevo) a po přesné detekci	36
Obr. 4.11: Snímek se zvýšeným kontrastem.....	38
Obr. 4.12: Binární mapa a odpovídající zvýraznění kandidátů pro vyšší práh.....	39
Obr. 4.13: Binární mapa a odpovídající zvýraznění kandidátů pro nižší práh	39
Obr. 4.14: Zleva: obraz po bottom-hat, binární mapa kandidátů, aplikovaná binární mapa na šedotónovém snímku.....	40
Obr. 4.15: Možné vstupy a výstupy z lokalizačního algoritmu	42
Obr. 5.1: Schéma rozpoznávání znaků	43
Obr. 5.2: Příklady možných výstupů z lokalizačního algoritmu	44
Obr. 5.3: Tmavá registrační značka z noci (vlevo), po korekci kontrastu (vpravo)	45
Obr. 5.4: Převodní charakteristika pro vstupní obraz na Obr. 5.3 vlevo	45

Obr. 5.5: Korekce natočení, zleva – prahování, rotace, odstranění okrajů z rotace	46
Obr. 5.6: RZ z Obr. 5.2 - odstranění okrajů s využitím geometrických podmínek	46
Obr. 5.7: Ukázka prahování – nahoře šedotónový obraz, vlevo dole je výsledek adaptivního prahování, vpravo dole prahování pomocí Otsu	47
Obr. 5.8: Separace vyhledáváním znaků, vstup vlevo, vizualizace výstupu vpravo	48
Obr. 5.9: Reálný výstup ze separačního algoritmu využívajícího geometrických podmínek	48
Obr. 5.10: Kolabující separace pomocí geometrických podmínek – vadí spojení 6 a B	48
Obr. 5.11: Kolabující separace pomocí geometrických podmínek – vadí vzájemné spojení znaků nahoře	48
Obr. 5.12: Separace pomocí projekcí, shora vstup, projekce, vizualizace, výstup	49
Obr. 5.13: Kolabující separace projekce – vadí slabé spojení H	50
Obr. 5.14: Kolabující separace projekce – emisní známky nejsou vyfiltrovány	50
Obr. 5.15: Separované znaky před (nahoře) a po (dole) normalizaci	50
Obr. 5.16: Vzory alfanumerických znaků ze zákona č. 243/2001 Sb. – o registraci vozidel.....	52
Obr. 5.17: Příklad znaků z reálných snímků.....	52
Obr. 5.18: Naznačení pohybu plovoucího okna při vytváření příznakového vektoru	53
Obr. 5.19: Klasifikovaný znak pomocí naivního bayesovského klasifikátoru	54
Obr. 5.20: Klasifikovaný znak pomocí k-NN.....	55
Obr. 5.21: Klasifikovaný znak pomocí template matchingu	56
Obr. 6.1: Zobrazení snímku testovacím skriptem	60
Obr. 6.2: Některé chybně detekované registrační značky metodou mahini, správné řešení zeleně, nalezené modře	68
Obr. 6.3: Některé chybně detekované registrační značky metodou tarabek, správné řešení zeleně, nalezené modře	69
Obr. 6.4: Některé chybně detekované registrační značky metodou zahi, správné řešení zeleně, nalezené modře	69
Obr. 6.5: Některé chybně detekované registrační značky metodou trkal_bp, správné řešení zeleně, nalezené modře	70
Obr. 6.6: Některé chybně detekované registrační značky metodou trkal_dp, správné řešení zeleně, nalezené modře	70
Obr. 6.7 Příklad chybně detekovaných znaků naivním bayesovským klasifikátorem ...	77
Obr. 6.8: Příklad chybně detekovaných znaků klasifikátorem k-NN	77
Obr. 6.9: Příklad chybně detekovaných znaků klasifikátorem template matching	78
Obr. 6.10: Originální snímek pro degenerační úpravy	79
Obr. 6.11: Příklad ze sady simulující rotaci, vlevo rotováno o -20° , vpravo o 20°	80
Obr. 6.12: Limitní meze rotace, vlevo rotováno o -12° , vpravo o 11°	80
Obr. 6.13: Příklad ze sady simulující snížení kontrastu, vlevo na 60 %, vpravo na 20 %	81
Obr. 6.14: Limitní meze snížení kontrastu, vlevo na 6 % - klasifikuje i znaky, vpravo na 2 % - nalezne značku, ale znaky nerozpozná správně	81
Obr. 6.15: Příklad ze sady simulující zvýšený šum, vlevo 5 % šumu, vpravo 15 %.....	81
Obr. 6.16: Limitní meze šumu, vlevo 7% šum - klasifikuje i znaky, vpravo 10% - ještě detekuje registrační značku.....	82
Obr. 6.17: Příklad ze sady simulující nepřítomnost registrační značky ve snímku.....	82

1 ÚVOD

Cílem této práce je navrhnout systém pro automatickou detekci a rozpoznávání českých jednořádkových registračních značek. Takových systémů lze využít například pro měření přestupkového jednání řidičů na komunikacích či jako identifikační nástroje ve vjezdových prostorách a mnohé další. Řešení celého komplexního problému rozpoznávání registračních značek závisí na větším množství vnějších parametrů, které ovlivňují vzniklé řešení. Ideální je tyto parametry znát a systém navrhovat na konkrétní řešení. V této práci ovšem bude snaha navrhnout celý systém co nejrobustnější, schopný detekovat značky v různých situacích, ačkoliv lze předpokládat, že kvalita v konkrétních úzkoprofilových případech nebude na nejvyšší možné úrovni.

V kapitole o registračních značkách jsou srovnány jejich různé podoby v České republice, Evropské unii i ve zbytku světa. Porovnává se především grafický vzhled, typ písma i různé způsoby kódování alfanumerických znaků. Zároveň jsou zde rozebrány různé možnosti využití detekčních systémů, jejich slabiny a jejich závislost na poloze snímacího zařízení.

Aby bylo možné celý systém navrhovat a testovat, je k dispozici 735 snímků s registračními značkami. Ty jsou rozděleny do odlišných galerií, jenž jsou v textu charakterizovány detailními údaji, tedy například pořizovacím zařízením, rozlišením, scénickou kompozicí, počasím při snímání a dalšími. Rozdělení fotografií je důležité především z toho důvodu, že lze předpokládat odlišné kvality detekce na různých galeriích. Potom je možné lépe najít problémové scény, na nichž je výhodné metody ladit. Každý dostupný snímek byl zpracován anotátorem, pomocí něhož se označila skutečná pozice registrační značky a zapsal správný registrační kód. Díky tomu bylo možné zautomatizovat závěrečné testování.

Dále jsou v této práci prozkoumány a srovnány různé přístupy pro lokalizaci registračních značek v obraze. Pro hlubší analýzu byly vybrány čtyři metody, které jsou podrobně rozebrány a implementovány pro možnost důkladného testování. Při rozboru metod se kladl důraz především na způsoby nalezení kandidátů registrační značky a na způsoby jejich verifikace. Na základě znalostí získaných z analýzy byla poté navržena vlastní lokalizační metoda.

V části o rozpoznávání znaků je navržen způsob převodu obrazu s registrační značkou na řetězec odpovídajících digitálních znaků. Jedná se o předzpracování registrační značky, separaci znaků a klasifikaci znaků. Pro klasifikaci byl vybrán vhodný způsob kódování obrazu do příznakového vektoru a zároveň byly implementovány tři různé klasifikátory, které vstupní data zařazovaly do jedné z 32 výstupních tříd.

Pro testování byl naprogramován skript, který porovná výstupy z lokalizačních algoritmů a klasifikátorů se správným řešením uloženým v anotačních souborech vytvořených anotátorem. Z výsledných dat potom bylo možné zjistit různé hodnotící

parametry (přesnost, senzitivita, F míra) jednotlivých implementovaných lokalizačních metod, jejich výpočetní náročnost i kvalitu klasifikátorů.

Výsledky jsou vztaženy buď k jednotlivým galeriím, nebo k celé množině dostupných snímků a jsou přehledně zobrazeny v tabulkách, z nichž lze jednoduše porovnávat jednotlivé implementované metody. Srovnává se především počet správně detekovaných registračních značek, počet chybně označených oblastí, počet neoznačených značek i hodnotící parametry. U klasifikátorů se poté porovnávají počty správně rozpoznaných znaků i počty správně rozpoznaných celých registračních značek. Na základě analýzy uvedeného srovnání je vybrána nejlépe pracující lokalizační metoda a nejlepší klasifikátor.

Detekční systém vytvořený z nejlepších dílčích částí je v závěru podroben citlivostní analýze, ze které bylo možné zjistit, jakým způsobem systém reaguje na různé degradace vstupního obrazu. Jednalo se o degradace natočením, snižováním kontrastu a zvyšováním šumu.

2 REGISTRAČNÍ ZNAČKY A MOŽNOSTI JEJICH ROZPOZNÁVÁNÍ

2.1 Podoby registračních značek

Čerpáno z vyhlášky č. 343/2014 Sb. a dále z [4], [15], [21], [22], [23], [29], [31].

S výrobou prvních automobilů přišla potřeba vozy označovat. Vývoj tohoto značení vozidel probíhá ve světě již více než 110 let. V počátcích se pro označování vozidel využívaly keramické destičky či kůže, které se umísťovaly kdekoli na automobilu. Až během času se začínaly využívat značky kovové, umístěvané na konkrétních místech na vozidlech tak, jak je to dnes běžné.

Dlouhodobým vývojem je dáno, že registrační značky vozidel jsou nyní velmi rozmanité. Ve vzhledu lze najít mnoho odlišností. Značky různých států se od sebe mohou lišit téměř ve všech ohledech, a to:

- rozměrem,
- barvou pozadí,
- barvou znaků,
- materiálem tabulky,
- použitým písmem,
- počtem znaků,
- užíváním speciálních znaků a mezer,
- abecedou
- i dalšími.

2.1.1 Registrační značky v České republice

Podoba registračních značek vozidel v České republice je definována ve vyhlášce č. 343/2014 Sb. – o registraci vozidel, přičemž značky v současném provedení jsou vydávány dle zákona č. 243/2001 Sb. o registraci vozidel.

Standardní provedení značky pro všechna silniční motorová vozidla a přípojná vozidla je s černým textem na bílém pozadí. Základní uspořádání je jednořádkové s rozměry 520 x 110 mm. Případně existuje i dvouřádkové provedení s několika různými rozměry, nejběžnější je 340 x 200 mm. Značka je doplněna modrým pruhem se znakem Evropské unie a zkratkou země s rozměry minimálně 49 x 98 mm.



Obr. 2.1: Příklad standardních tabulek

V České republice se dále vyskytují registrační značky pro zvláštní motorová vozidla s černým textem na žlutém pozadí. K vidění jsou i značky diplomatické nebo cizinecké s modrým textem na bílém pozadí, značky pro export a značky se zeleným textem na bílém pozadí pro historická nebo sportovní vozidla.



Obr. 2.2: Příklad speciálních registračních značek

2.1.2 Registrační značky v Evropské unii

Prozkoumáním jednotlivých podkladů především z [21] a [22] bylo zjištěno, že registrační značky ve státech Evropské unie mají společný modrý pruh v levé části tabulky či preferenci jednořádkových provedení. Naopak mnoho rysů je odlišných a ani použití černých znaků na bílém pozadí není pravidlem. V jednotlivých státech, stejně jako v České republice, jsou stále platné i značky straší, kde modrý pruh být nemusí. V následujících kapitolách je podrobněji rozebráno několik modelů značek z pěti větších zemí Evropské unie.

Francie

Francie nyní používá model zavedený v roce 2009 (Obr. 2.3), který využívá černé znaky a ohraničení na bílém pozadí a modré pruhy vpravo a vlevo. Ve Francii se také stále velmi často vyskytuje model platný mezi lety 1950 a 2009 (Obr. 2.4), který využíval na přední značce bílý a na zadní žlutý podklad pro černé znaky.

Na současných značkách je zobrazeno 8 alfanumerických znaků v pořadí: dvě písmena, tři čísla a dvě písmena, přičemž jednotlivé skupiny jsou od sebe odděleny pomlčkou.

Německo

Německo v současné době vydává registrační značky na základě modelu z roku 1994 (Obr. 2.5). Tento model využívá opět černé znaky na bílém podkladě. Použitý font od roku 2000 významně zjednodušuje strojové čtení značek, jelikož od sebe výrazně odlišuje „0“, „O“ a „Q“ přerušením znaků na různých místech. Na značce může být až 8 znaků psaných latinkou. Využívají se i přehláskovaná písmena „Ä“, „Ö“, „Ü“.

Itálie


V Itálii je v současnosti používán model z roku 1994 (Obr. 2.6), který byl převzat i ve Francii. Typické je zobrazení černých znaků na bílém pozadí. Základem písma je font DIN 1451 s určitými změnami. Značky osobních automobilů mají kombinace znaků ve formátu: dvě písmena, tři číslice a dvě písmena. Motocykly a nákladní automobily musí obsahovat kombinace formátu: dvě písmena, 5 číslic. Skupiny na rozdíl od Francie nejsou odděleny pomlčkami ani dvojtečkami.

Belgie

V Belgii používaný model se od ostatních evropských značek liší především použitím červené barvy na obvod a alfanumerické znaky (Obr. 2.7). Podklad zůstává typicky bílý. Modrý pruh se znakem Evropské unie vlevo je pouze volitelný. Na žadateli o značku je také volba, zda využije jednořádkovou nebo dvouřádkovou variantu. Použitý formát znaků je: číslo, tři písmena, tři čísla.

Dánsko

V Dánsku se od roku 2009 vyskytuje model značky (Obr. 2.8), který se od ostatních odlišuje především červeným ohraničením tabulky. Jinak typické černé znaky na bílém pozadí zůstávají podobné ostatním značkám EU. Skupiny znaků: dvě písmena, dvě čísla, tři čísla jsou odděleny mezerami.



Obr. 2.3 Současně používaná podoba RZ ve Francii



Obr. 2.4 Starší podoby RZ ve Francii, přední (vlevo) a zadní tabulka




Obr. 2.5 Německá registrační značka



Obr. 2.6 Italská registrační značka



Obr. 2.7 Podoby belgických registračních značek



Obr. 2.8 Dánská registrační značka

2.1.3 Registrační značky ve světě

USA

Registrační značky ve Spojených státech amerických jsou velmi rozmanité (např. Obr. 2.9). Každý ze států má naprosto jinou poznávací značku. Závazné jsou pouze rozměry 350 x 152 mm a velikost alfanumerických znaků 70 mm.

Význam a uspořádání jednotlivých znaků, barevné kombinace pozadí a symbolů či počty znaků jsou čistě na vydavatelích značek. Na značkách se také často vyskytují různé zkratky nebo hesla vázající se ke konkrétním událostem daného státu. Zvláštní značky mají také hasiči, armádní veteráni či příslušníci indiánských kmenů.

Kanada

Situace s kanadskými registračními značkami je velmi podobná jako v USA. Každé teritorium má svůj speciální vzhled (příkladem je Obr. 2.10). Tvar značky může dosáhnout až velmi netradičních podob.

Rusko

Rusko od roku 1994 využívá černých znaků na bílém reflexním pozadí (Obr. 2.11). Kód se skládá z malého písmene, tří číslic a dvou malých písmen. Vpravo je číselné označení oblasti, kde byla značka registrována.



Obr. 2.9 Americké registrační značky



Obr. 2.10 Kanadské registrační značky



Obr. 2.11 Ruská registrační značka

2.1.4 Shrnutí

Na základě porovnání vzhledů jednotlivých značek lze usoudit, že pro vytvoření opravdu robustního algoritmu pro lokalizaci oblastí s registrační značkou nelze ve větší míře využívat algoritmy založené na práci s barvami. Špatně využitelné se jeví i algoritmy hledající pouze konkrétní poměry obdélníka tabulky s registrační značkou.

Naopak lze usuzovat, že algoritmy pracující na základě hranových detektorů by měly být úspěšné i v obecném měřítku, jelikož znaky a pozadí na značkách jsou vždy dostatečně kontrastní.

Vzhledem k předpokladu, že bude proveden návrh celého algoritmu rozpoznání SPZ, bude kvůli rozdílnému typu písma u většiny států v následující práci operováno pouze s jednořádkovými značkami České republiky.

2.2 Možnosti automatického rozpoznávání registračních značek

Při tvorbě této kapitoly bylo čerpáno především z [20].

Automatické rozpoznávání registračních značek (Automatic Number Plate Recognition - ANPR) vozidel je systém využívající optického rozlišení znaků na snímcích či záběrech za účelem přečtení registračních značek. Rozpoznávací nástroje mohou využívat klasických kamerových systémů nebo kamer konkrétně vytvořených pro dané účely. První systém tohoto druhu byl nasazen do praxe ve Spojeném království v roce 1979. Současné detekční systémy lze využít mnoha způsoby, přičemž ve většině případů je jejich použití výhodnější a rychlejší než použití člověka pro tentýž účel.

2.2.1 Možné oblasti využití

Jedním ze způsobů využití je kontrola vjezdu vozidel do určitých prostor. Systém udržuje přehled o tom, které vozidlo a v jakou dobu vjelo do areálu a kdy jej opustilo. Kódy mohou být propojeny s databází pověřených osob a podle toho může být vstup do oblasti povolen nebo zamítnut. Toho lze využít u parkovacích systémů, na letištích, v obchodních centrech atd.

Systémy ANPR se také často využívají pro kontrolu dodržování pravidel silničního provozu, například kontrola přestupkové jízdy na červenou, přejíždění přes plnou čáru, neoprávněné používání pruhu pro autobusy. Pokud jsou k dispozici dvě kontrolní kamerová stanoviště, lze při znalosti jejich vzájemné vzdálenosti kontrolovat dodržování maximální povolené rychlosti.

Dalším možným využitím jsou kontroly na hranicích, výběr silničních daní, dohledávání kradených vozidel, upozorňování na řidiče, kteří nezaplatili palivo na čerpacích stanicích a mnohé další.

2.2.2 Slabiny systémů

Mezi zásadní slabiny ANPR systémů patří velké množství proměnných zasahujících do samotného procesu rozpoznávání. Všechny tyto proměnné musí být při implementaci a instalaci systému zváženy a jejich vliv na kvalitu rozpoznávání by měl být co možná nejvíce potlačen. Mezi ovlivňující proměnné patří například vzdálenost značky od kamery, úhel, ve kterém kamera snímá, světelné podmínky, znečištění poznávací značky, umístění značky i rychlost jedoucího vozidla.

Klíčovým faktorem zhoršujícím kvalitu ANPR systému je kvalita obrazu. Například rozmazané snímky drasticky snižují účinnost systémů, proto je zapotřebí využívat speciálních technik snižujících dobu expozice. V některých případech, například při umístění ANPR systému ve vozidlech, je nutné skombinovat protichůdné požadavky na výkon, odběr energie a velikost zařízení, které musí být schopné fungovat dostatečně rychle i při relativních rychlostech přesahujících 160 km/h.

Mezi další faktory snižující účinnost rozpoznávacích systémů patří také špatné osvětlení značky, nízký kontrast, výskyt stínů, špatná kvalita kamery, výskyt zahraničních vozidel s jinými značkami a další.

2.2.3 Umístění kamery

Umístění kamery, tedy vzájemná poloha mezi rozpoznávanou registrační značkou a snímacím zařízením, je jednou z klíčových proměnných při určování využitelnosti systémů typu ANPR. Každý stupeň vertikální rotace či horizontálního zakřivení může mít výrazný vliv na kvalitu rozpoznávání.

Poloha kamery se volí především v závislosti na konkrétní aplikaci. Umístění kamery zaměřující bariérový vstup je pravděpodobně nejvhodnější na 1 metr vysokém patníku, který je zacílen přímo na přibližující se vozidlo. Naopak kamera sledující průběžný pruh na komunikaci se umísťuje na bránu přímo rovnoběžně nad daný jízdní pruh. Je evidentní, že rozdílná perspektiva v obou případech způsobí i rozdílný geometrický tvar značky na výsledném snímku, čemuž se musí přizpůsobit detekční algoritmus.

3 DATABÁZE SNÍMKŮ S RZ

Soubory snímků obsahující registrační značky jsou velmi důležitým prvkem při navrhování algoritmů rozpoznávání SPZ, jelikož při implementaci jednotlivých metod je snaha dosáhnout nejlepších výsledků právě na těchto galeriích. Z toho důvodu je dobré, pokud jsou soubory obrazů rozmanité a pořízené v reálných podmínkách. Jelikož vyhodnocení kvality rozpoznávání je v experimentu vztaženo vždy zvláště ke každé databázi, je dále uvedena stručná charakteristika jednotlivých databází.

3.1 Vlastní galerie

V této práci bylo využito 5 vlastních a 4 převzaté galerie. Všechny obsahovaly české jednořádkové registrační značky. Snímky z vlastních galerií byly pořízeny mobilním telefonem iPhone 5 od společnosti Apple v rozlišení 3264 x 2448 pixelů. Registrační značky na těchto fotografiích byly pořízeny z rozdílných vzdáleností, ve většině případů kolmo na značku. Galerie se od sebe liší především místem pořízení a povětrnostními podmínkami.

3.1.1 Galerie db_parkoviste_zatazeno


Vlastní galerie 121 snímků. Všechny fotografie byly pořízeny na šířku při zataženém počasí. Snímky ve většině případů neobsahují komplexní scény s více značkami. Registrační značky se nacházejí přibližně ve vzdálenosti 3 metrů od fotoaparátu.



Obr. 3.1: Příklad snímků z databáze db_parkoviste_zatazeno

3.1.2 Galerie db_parkoviste_slunecno

Vlastní galerie 259 snímků pořízená za slunečného počasí, čímž na fotografiích vznikají stíny, v některých případech zakrývající část registrační značky. Tato záležitost by mohla komplikovat proces lokalizace, jelikož značka nemá rovnoměrně rozložené jasové hodnoty. I přesto snímky neobsahují příliš komplexní scény s více značkami.



Obr. 3.2: Příklad snímků z databáze db_parkoviste_slunecno

3.1.3 Galerie db_slunecno

Vlastní galerie obsahující 35 fotografií. Tato databáze je velmi rozmanitá. Registrační značky byly pořízeny z různých vzdáleností za slunečného počasí. Některé značky jsou zcela zastíněné, jiné naopak přímo osvětlené sluncem, čímž na značkách vznikají odlesky komplikující rozpoznání. Některé snímky obsahují i komplexní scény s více značkami.



Obr. 3.3: Příklad snímků z databáze db_slunecno

3.1.4 Galerie db_destivo

Vlastní galerie s 88 snímky pořízená v deštivém počasí. Registrační značky byly fotografovány z různých vzdáleností. Některé byly pořízeny za mokrým sklem osobního automobilu, čímž u snímků docházelo k drobnému rozmazání. Snímky mohou obsahovat komplexní scény s více automobily a rozmanitým pozadím.



Obr. 3.4: Příklad snímků z databáze db_destivo

3.1.5 Galerie db_tma

Vlastní galerie obsahující 19 snímků pořízených za tmy. V některých případech jsou značky částečně osvětleny pouličními lampami shora, čímž na jejich vrchní části vzniká stín. Na dvou snímcích je značka osvětlena žárovkami přímo z nastartovaného automobilu, ale na většině snímků jsou automobily zaparkované a nenastartované. Vlivem potřebné vyšší expoziční doby snímacího zařízení jsou některé snímky mírně rozmazané.



Obr. 3.5: Příklad snímků z databáze db_tma

3.2 Převzaté galerie

Převzaté databáze jsou rozmanité téměř ve všech ohledech. Liší se snímacím zařízením, výstupním rozlišením, počasím i kvalitou.

3.2.1 Galerie mpov_1

Převzatá galerie obsahující 90 barevných snímků. Údaje o pořizovacím zařízení nejsou k dispozici. Galerie obsahuje 24 snímků s rozlišením 1552 x 2592 px s orientací na výšku. Další 37 snímků je orientováno na šířku s rozlišením 2592 x 1936 px. A posledních 29 fotografií je s rozlišením 4128 x 2322 px. Lze předpokládat, že každá skupina byla focena jiným autorem na různých místech, proto je tato galerie více rozmanitá v komplexnosti scén, v povětrnostních podmínkách i v kvalitě fotografií.



Obr. 3.6: Příklad snímků z databáze mpov_1

3.2.2 Galerie mpov_2

Převzatá databáze se 45 barevnými fotografiemi. Tato galerie je opravdu velmi rozmanitá. Registrační značky jsou pořízeny z různých vzdáleností a z rozdílných úhlů. Zároveň se v databázi vyskytují i značky poškozené a pokroucené. Některé snímky jsou špatně zaostřené a tím pádem rozmazané. Všechny fotografie byly pořízeny v zataženém až deštivém počasí bez slunečních odlesků. Jeden snímek byl pořízen mobilním telefonem Sony Ericsson K750i v rozlišení 1000 x 750 px. Další 9 snímků s rozlišením 5184 x 3456 px bylo fotografováno fotoaparátem Canon EOS 60 D. Zbytek fotografií byl získán mobilním telefonem Nexus 5 s rozlišením 3264 x 2448 px.



Obr. 3.7: Příklad snímků z databáze mpov_2

3.2.3 Galerie mpov_3

Galerie obsahující 79 snímků s rozlišením 800 x 600 px pořízených mobilním telefonem Samsung Galaxy Nexus. Tato databáze je velmi jednotná. Všechny registrační značky byly foceny ze stejné vzdálenosti přibližně 2 metrů kolmo na tabulku. Dále není patrné žádné natočení registračních značek. Několik fotografií je mírně rozmazáno. Část značek je osvětlena slunečními paprsky.



Obr. 3.8: : Příklad snímků z databáze mpov_3

3.2.4 Galerie camea

Tato galerie se od ostatních výrazně odlišuje, jelikož je tvořena snímky pořízenými průmyslovým zařízením použitým v reálném provozu. Jako jediná je tato galerie složena pouze ze šedotónových snímků. Vzhledem k umístění kamery relativně vysoko nad komunikací dochází k částečnému geometrickému zkreslení registračních značek, čím se mění poměry stran značky. Na fotografiích se také vyskytuje vložený text, který by mohl ovlivňovat lokalizační algoritmy.



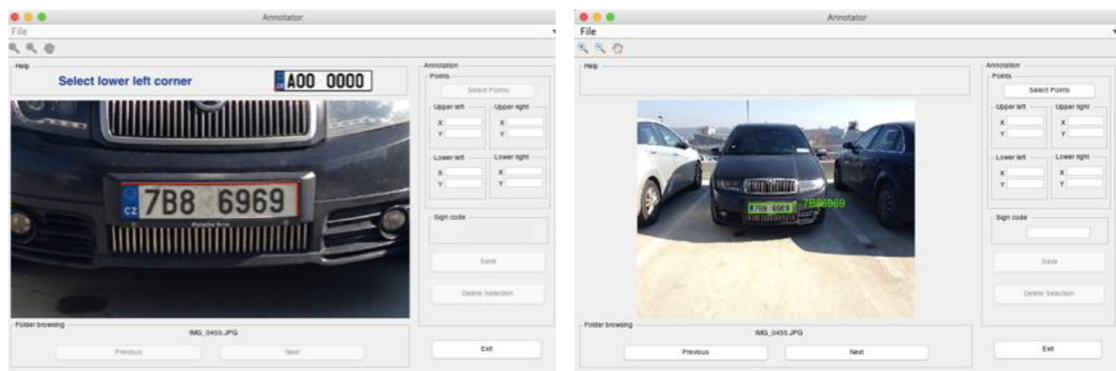
Obr. 3.9: Příklad snímků z databáze camea

3.3 Anotátor

Anotátor vychází z nástroje použitého v práci [33]. Původní program byl vytvořen ve vývojovém prostředí Matlab GUIDE pro anotaci dopravních značek. Tento nástroj uměl přidávat nové anotace do *.csv souboru anotací a zároveň uměl zobrazovat již hotové anotace. Také bylo možné listovat mezi snímky v rámci jedné složky a jednotlivé snímky přibližovat nebo oddalovat.

I další základní funkčnosti a principy v této práci implementovaného anotátoru zůstávají zachovány. Tedy po spuštění je uživatel dotázán k vybrání složky obsahující snímky určené k anotaci. Poté lze buď vytvořit nový *.csv soubor, nebo otevřít stávající, pokud se v aktuální složce nachází. Vylepšení původního nástroje vychází především z potřeby přizpůsobení anotací registračním značkám. Dále došlo ke zprehlednění UI a zjednodušení některých postupů.

Po kliknutí na tlačítko „Select Points“ uživatel postupně označí jednotlivé rohové body registrační značky. Sled označování je velmi důležitý, proto je zde výrazně zobrazena slovní i grafická nápověda ulehčující orientaci. Postup je: levý horní roh, pravý horní roh, pravý spodní roh a levý spodní roh. Po označení všech čtyř rohů je možné zapsat textovou podobu kódu značky do pole „Sign code“. Poté lze vytvořenou anotaci uložit tlačítkem „Save“ nebo zrušit tlačítkem „Delete Selection“. Kliknutím na „Next“ nebo „Previous“ se uživatel přesune na další nebo předchozí snímek a anotační postup je možné opakovat.



Obr. 3.10: Anotátor, vlevo průběh anotování, vpravo již anotovaná značka

V jednom snímku lze označit i více registračních značek. Uložené anotace jsou poté zeleně zobrazeny v příslušném snímku zároveň s textovým kódem značky. Formát uložené anotované značky v *.csv souboru je naznačen na Obr. 3.11 s tím rozdílem, že v samotném souboru jsou od sebe hodnoty v řádcích odděleny čárkami. Souřadnice každého rohu se ukládají s přesností až na 4 desetinná místa.

file	upper left x	upper left y	upper right x	upper right y	lower right x	lower right y	lower left x	lower left y	licence code
IMG_0454.JPG	1428.1928	805.747	1817.759	810.6627	1817.759	884.3976	1428.1928	879.4819	5B25756
IMG_0455.JPG	1175.9184	1083.2768	1630.411	1081.5354	1630.411	1166.8616	1175.9184	1173.827	7B86969

*Obr. 3.11: Způsob uložení anotací v *.csv souboru*

Při samotném anotování se ukázalo jako výhodné maximalizovat okno anotátoru a pomocí tlačítka přiblížení zvětšit registrační značku na celý zobrazovací prostor. Roh značky bylo poté ideální označit co nejpřesněji do průsečíku pomyslného prodloužení příslušných stran značky.

4 LOKALIZACE REGISTRAČNÍ ZNAČKY

Lokalizace značky je první částí postupu při rozpoznávání registračních značek. Dalšími jsou separace jednotlivých alfanumerických znaků a samotná klasifikace separovaných znaků. Lokalizací samotný rozpoznávací řetězec začíná, proto má její kvalita největší vliv na úspěšnost rozpoznávání, jelikož je možné, že použitá lokalizační metoda registrační značku vůbec nenajde nebo naopak je za registrační značku prohlášena oblast, která značkou není. Tímto se stává celý řetězec rozpoznávání zcela zbytečný a případná kvalita dalších kroků či samotné prostředky použité na vytvoření algoritmů separace a klasifikace, již nejsou využity.

Kvalitu lokalizace ale ovlivňuje i způsob, jakým je registrační značka na snímku označena. Žádný algoritmus neoznačí značku na snímku naprosto přesně. Většinou vlivem nedokonalostí, poškození značky, šumu, odlesků či špatně pracujícím lokalizačním algoritmem je označena oblast větší než je samotná značka. Nebo naopak částečně zastíněná značka může být v konečném důsledku označena jen zčásti. Většina algoritmů označuje obdélník registrační značce opsaný, jenž má strany rovnoběžné s celým snímkem, potom je mírně natočená registrační značka vyznačena taktéž nepřesně. Pokud špatně označené registrační značky postupují dále do řetězce rozpoznávání, je velmi pravděpodobné, že celková rozpoznávací úspěšnost bude degradovat.

Některé přístupy využití rozpoznávání registračních značek počítají s rozpoznáváním v reálném čase, přičemž je nutné analyzovat snímky mnohokrát za sekundu. Proto také velmi záleží na době trvání zpracování jednoho snímku. Největší podíl na tomto čase má právě lokalizace, jelikož jejím vstupem je snímek s největším rozlišením a nad celým snímkem probíhají komplexní výpočty.

Při posuzování kvality lokalizace je tedy důležité, aby algoritmy minimalizovaly falešně pozitivní a především falešně negativní kandidáty. Dále se očekává co nejpřesnější označení registrační značky, ideálně i přesné označení natočené značky. Důležitou vlastností je i nízká doba trvání lokalizace.

4.1 Rozdělení lokalizačních metod

V následujícím textu jsou, s využitím analýzy článků zabývajících se lokalizací registračních značek, rozebrány možné využitelné přístupy.

Velmi často používané metody jsou založené na práci s hranovými body vzhledem k jednoduše implementaci a nízké výpočetní náročnosti. Metody využívají velkého jasového gradientu, který vzniká na přechodech tmavých znaků na světlém pozadí. Tento gradient se nejčastěji zvýrazní vertikálním hranovým operátorem. Princip je použit v pracích: [1], [5], [10], [19], [25].

Jiné přístupy využívají morfologické operace, a to jak operace s binárními, tak s šedotónovými obrazy. Ve většině případů se řetězí několik operací za sebou. Často se využívá morfologické otevření, uzavření, top-hat či bottom-hat se strukturními elementy typu diamant nebo obdélník. Tento přístup má snahu především zvýraznit v obraze tabulku s registrační značkou a naopak ostatní prvky eliminovat. Použití v: [13], [17], [34].

Autoři v [14] kombinují metodu vyhledávající vertikální hrany s fuzziifikací barevného prostoru, jenž využívá skutečnosti, že značka obsahuje barevné tmavé znaky na jednobarevném světlém pozadí. Další možnost se skrývá v použití iteračního algoritmus CSER [18], jenž čerpá základy z umělých neuronových sítí.

V [7] je algoritmus postaven na vyhledávání vzoru registrační značky v obraze hran pomocí dvourozměrné korelace. Algoritmus mimo jiné vychází z podmínky znalosti vzdálenosti mezi snímacím zařízením a hledanou registrační značkou. Tuto podmínku ovšem nelze ve všech aplikacích zajistit.

V této kapitole bude dále podrobně rozebráno pět samostatných lokalizačních metod. Pokud budou některé uvedené údaje neúplné nebo málo detailní, je to proto, že autoři tyto informace do svých článků neuvedli. Pro lepší orientaci a jednoduchost budou metody označovány příjmením prvního autora článku, ve kterém je daná metoda popsána. Tedy postupně to budou metody „mahini“ z [17], „zhai“ z [34] a „tarabek“ z [28]. Metody realizované autorem této práce se budou nazývat „trkal_bp“ z [29] a „trkal_dp“.

Pro lepší názornost a porovnání bude grafické znázornění jednotlivých kroků následujících rozebraných metod vždy vycházet ze vstupního snímku na Obr. 4.1.



Obr. 4.1: Ověřovací snímek

4.2 Metoda Mahini

Úvod

Lokalizační metoda, která by dle autorů měla být schopná robustně detekovat značky s různým osvětlením, zastíněním, měřítkem, rotací i šumem z reálného prostředí, přičemž

výška tabulky se značkou se může pohybovat v intervalu od $\frac{1}{2}$ do $\frac{1}{50}$ výšky celého snímku. Při vyhledávání oblastí využívá statistiku hranových obrazů a morfologické operace. Metoda byla v původním článku testována na 269 snímcích, na nichž bylo úspěšně detekováno 96,5 % registračních značek. Značky byly íránské s arabskými znaky, ale pomocí několika drobných úprav lze algoritmus aplikovat i na tabulky z jiných zemí.

Nalezení kandidátů

Algoritmus začíná krokem, ve kterém se zmenší velikost vstupního snímku na šířku 100 px, přičemž výška se změní adekvátně v poměru k původnímu snímku. V každém dalším opakujícím se cyklu se využije větší velikost vstupního snímku (v článku není upřesněno, o kolik větší) až do případu, kdy je verifikačním algoritmem kandidát na značku označen jako registrační značka. Poté se celý algoritmus ukončuje.

V každém cyklu se vypočítají tři rozdílné obrazy (C_1, C_2, C_3), ze kterých se složí binární maska označující kandidáty na registrační značku. C_1 zvýrazňuje regiony se zvýšeným výskytem vertikálních hran. Výpočet C_1 začíná výpočtem morfologické transformace bottom-hat (4.1), výsledek je na Obr. 4.2.

$$I_0 = I \nabla S_{2 \times 8} = I \bullet S_{2 \times 8} - I = (I \oplus S_{2 \times 8}) \ominus S_{2 \times 8} - I \quad (4.1)$$


- I je původní šedotónový obraz,
- $S_{2 \times 8}$ je strukturální element o velikosti 2×8 ,
- ∇ je operátor bottom-hat transformace,
- \bullet je operátor morfologického uzavření,
- \ominus je operátor morfologické eroze,
- \oplus je operátor morfologické dilatace.

Z obrazu I_0 je poté konvolucí se sobelovým operátorem (4.2) extrahován obraz vertikálních hran, jenž je lineárně normalizován do intervalu 0 až 255 (Obr. 4.2). Kvůli odstranění šumu je následně aplikován mediánový filtr o rozměrech 5×5 px (Obr. 4.3). Nakonec jsou oblasti se zvýšeným výskytem hran zvýrazněny pomocí konvoluce s jednotkovou maticí o rozměrech 3×3 px. Tím vzniká jeden ze tří základních obrazů, tedy C_1 , který je zobrazen na Obr. 4.3.

$$sobel = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (4.2)$$



Obr. 4.2: Výsledný obraz po operaci bottom-hat (vlevo) a obraz vertikálních hran




Obr. 4.3: Obraz po filtraci šumu (vlevo) a obraz C_1 po konvoluci s jednotkovou maticí

Obraz C_2 (Obr. 4.4) zvýrazňuje šedě vypadající oblasti. Myšlenka vychází z předpokladu, že registrační značka obsahuje černé znaky na bílém pozadí, což jsou vlastně oblasti, ve kterých jsou hodnoty jednotlivých složek RGB obrazu velmi blízké. Proto hodnota pixelů i, j v obrazu $C_2(i, j)$ je rovna 1, pokud jsou si jasové složky R, G, B u původního obrazu velmi blízké, jinak je pixelu přiřazena hodnota 0.

Poslední dílčí obraz C_3 (Obr. 4.4) zvýrazňuje světlé oblasti na původním snímku. Tento princip vychází z jednoduché skutečnosti, že tabulky registrační značky jsou bílé, tedy světlé. Proto je C_3 vypočítán pomocí morfologického uzavření (4.3).

$$C_3 = I \bullet S_{3 \times 30} \quad (4.3)$$

- I je původní šedotónový obraz a
- $S_{3 \times 30}$ je strukturální element s rozměry 3x30 px.



Obr. 4.4: Obrázek C_2 (vlevo) a obrázek C_3 zvýrazňující světlé oblasti

Nyní sloučením C_1 , C_2 a C_3 , jenž je znázorněno na Obr. 4.5, dle vzorců (4.4), (4.5) a (4.6) vzniká binární maska BC korespondující s možnými kandidáty. Každá samostatná oblast v masce, jejíž hodnoty pixelů jsou rovny 1, přímo určuje výřez z původního obrazu. Každý výřez je poté ověřen ve verifikační fázi.

$$Kan_1(i, j) = C_1(i, j) \times C_2(i, j) \times C_3(i, j) \times (C_3(i, j) > 50) \quad (4.4)$$

$$\begin{aligned} Kand_2 &= Kan_1 \Delta S_{3 \times 8} = Kan_1 - Kan_1 \circ S_{3 \times 8} \\ &= Kan_1 - (Kan_1 \odot S_{3 \times 8}) \oplus S_{3 \times 8} \end{aligned} \quad (4.5)$$

- $S_{3 \times 8}$ je strukturní element o velikosti 3×8 ,
- Δ je operátor top-hat transformace.

$$BC = Kand_2 > Práh \quad (4.6)$$



Obr. 4.5: Sloučení C_1 , C_2 a C_3 (vlevo), binární maska, obraz kandidátů (vpravo)

Verifikace kandidátů

Po nalezení kandidátů v daném cyklu je nutné vybrat přesně jen ty, které odpovídají registračním značkám. Proto vybraný kandidát musí splňovat následující podmínky. Region se značkou nesmí být velmi malý, jeho tvar musí být podobný obdélníku a poměr

výše ku šíři se musí pohybovat v intervalu od 2 do 10. Dále průměrná jasová úroveň regionu kandidáta musí být dostatečně vysoká, přičemž se oblast nesmí dotýkat okraje původního snímku. Pokud se kandidát převede pomocí prahovací metody Otsu na binární obraz, lze poté provést vertikální amplitudovou projekci. Je-li na vzniklém grafu nalezeno 4 až 10 vrcholů a jsou-li splněny i předchozí dílčí podmínky, je analyzovaný kandidát prohlášen za registrační značku.

Zhodnocení

Testovací databáze v původním článku obsahovala 269 barevných snímků s rozlišením 800 x 600 px uložených v JPEG formátu. Všechny fotografie značek byly pořízeny v reálných podmínkách z různých vzdáleností a úhlů. Z těchto snímků jich 13 neobsahovalo žádnou registrační značku. Převedený algoritmus úspěšně rozpoznal 96,5 % značek, přičemž úspěšně dokázal detekovat i velmi malé značky.

Naopak již z principu algoritmického postupu lze odhadnout, že metoda nenajde menší značky v obraze tam, kde se vyskytuje i nějaká větší. Což ale může být v jistých případech i výhodou, například v podzemních parkovištích či u vjezdových bran, kde se přímo očekává detekce největší značky. Celý algoritmus by mohl velmi degradovat chybně nastavený výpočet C_2 , jenž zvýrazňuje oblasti s podobnými jasovými úrovněmi složek R, G a B. Například značky na snímcích pořízených při západu slunce, či fotografie pořízené kamerou s nesprávným nastavením vyvážení bílé, které mohou být zabarvené do žluta nebo do modra, by mohly být velmi lehce vyřazeny z množiny kandidátů.

4.3 Metoda Zhai

Úvod

Metoda využívající především morfologického otevření a uzavření s různými strukturálními elementy s cílem maximálně eliminovat oblasti neobsahující registrační značku. V původním článku byl algoritmus testován pomocí databáze anglických značek. Vzhledem k jednodušší implementaci a malému počtu kroků při lokalizaci nezabere algoritmus mnoho výpočetního času.

Nalezení kandidátů

Hledání kandidátů je rozděleno na použití morfologických operací a na výběr konkrétních oblastí jednotlivých kandidátů. Do lokalizačního algoritmu vstupují již šedotónové snímky.

Nejdříve je vypočítán snímek s odstraněnými malými objekty pomocí morfologického otevření s obdélníkovým strukturálním elementem 4x30 px, jehož počátek je ve 3. řádce a 16. sloupci. Velikost tohoto strukturálního elementu je přímo odvislá od rozlišení vstupního snímku a od předpokládané velikosti tabulky s registrační značkou. Tedy jeho šíře 30 px je určena podle největší možné mezery mezi jednotlivými znaky. A

jeho výše pak podle toho, že horní a spodní mezera mezi znakem a okrajem tabulky je vždy větší než 4 px.

Tímto je fakticky vypočítán snímek zobrazující pozadí bez detailů. Toto pozadí je poté odečteno od vstupního snímku, čímž vzniká obraz se zvýrazněnými oblastmi, ve kterých by se mohla vyskytovat značka. Uvedený postup je vlastně top-hat morfologická transformace s výpočtem (4.7) a s výsledkem na Obr. 4.6 vlevo.

$$I_1 = I \Delta S_{4 \times 30} = I - I \circ S_{4 \times 30} = I - (I \odot S_{4 \times 30}) \oplus S_{4 \times 30} \quad (4.7)$$

V dalším kroku je nutné snímek se zvýrazněnými oblastmi převést na binární pomocí prahování (Obr. 4.6 uprostřed), přičemž práh se vypočte dle vzorce (4.8). Cílem kroku je především eliminovat oblasti s málo výraznými detaily, ve kterých se nedá předpokládat výskyt registrační značky.

$$Práh = (max1 - (max1 - min1)/1,35)/255 \quad (4.8)$$


- *Max1* je maximální hodnota pixelu ze snímku se zvýrazněnými oblastmi,
- *min1* je minimální hodnota pixelu ze snímku se zvýrazněnými oblastmi.



Obr. 4.6: Top-hat obraz (vlevo), binární obraz a obraz s odstraněnými detaily (vpravo)

I po provedení předchozích postupů zůstávají ve snímku přebytečné matoucí informace, tedy objekty, které značně neodpovídají. Pro jejich odstranění je nejdříve aplikována operace morfologického otevření se strukturálním elementem typu diamant o poloměru 2, jenž odstraňuje přebytečné malé segmenty (Obr. 4.6 vpravo). Následuje morfologická operace uzavření s obdélníkovým strukturálním elementem o velikosti 4x13 px, která spojí horizontálně si blízké objekty (Obr. 4.7).

Posledním krokem je nalezení kandidátů na registrační značku. Po identifikaci oblastí na konečném binárním snímku musí každá oblast splňovat dvě kritéria. První je správný poměr šíře ku výši oblasti. Druhou podmínkou je splnění předem daného rozsahu šíře i výše tak, aby se eliminovaly příliš velké nebo naopak malé objekty. Po splnění kritérií je oblast označena jako kandidát a ten poté postupuje k verifikaci.



Obr. 4.7: Binární maska možných kandidátů (vlevo) a její aplikace

Verifikace kandidátů

Ověřování kandidátů spočívá pouze na jedné podmínce a tou je počet objektů na binárním snímku kandidáta odpovídajících alfanumerickému znaku. Přesněji, je zjišťován počet objektů na binárním snímku kandidáta, které mají výšku a šířku, jenž by mohla odpovídat číslici nebo písmenu. Jestliže je tento počet po analýze všech objektů na binárním snímku kandidáta v intervalu mezi 2 až 15, je tento kandidát prohlášen za registrační značku.

Zhodnocení

Algoritmus byl v původním článku testován pomocí databáze obsahující 1000 snímků pořízených v různých podmínkách. Snímky měly rozlišení 768x288 px. Jelikož metoda používá pouze tři morfologické operace, je velmi nenáročná na výpočetní čas procesoru. Metoda správně detekovala 98,7 % ze všech testovacích registračních značek.

Jistou nevýhodou algoritmu je velmi malý rozsah velikostí detekovaných značek kvůli pevně zvoleným velikostem strukturních elementů. Dále pro správné fungování metody je předpoklad stejné horizontální vzdálenosti jednotlivých znaků na registrační značce, což ovšem nemusí být vždy platné pravidlo, jelikož například na českých značkách je větší mezera mezi třetím a čtvrtým znakem. Metoda by poté mohla místo jedné značky detekovat dvě.

4.4 Metoda Tarabek

Úvod

Tato lokalizační metoda je postavena především na vyhledávání značek v obrazu pomocí vertikálních hran, jelikož hrany nejsou příliš závislé na změnách osvětlení. Z tohoto obrazu jsou ve dvoufázovém detekčním procesu extrahováni kandidáti pomocí plovoucího okna, v nichž se provádí výpočet hustoty pixelů. Algoritmus by měl být v reálném čase schopný detekovat několik různě velikých značek najednou i při

komplexním pozadí. V databázi 501 snímků bylo dosaženo úspěšnosti 97,4 % správně nalezených registračních značek.

Nalezení kandidátů

Hledání kandidátů je rozděleno do tří rozdílných kroků: nalezení vertikálních hran, hrubá detekce a přesná detekce. V postupu se vyskytuje několik experimentálně nastavených konstant, jejichž hodnoty byly laděny na tréninkové galerii, která obsahovala 40 % fotografií z celé dostupné databáze autora.

Pro vyhledání vertikálních hran (Obr. 4.8 vlevo) byl využit Sobelův operátor (4.2), především pro jeho odolnost vůči šumu a jeho výpočetní nenáročnost. Obraz vertikálních hran obsahuje dostatečné množství informací o registračních značkách, přičemž odstraněním horizontálních hran se celkový obraz velmi zjednodušuje. Pomocí adaptivního prahování je poté získán binární obraz hran (Obr. 4.8 vpravo), se kterým pracuje samotná detekce.



Obr. 4.8: Obraz vertikálních hran (vlevo) a jeho binární podoba

Hrubá i přesná detekce kandidátů využívá principu plovoucího okna. Na začátku je okno s nejmenší velikostí posouváno po binárním obrazu vertikálních hran. Každá jeho poloha je vyhodnocena, a pokud jsou splněny dále uvedené stanovené podmínky, je jeho poloha i uložena pro další zpracování. Po prohledání celého obrazu je velikost okna zvětšena a celý detekční cyklus se opakuje, dokud není dosažena maximální nastavená velikost okna. Vyhodnocování velkého množství poloh plovoucího okna bývá výpočetně velmi náročné, a proto je nutné volit kroky změny velikostí a polohy velmi rozumně. Vyhodnocovací mechanismus je vlastně binární klasifikátor založený na výpočtu hustot hran v okně s hierarchicky strukturovanými podmínkami. Hustota hran v dané oblasti se vypočte dle (4.9).

$$Ed = \frac{1}{w \times h} \sum_{x=1}^w \sum_{y=1}^h e(x, y) \quad (4.9)$$

- Ed je hustota pixelů v daném okně,
- w je šíře okna,
- h je výše okna,
- e(x, y) je konkrétní bod z binárního obrazu vertikálních hran.

Během dalšího postupu je nutné brát v potaz jednu vlastnost vyhodnocování na základě hustoty hran, totiž že hodnota hustoty není pro registrační značku konstantní, ale klesá se zvětšující se velikostí značky. Při předpokladu detekce mnoha značek s velkou rozdílnou velikostí je lepší využít adaptující se prahovou hodnotu hustoty přímo odvozenou od aktuální velikosti plovoucího okna. Toho ale autoři v článku nevyužili.

Úkolem hrubé detekce (Obr. 4.10 vlevo) je rychle a efektivně oddělit oblasti obsahující pozadí od oblastí, na kterých se mohou nacházet registrační značky. Oblasti se detekují pomocí výpočtu hustoty hranových bodů v plovoucím okně. Pokud je hustota větší než experimentálně zvolená rozhodovací hodnota 0,15, uloží se poloha okna pro další postup. Okno se postupně posouvá o 15 % aktuální výšky a šířky okna a jeho šíře se v každém cyklu zvětšuje o 40 % od minimální hodnoty 20 px do maximální 40 px. Šíře je poté nastavena vždy čtyřikrát větší než výše.


Přesná detekce vyřazuje z dalšího zpracování ta okna, jejichž obsah nesplňuje následující podmínky: hodnota hustoty hran je větší než v okolí, rozložení hranových bodů je relativně uniformní, velikosti hran jsou relativně velké vzhledem k velikosti značky a výška hranových objektů je menší než výška značky. Tyto podmínky ovšem většinou nejdou přímo implicitně vyjádřit, proto jsou transformovány do následujících ověřovacích postupů.

Pro každou jednotlivou velikost plovoucího okna je vypočtena minimální hustota vertikálních hranových bodů ed_{min} podle (4.10), pokud je hustota hranových bodů v aktuální poloze okna větší než ed_{min} , je poloha okna nadále uchována.


$$ed_{min} = T_{min} - \left(\left(\frac{T_{max} - T_{min}}{H_{max} - H_{min}} \right) \times (H_c - H_{min}) \right) \quad (4.10)$$

- T_{max} je prahová hodnota pro maximální velikost registrační značky,
- T_{min} je prahová hodnota pro minimální velikost registrační značky,
- H_{min} je minimální výška plovoucího okna,
- H_{max} je maximální výška plovoucího okna,
- H_c je aktuální výška plovoucího okna.

Jestliže poloha okna nebyla dosud odstraněna, je dále testováno na rovnoměrné rozložení vertikálních hranových bodů. Nejdříve se rozdělí horizontálním a vertikálním předělem na čtyři podokna (Obr. 4.9 nahoře). Hustota vertikálních hranových bodů každého podokna musí být znovu větší než ed_{min} , jinak je celé okno vyřazeno. Pokud vyřazeno není, je dále rozděleno na 20 vertikálních a 10 horizontálních podoken (Obr. 4.9 dole). Jestliže hodnota hustoty hran alespoň u 22 podoken přesahuje ed_{min} , okno se zachovává a předpokládá se, že oblast obsahuje kandidáta registrační značky (Obr. 4.10 vpravo). Samotná oblast může být ještě případně částečně zmenšena, aby přesněji opisovala objekt uvnitř.



Obr. 4.9: Rozdělení oblastí v plovoucím okně, dle kterých se testuje uniformita hustoty vertikálních hran



Obr. 4.10: Uložené polohy plovoucích oken po hrubé detekci (vlevo) a po přesné detekci

Verifikace kandidátů

Aby byl kandidát prohlášen za registrační značku, musí splňovat podmínky založené na geometrických vlastnostech výřezu a horizontální projekci. První podmínka určuje, že poměr šíře a výše kandidáta musí být v intervalu 2,2 až 6,2.

Pro odstranění falešných kandidátů je vypočtena horizontální projekce vertikálních hranových bodů. Podmínka je splněna, jestliže se v projekci vyskytuje počet vrcholů v rozmezí 9 až 40 větších než 20 % výšky kandidáta. Tímto by při splnění předchozích podmínek měly být přesně extrahovány registrační značky z obrazu.

Vyhodnocení

Lokalizační algoritmus byl v původním článku testován na dvou databázích s řeckými značkami s obsahem 335 a 501 snímků. Galerie byly ještě dodatečně rozděleny podle podobných vlastností na snímky se značkami fotografovanými zblízka, z dálky, se značkami ve stínu a s částečně zastíněnými značkami. Snímky byly dostupné v rozlišení 640 x 480 px, přičemž průměrný čas zpracování jedné fotografie byl 36 ms.

Metoda byla schopná lokalizovat několik registračních značek v jednom snímku a vzhledem k rychlosti zpracování se hodí i na použití v reálném čase. V menší galerii fotografií bylo dosaženo 97,97 % korektně detekovaných značek a ve větší bylo takto nalezeno 98,60 % značek.

Vzhledem k tomu, že metoda nehledá přímo hranice tabulky registrační značky, ale pouze prochází pevně dané oblasti, lze předpokládat, že výřezy kandidátů nebudou docela přesné. Zároveň je nutné během ladění experimentálně nastavit větší množství parametrů, což znamená, že i když bude metoda dosahovat velmi dobrých výsledků na trénovací galerii, v reálných podmínkách již nemusí být dostatečně kvalitní.

4.5 Metoda Trkal_bp

Úvod

Tento algoritmus přináší lehce implementovatelné řešení pro základní použití, jelikož účelem této metody bylo především zautomatizovat získávání výřezů registračních značek pro další zpracování. V galerii se nacházelo 527 fotografií pořízených v různých reálných povětrnostních podmínkách, přičemž vzdálenost značek od snímacího zařízení byla přibližně 3 metry.

Nalezení kandidátů

V rámci předzpracování se zvyšuje kontrast pomocí převodní charakteristiky u všech tří RGB hladin tak, aby došlo k zesvětlení bílé části značky a naopak ke ztmavení černého rámečku kolem tabulky (Obr. 4.11). Jasová hodnota se měnila podle vzorce (4.11).

$$\begin{aligned}
I_{new}(x, y) &= 0, \text{ pokud } I_{old}(x, y) < I_{10\%} \\
&= 1, \text{ pokud } I_{old}(x, y) > I_{60\%} \\
&= \frac{255}{I_{60\%} - I_{10\%}} \times I_{old}(x, y), \text{ pokud } I_{10\%} \leq I_{old}(x, y) \leq I_{60\%}
\end{aligned}
\tag{4.11}$$

- I_{new} je nová jasová hodnota,
- x, y jsou souřadnice konkrétního bodu,
- I_{old} je jasová hodnota na původním snímku,
- $I_{10\%}$ je jasová hodnota, pod kterou se nachází jas 10 % bodů v původním obrazu,
- $I_{60\%}$ je jasová hodnota, pod kterou se nachází jas 60 % bodů v původním obrazu.

Každá jasová hladina se poté prahováním převádí do binárního formátu. A výsledný binární snímek vzniká složením všech tří hladin dohromady pomocí logické funkce *and*. Prahování každé hladiny separátně má výhodu v tom, že ze snímku eliminuje barevné objekty. Pro tyto účely byly experimentálně zvoleny dva pevně stanovené prahy a prahování tedy proběhlo vždy dvakrát. První hodnota prahu (Obr. 4.12) byla vyladěna především na značky umístěné ve stínu a druhý práh (Obr. 4.13) lépe prahuje značky přímo sluncem osvětlené.



Obr. 4.11: Snímek se zvýšeným kontrastem



Obr. 4.12: Binární mapa a odpovídající zvýraznění kandidátů pro vyšší práh



Obr. 4.13: Binární mapa a odpovídající zvýraznění kandidátů pro nižší práh

Na oba binární snímky je aplikována indexace bílých oblastí. Těmto oblastem se opíše obdélník. Pokud opsaný obdélník splňuje podmínku, že poměr šířky k výšce je v intervalu 3 až 6 a zároveň poměr počtu bílých pixelů ku počtu všech pixelů v obdélníku je větší než 0,4, je výřez tohoto obdélníku z původního obrazu považován za kandidáta.

Verifikace kandidátů

Každý kandidát je převeden do šedotónového formátu a pomocí Sobelova operátoru jsou v něm nalezeny vertikální hrany. Kandidát, jehož suma hodnot hranových bodů je vzhledem k jeho velikosti největší, je poté označen jako registrační značka a celý algoritmus detekce se ukončuje.

Vyhodnocení

Výše popsaným způsobem bylo správně detekováno 85,39 % z 527 registračních značek. Kvalita detekce výrazně závisí na čistotě a kvalitě černých rámečků okolo tabulky s registrační značkou. Pomocí této metody je tedy velmi obtížné nalézt značky s bílým rámečkem. Zároveň je vyšší úspěšnost detekce značek u vozidel s tmavým lakem než se světlým nebo úplně bílým.

Vzhledem k velmi vysokému rozlišení vstupních snímků 3264x2448 px je metoda velmi pomalá, jelikož musí při zpracování procházet velké množství dat. Ke zrychlení celého algoritmu by bylo výhodné snížit rozlišení snímků. Tím by ale klesla kvalita detekce, protože rámečky kolem registračních značek by vzhledem k degradaci informací ve snímku již nebyly tak detailně vykresleny.

4.6 Metoda Trkal_dp

Úvod

Tato metoda vznikla v rámci vymýšlení vlastní detekční metody, schopné co nejlépe pracovat s dostupnými databázemi fotografií popsanými v kapitole 3. Tyto galerie jsou velmi rozmanité, a proto je nutná velká robustnost výsledného algoritmu. Testování této metody bude rozebráno až v kapitole 6.4. Celý algoritmus vznikl kombinováním již zavedených či ověřených postupů z předchozích metod.

Při návrhu této metody bylo pracováno s předpokladem, že registrační značka na snímku je světlejší než její okolí. Nalezením těchto oblastí a následným vhodným verifikačním přístupem, by mohla vzniknout fungující lokalizační metoda.

Detekce kandidátů

Nejdříve je v rámci předzpracování každý analyzovaný snímek převeden na šedotónový. Pokud je šíře snímku větší než 1000 px, je kvůli urychlení algoritmu jeho rozlišení sníženo právě na tuto hodnotu se zachovaným poměrem výšky snímku. Dále je již jako originál považován právě tento zmenšený obraz.

Dokud není případný kandidát označen jako registrační značka, cyklicky se opakuje následující postup. V prvním cyklu je původní obraz zmenšen na 10% velikosti. Ve druhém na 20% atd. Od zmenšeného se odečte obraz vzniklý po aplikaci operace morfologické otevření se strukturním elementem o velikost 4 x 30 px podle vzorce (4.7), což je vlastně bottom-hat operace. Tento výsledný rozdíl je pomocí prahování (4.8) převeden na obraz binární. Tím je získán obraz zvýrazňující větší nahuštění detailů. Výsledné grafické podoby jsou na Obr. 4.14.



Obr. 4.14: Zleva: obraz po bottom-hat, binární mapa kandidátů, aplikovaná binární mapa na šedotónovém snímku

Na vzniklý obraz je aplikován algoritmus identifikace souvislých oblastí, který každému uzavřenému bílému objektu přiřadí jednoznačný identifikátor. Opsaný obdélník každého objektu je následně analyzován a při splnění všech dále uvedených podmínek je označen za kandidáta. Tyto podmínky byly nastaveny experimentálně analýzou dostupných registračních značek a vyplývají především ze znalosti geometrické podoby registrační značky:

- Poměr šířky ku výšce je v intervalu (2, 6),
- jeho šíře menší než polovina šíře binárního obrazu,
- jeho šíře je větší než patnáctina šíře binárního obrazu,
- jeho šíře je větší než 50 px,
- poměr počtu bílých pixelů ku všem je větší než 0,3.

Verifikace kandidátů

Byly vyzkoušeny tři způsoby verifikace. Nejhorší výsledky vykazovalo použití vertikální amplitudové projekce binárního snímku a následné počítání vrcholů na vzniklé křivce. Lepší výsledky přineslo využití výpočtu hustoty hranových bodů a její rovnoměrné rozložení v oblasti kandidáta podle postupu z kapitoly 4.4.

Ovšem nejlepších výsledků bylo dosaženo při využití metody založené na geometrických podmínkách objektů. Tím je myšleno to, že se provede analýza nespojených objektů na binárním snímku kandidáta. Následně se počítá počet objektů, které by mohly odpovídat alfanumerickému znaku. Kandidát je označen za registrační značku, pokud je počet těchto objektů v rozmezí 6 až 8. Aby byl objekt považován za znak, musí splňovat následující experimentálně určené podmínky:


- nesmí se dotýkat okraje obrazu,
- poměr výše k šíři objektu musí být větší než 0,9,
- výše objektu musí být větší než třetina výše kandidáta,
- šíře objektu musí být menší než pětina šíře kandidáta a
- šíře objektu musí být větší než dvacetina šíře kandidáta.

Vyhodnocení

Při návrhu bylo zjištěno, že mezi kandidáty se registrační značka dostane téměř vždy, a tedy kvalita metody závisí na kvalitě verifikace kandidátů.

Konkrétním vyhodnocením úspěšnosti se budou zabývat ještě další kapitoly v této práci, ale předpokládá se, že algoritmus bude schopný pracovat s velkým rozsahem rozlišení vstupních fotografií. Zároveň se metoda hodí na aplikace, v nichž je nutné rozpoznat tu největší registrační značku na snímku.

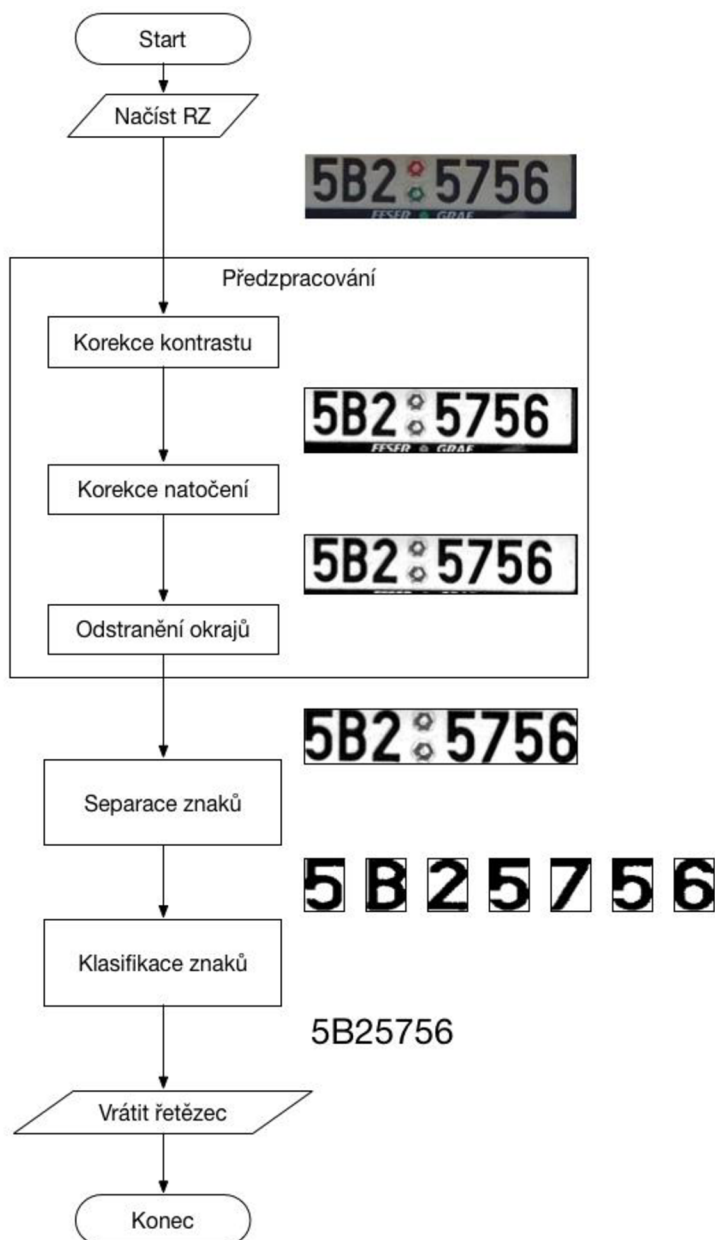
4.7 Výstupy lokalizace



Obr. 4.15: Možné vstupy a výstupy z lokalizačního algoritmu

5 ROZPOZNÁVÁNÍ ZNAKŮ

Rozpoznávání znaků je po lokalizaci registrační značky druhou částí celého řetězce automatického rozpoznávání registrační značky. Cílem je vytvořit algoritmus, který bude schopný klasifikovat jednotlivé alfanumerické znaky z výřezu registrační značky a jehož výstupem bude odpovídající digitální řetězec znaků. Tento řetězec je poté možné jednoduše ukládat či porovnávat s případnou dostupnou databází registračních kódů.



Obr. 5.1: Schéma rozpoznávání znaků

V rámci rozpoznávání je nutné provést několik kroků, jenž vedou k požadovanému výsledku. Především je nutné normalizovat výstup z lokalizačního algoritmu, jelikož lze předpokládat, že značka nebude nikdy naprosto přesně detekována, což je vidět i na Obr. 5.2. Dále v závislosti na využití klasifikační metodě je potřebné jednotlivé znaky separovat, protože použité klasifikátory dokážou zpracovat pouze jeden znak. Zásadním nástrojem pro klasifikaci je příznakový vektor a samotný klasifikátor, jenž vstupnímu vektoru přiřadí jednu z výstupních tříd. Cílem je vyzkoušet tři typově odlišné klasifikátory. Schéma postupu je na Obr. 5.1.

5.1 Předzpracování výřezu s registrační značkou

Jak již bylo zmíněno v předchozím textu, žádný z implementovaných lokalizačních algoritmů nedetekuje tabulku s registrační značkou naprosto přesně. Tato vlastnost se nejvíce projeví, pokud je značka natočená nebo zkreslená vlivem perspektivy. Několik příkladů detekovaných výřezů je na Obr. 5.2. Odstraněním uvedených nedostatků lze zvýšit následnou klasifikaci. Proto je navržen způsob korekce kontrastu, vyrovnání snímku a odstranění přebytečných okrajů.




Obr. 5.2: Příklady možných výstupů z lokalizačního algoritmu

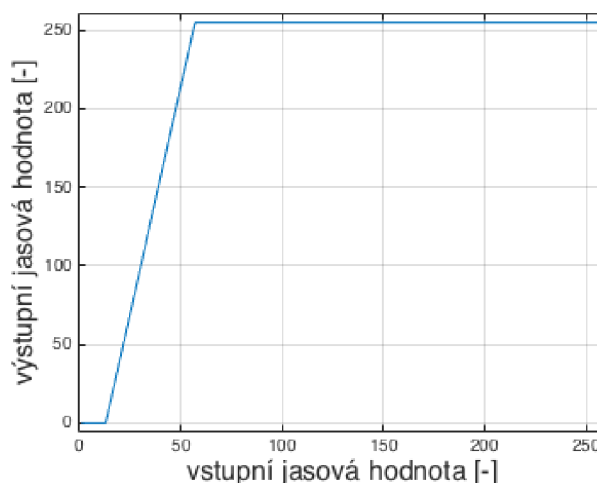
5.1.1 Korekce kontrastu

Z výřezů je patrné, že vlivem různých světelných podmínek při pořizování snímku nemají všechny výřezy stejný kontrast. Pokud na značku svítí nějaký zdroj světla (přírodní či umělý), lze předpokládat celkový posun histogramu do světlejších poloh. Důsledkem toho nemusí být barva černých znaků na snímku zcela černá, ale může přecházet do šedých odstínů. Naopak registrační značka umístěná ve stínu či snímaná ve tmě bude mít celkově tmavší charakteristiku a do šedých odstínů může přecházet naopak bílá barva tabulky. K eliminaci těchto kontrastních nesrovnalostí je na výřez se značkou, převedený do šedotónového formátu, aplikována lokální jasová transformace zvýšení kontrastu.

Analýzou dostupných značek bylo zjištěno, že na značce se vyskytuje přibližně 25 – 30 % černých pixelů příslušejících alfanumerickým znakům a zbytek přísluší bílému pozadí tabulky. Z toho důvodu byla pro transformaci jasu použita převodní charakteristika vždy přizpůsobena aktuálnímu vstupnímu obrazu, přičemž poloha spodního zlomu je volena tak, aby třetina nejtmařejších černých bodů příslušející ke znakům byla na výstupu zcela černá. Což odpovídá jasové hodnotě, pod níž se nachází 10 % nejtmařejších bodů na snímku. Charakteristika poté lineárně stoupá až do bodu horního zlomu, který je zvolen tak, aby na výstupu byla třetina všech světlých bodů příslušejících tabulce zcela bílá. Což odpovídá přibližně jasové hodnotě, nad níž se nachází 25 % nejsvětlejších bodů ze snímku. Pro výrazně tmavou registrační značku vyfotografovanou v noci (Obr. 5.3 vlevo) je potom převodní charakteristika znázorněna na Obr. 5.4. Výstup po korekci je ukázán na Obr. 5.3 vpravo.



Obr. 5.3: Tmavá registrační značka z noci (vlevo), po korekci kontrastu (vpravo)



Obr. 5.4: Převodní charakteristika pro vstupní obraz na Obr. 5.3 vlevo

5.1.2 Korekce natočení

Z výřezů na Obr. 5.2 je rovněž vidět, že některé značky nejsou, většinou vlivem nesprávné polohy fotoaparátu, ve správné horizontální rovině, ale jsou různě natočené. Mírně otočené znaky by mohly u použitých klasifikátorů výrazně ovlivnit celkovou úspěšnost rozpoznávání. V případě výrazněji natočené značky by mohl selhávat i samotný separační algoritmus, který bude rozebrán v následující kapitole. Pro srovnání značky do správné horizontální polohy bylo využito algoritmu korekce natočení.

Algoritmus pracuje následujícím způsobem. Nejdříve je výřez převeden do binární formy. Poté je zjištěn úhel orientace hlavní osy elipsy opsané největšímu bílému

objektu, který vlastně odpovídá tabulce s registrační značkou. O tento úhel je poté otočen nazpět celý výřez, čímž se značka dostává do správné horizontální polohy. Následně se odstraní horní a spodní okraje vzniklé při rotaci. Jednotlivé fáze jsou znázorněny na Obr. 5.5.




Obr. 5.5: Korekce natočení, zleva – prahování, rotace, odstranění okrajů z rotace

5.1.3 Odstranění okrajů

Posledním evidentním nedostatkem, kterého si lze na výřezech všimnout, jsou přebytečné okraje kolem sady znaků, které nemají pro další zpracování žádný užitečný význam. Pro jejich odstranění byly vyzkoušeny dva způsoby.

První využívá horizontální amplitudové projekce černých bodů binárního snímku výřezu. V projekci jsou poté nalezena dvě lokální minima, která odpovídají mezerám nad a pod sadou znaků. Tento způsob funguje spolehlivě v případě, že je značka v horizontální rovině. Jeho nevýhodou je ovšem odstranění pouze okrajů nad a pod sadou znaků, což ale v konečném důsledku nemusí vadit. Při pokusu o využití stejné metody pro odstranění bočních okrajů nebyly výsledky uspokojivé, jelikož nelze jednoznačně přímo určit lokální minimum odpovídající okraji značky. Naopak v některých případech byly takto odstraňovány i samotné znaky. Proto bylo nakonec použití toho postupu zamítnuto.

Druhý způsob využívá také pouze binární formy výřezu. V tomto binárním obrazu jsou poté vyhledávány objekty, které by měly odpovídat samotným alfanumerickým znakům. Této skupině vyhledaných objektů je následně opsán obdélník, který označuje hranici pro odstranění okrajů. Pravidla určující, zda objekt odpovídá nebo neodpovídá znaku jsou rozebrána v následující kapitole o separaci znaků pomocí geometrických podmínek, jelikož obě metody využívají principiálně stejných principů.




Obr. 5.6: RZ z Obr. 5.2 - odstranění okrajů s využitím geometrických podmínek

5.2 Separace znaků

Po předzpracování výřezu s registrační značkou přichází na řadu oddělení jednotlivých znaků od sebe. Separace je nutná, jelikož použité klasifikátory jsou schopné zpracovat vždy pouze jeden znaku odpovídající segment. Kvalitní výstupy ze separačního algoritmu jsou podmínkou pro následnou úspěšnou klasifikaci, protože separací lze přímo ovlivnit, jaká část obrazu se dostane na vstup klasifikátoru. Při návrhu optimálního separačního algoritmu byly vyzkoušeny dva přístupy, oba vycházející z binární formy obrazu s registrační značkou.

Během vývoje bylo zjištěno, že použitý způsob prahování má velký vliv na kvalitu použitých metod. Nejlepších výsledků bylo dosahováno při využití adaptivního prahování, které si lépe dokázalo poradit s nerovnoměrně osvětlenými značkami. Srovnání prahování pomocí metody Otsu a adaptivního prahování na problémové značce je ukázáno na Obr. 5.7. Na šedotónovém snímku je vidět částečný stín, který překrývá vrchní části znaků. Při využití metody Otsu je stín považován za objekt, což má za následek spojení všech znaků do jednoho objektu. Naopak při aplikaci adaptivního prahování je stín eliminován a jednotlivé znaky jsou odděleny tak, jak je potřebné pro použité metody.



Obr. 5.7: Ukázka prahování – nahoře šedotónový obraz, vlevo dole je výsledek adaptivního prahování, vpravo dole prahování pomocí Otsu

5.2.1 Separace pomocí geometrických podmínek

Tento první přístup využívá identifikaci a následnou analýzu uzavřených objektů na binárním snímku. Každý objekt z obrazu (Obr. 5.8), splňující všechny následující podmínky byl uznán jako alfanumerický znak a uložen k dalšímu zpracování. Tyto uznávací podmínky byly určeny experimentálně analýzou znaků z dostupných galerií a požadují, aby:


- poměr výšky k šířce objektu byl větší než 0,9,
- výše objektu byla větší než 1/2 výše obrazu se značkou,
- šíře objektu byla menší než 1/5 šíře obrazu se značkou a
- šíře objektu byla větší než 1/50 šíře obrazu se značkou.

Těmito podmínkami je zároveň zajištěna jednoduchá filtrace rušivých elementů. Metoda nejlépe funguje na snímcích, které jsou dobře rovnoměrně osvětleny. Nevýhodou

uvedeného přístupu je zhoršená separace poškozených znaků vlivem například odřené barvy. I drobné přerušení znaku na jednom místě může zapříčinit selhání separace a následně tedy i klasifikace.



Obr. 5.8: Separace vyhledáváním znaků, vstup vlevo, vizualizace výstupu vpravo



Obr. 5.9: Reálný výstup ze separačního algoritmu využívajícího geometrických podmínek



Obr. 5.10: Kolabující separace pomocí geometrických podmínek – vadí spojení 6 a B



Obr. 5.11: Kolabující separace pomocí geometrických podmínek – vadí vzájemné spojení znaků nahoře

5.2.2 Separace pomocí amplitudové projekce

Druhý vyzkoušený přístup separace znaků využívá vertikální amplitudové projekce černých pixelů. Ve výsledné projekci jsou následně hledána lokální minima, která označují mezery mezi znaky (Obr. 5.12). Amplitudová projekce je spočítána na invertovaném binárním obrazu registrační značky, takže pixely náležící objektu mají hodnotu 1 a pixely pozadí mají hodnotu 0. Potom lze vertikální projekci vypočítat dle vzorce:

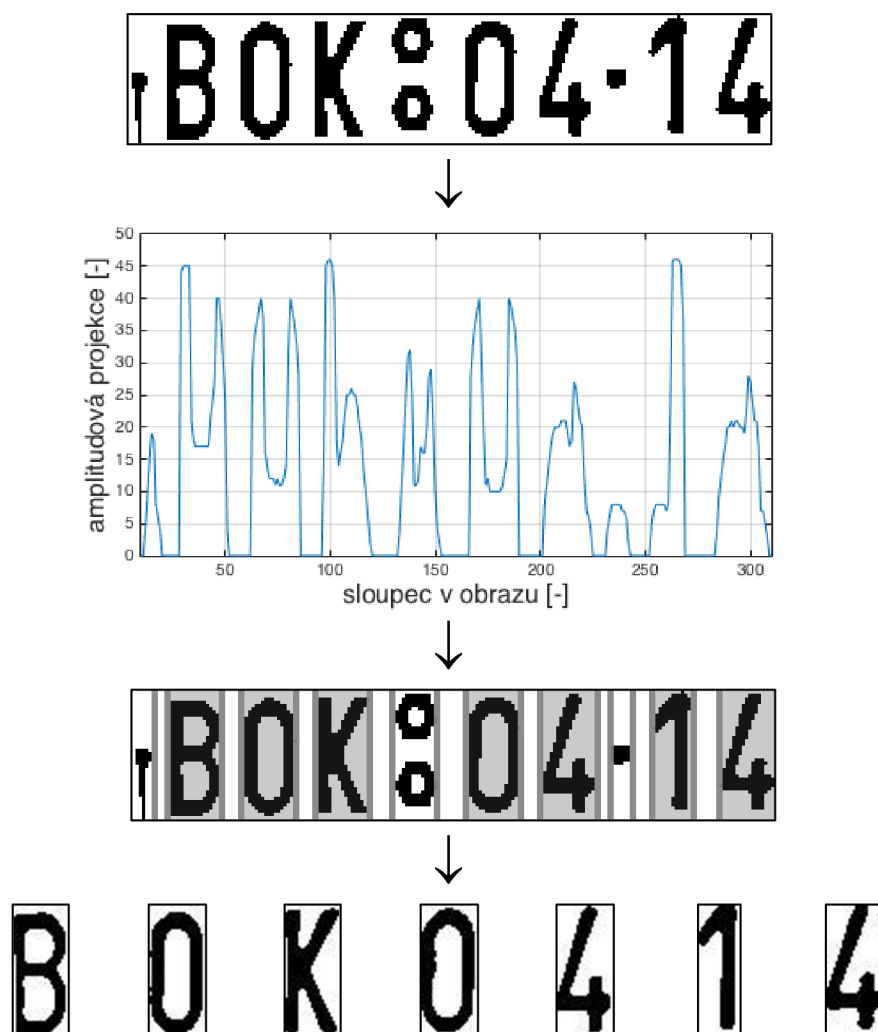
$$AP_v(x) = \sum_{y=1}^Y g(x, y), \text{ pro } x = 1 \dots X \quad (5.1)$$

Kde X je šíře obrazu, Y je výše obrazu, x je souřadnice sloupce, y je souřadnice řádku a $g(x, y)$ je hodnota pixelu vstupního obrazu na pozici x, y . Výsledek lze ještě normalizovat do intervalu od 0 do 1 dělením každého prvku z AP_v hodnotou Y , což ale není v této práci nutné.

Algoritmus je robustnější vůči drobnému zdánlivému spojení dvou a více znaků nečistotou, šroubem nebo stínem. Zároveň je algoritmus schopný zpracovat i některé hůře prahované snímky.

Na druhou stranu je nevýhodou navrženého algoritmu nutnost po oddělení jednotlivých oblastí znovu zkoumat, zda segment náleží znaku, či pouze nějaké nečistotě nebo stínu. Důležité taky bylo testovat, zda vyseparovaný objekt nenáleží emisní a STK známce. K vyřazení těchto známek došlo při splnění prosté podmínky, která zkoumala, zda se v prostředních řádcích vyseparovaného obrazu nenachází žádný černý pixel.

Během vývoje se ukázalo jako vhodné ještě před výpočtem projekce odstranit vodorovné dlouhé objekty odpovídající většinou stínům, jenž v obrazu zůstaly po prahování. A naopak po separaci je výhodné analyzovat nejvrchnější a nejspodnější šestiny vzniklého výřezu. Pokud je v těchto oblastech nalezen řádek neobsahující žádný černý pixel, je ještě v tomto řádku obraz oříznut.



Obr. 5.12: Separace pomocí projekcí, shora vstup, projekce, vizualizace, výstup

Během implementace a testování bylo zjištěno, že právě separace pomocí amplitudové projekce vykazuje lepší výsledky než druhý vyzkoušený přístup, a proto byla v této práci dále používána. Výhody projekcí se projeví především u poškozených a částečně zastíněných značek. U rovnoměrně osvětlených registračních značek vykazovaly oba přístupy výsledky stejně dobré.



Obr. 5.13: Kolabující separace projekce – vadi slabé spojení H




Obr. 5.14: Kolabující separace projekce – emisní známky nejsou vyfiltrovány

5.2.3 Normování znaku

Kvůli principu použitých separačních algoritmů má každý znak po separaci jinou velikost (Obr. 5.9 a Obr. 5.12 dole). Vlivem různě širokých znaků se liší především jejich šíře. V důsledku nečistot, stínů a perspektivy se ale může lišit i jejich výše. Pro klasifikátor je nepřijatelné, aby vstupní data měla různou délku, proto je po separaci nutné každý znak normovat na stejnou velikost.

Vzhledem k dalšímu zpracování se nejvíce osvědčil normalizační obdélník o velikosti 60 x 42 pixelů. Tyto rozměry byly experimentálně zvoleny tak, aby si každý znak zachoval dostatek detailů, přičemž je, kvůli následující tvorbě příznakového vektoru důležité, aby byly oba rozměry dělitelné šesti. Před normováním se odstraní přebytečné okraje kolem samotného znaku a poté je znak roztažen na celý obdélník tak, aby co nejvíce vyplnil celou plochu (Obr. 5.15). Znaky sice ztratí původní poměr, ale jejich vzájemná separabilita se tím zvýší.



Obr. 5.15: Separované znaky před (nahore) a po (dole) normalizaci

5.3 Klasifikace znaků

Při tvorbě této kapitoly bylo čerpáno z [30] a [32]. Smyslem klasifikace znaku je zařadit již předzpracovaný binární obraz s alfanumerickým znakem do třídy určující, který znak je na vstupním obrazu. O kvalitě klasifikace rozhoduje několik faktorů. Je to především kvalita vstupních dat, způsob popisu obrazu se znakem, zvolený klasifikátor a jeho tréninková množina. Klasifikátor rozřazuje znaky do 10 číselných tříd (0 – 9) a do 22 písmenových tříd obsahující znaky abecedy bez písmen s diakritikou a bez písmen „G“, „O“, „Q“ a „W“, která se na značkách nevyskytují.

Další zlepšení kvality může zajistit implementace obecných znalostí o strukturách značek, které se na vozovkách vyskytují ve starém i novém formátu z roku 2001. Tím je myšleno především pravidlo o uspořádání registrační značky, ve kterém se při kombinaci obou základních formátů předpokládá:


- přítomnost sedmi alfanumerických znaků,
- na první pozici se může vyskytovat číslice i písmeno,
- na druhé pozici se vyskytuje pouze písmeno,
- na třetí pozici se může vyskytovat číslice i písmeno,
- na čtvrté až sedmé pozici se vyskytuje pouze číslice.

Na základě těchto znalostí a pozice klasifikovaného znaku je poté omezen počet výstupních tříd buď pouze na číslice, nebo pouze na písmena, případně na obojí. Výjimku tvoří číslice 0, která se musí vyskytovat i v množině písmen, kde zastupuje písmeno „O“, které se objevuje na registračních značkách staršího formátu.

5.3.1 Tréninková množina

Jedním z nejdůležitějších faktorů ovlivňujících schopnosti všech klasifikátorů je zvolená tréninková množina. Jednotlivé prvky z této množiny by měly dostatečně charakterizovat danou třídu, přičemž ideálně by měl být počet prvků příslušejících k jednotlivým třídám shodný. V této práci byly použity dvě tréninkové množiny.


První množina, jenž bude dále pracovní nazývána jako „množina šablon“, je vygenerována přímo ze vzorů alfanumerických znaků ze zákona č. 243/2001 Sb. – o registraci vozidel. Vzory jsou ukázány na Obr. 5.16. U této množiny se předpokládá, že každé třídě přísluší pouze jeden prvek, jenž danou třídu nejlépe charakterizuje. Tato množina je použita především jako soubor šablon pro klasifikaci pomocí metody *template matching*.




Obr. 5.16: Vzory alfanumerických znaků ze zákona č. 243/2001 Sb. – o registraci vozidel

Druhá tréninková množina, která bude dále pracovně nazývána jako „množina vektorů“, obsahuje znaky přímo vyseparované z reálných snímků (Obr. 5.17) a převedené na příznakové vektory, jejichž struktura bude popsána v následujícím textu. Maximální počet znaků patřících do jednotlivých tříd byl stanoven na 30. Tohoto limitu ovšem některá písmena nedosáhla, jelikož nebyl k dispozici jejich dostatečný počet. Nejméně se vyskytující písmena v dostupných galeriích byla především „F“, „N“, „V“, „X“ a „Y“.

Každý binární obraz znaku o normované velikosti 60 x 42 px z druhé tréninkové množiny je zakódován do příznakového vektoru pomocí plovoucího okna. Toto okno o velikosti 6 x 6 px se postupně posunuje po obrazu se znakem po krocích 3 px tak, jak je naznačeno na Obr. 5.18. V každé pozici je potom spočten poměr mezi počtem pixelů příslušejících znaku ku celkové ploše okna. Tento způsob popisu byl vybrán na základě dobrých výsledků v předchozí práci [29] a v článkách [8], [30].



Obr. 5.17: Příklad znaků z reálných snímků



Obr. 5.18: Naznačení pohybu plovoucího okna při vytváření příznakového vektoru

5.3.2 Naivní bayesovský klasifikátor

Bayesovské klasifikátory jsou pravděpodobnostní modely založené na Bayesovu teorému. Pravděpodobnostní modely se dají dobře použít v problémech, ve kterých není možné nalézt přímo přesné řešení a je nutné stanovit, jak pravděpodobné jsou jednotlivé hypotézy.

Podle Bayesova teorému je podmíněná pravděpodobnost $P(y_c|\mathbf{x})$ třídy y_c , když na vstupu je vektor $\mathbf{x} = (x_1, \dots, x_n)$ určena jako:

$$P(y_c|\mathbf{x}) = \frac{P(\mathbf{x}|y_c)P(y_c)}{P(\mathbf{x})} \quad (5.2)$$

kde $P(y_c)$ je určeno početním podílem třídy y_c v tréninkovém setu. $P(\mathbf{x})$ není pro klasifikaci relevantní, jelikož je porovnávána u různých y_c na stejném \mathbf{x} a je tedy konstantní. Jediná neznámá je potom $P(\mathbf{x}|y_c)$. Naivní bayesovský klasifikátor předpokládá, že n atributů jsou v každé třídě navzájem nezávislé, poté lze podmíněnou pravděpodobnost $P(\mathbf{x}|y_c)$ vypočítat podle:

$$P(\mathbf{x}|y_c) = \prod_{i=1}^n P(x_i|y_c) \quad (5.3)$$

V tréninkové fázi je poté nutné určit pravděpodobnost $P(y_c)$ pro všechna y_c z množiny tříd C . A v testovací fázi se určuje $P(x_i|y_c)$ pro všechny atributy (x_1, \dots, x_n) . V klasifikační fázi je testovací instance $\mathbf{x} = (x_1, \dots, x_n)$ přiřazena do třídy y :

$$y = \underset{c \in \{1, \dots, C\}}{\operatorname{argmax}} P(y_c) \prod_{i=1}^n P(x_i|y_c) \quad (5.4)$$

Vnitřní výpočet funkce argmax neudává konkrétní pravděpodobnost, jelikož při výpočtu bylo zanedbáno $P(\mathbf{x})$. Pravděpodobnost ale lze získat, pokud se všechny dílčí výsledky pro všechna c normují tak, aby byl jejich součet roven 1.

Pro názornost jsou zde uvedeny jednotlivé výsledky pravděpodobností při klasifikaci znaku z Obr. 5.19. pomocí tréninkové množiny vektorů, jejíž část je na Obr. 5.17. Aby byly hodnoty názorné, jsou normovány tak, jak je uvedeno v předchozím odstavci. Po výpočtu všech jednotlivých pravděpodobností udává *naivní bayesovský* klasifikátor, že znak na Obr. 5.19 patří s pravděpodobností $P(y_8|\mathbf{x}) = 0,827$ do třídy „8“, přičemž vektor \mathbf{x} odpovídá příznakovému vektoru vytvořenému ze vstupního obrazu. Druhá nejvyšší pravděpodobnost patří třídě „0“ a je $P(y_0|\mathbf{x}) = 0,113$. Hodnoty pravděpodobností pro zbylých 30 tříd jsou již nižší než 0,05.



Obr. 5.19: Klasifikovaný znak pomocí naivního bayesovského klasifikátoru

5.3.3 Klasifikátor k-NN

Další z možností, jak klasifikovat vzor do jedné ze tříd, je pomocí pravidla nejbližšího souseda. Jedná se o relativně přímočarou a snadno implementovatelnou metodu. Pro každou třídu existuje jeden nebo více reprezentantů, kteří se vyberou tak, aby ji co nejlépe charakterizovali. Při klasifikaci příznakového vektoru nezařazeného segmentu se spočte jeho vzdálenost od všech reprezentantů ze všech tříd. Vzor je potom přiřazen do té třídy, která odpovídá „k“ nejbližším reprezentantům.

Při výpočtu vzdálenosti vzoru od reprezentanta je důležité vybrat správnou metriku, jejíž volba dokáže výrazně ovlivňovat výsledky klasifikace. V této práci byla pro výpočet vzdálenosti dvou n-dimensionálních příznakových vektorů $\mathbf{x} = (x_1, \dots, x_n)$ a $\mathbf{y} = (y_1, \dots, y_n)$ vyzkoušena euklidovská (5.5) a pravoúhlá (5.6) vzdálenost, přičemž lepších výsledků bylo dosahováno s použitím vzdálenosti euklidovské.

$$\text{Euklidovská vzd.: } |\mathbf{x} - \mathbf{y}| = \sqrt{(x_1 - y_1)^2 + \dots + (x_n - y_n)^2} \quad (5.5)$$

$$\text{Pravoúhlá vzd.: } |\mathbf{x} - \mathbf{y}| = (x_1 - y_1) + \dots + (x_n - y_n) \quad (5.6)$$

Jednotliví reprezentanti byli vybíráni z tréninkové množiny. Vybrány byly správně segmentované a na pohled pěkné znaky. Experimentálně bylo ověřováno na dostupných snímcích zjištěno, že klasifikátor dosahuje nejlepších výsledků při $k = 4$ a počtem maximálně 30 reprezentantů v každé třídě. Nevhodné je použití $k = 1$, protože poté již klasifikátor nedokáže generalizovat.

Při klasifikaci jednoznačného znaku číslice „9“ z Obr. 5.20 při použití trénovací množiny z Obr. 5.17 odpovídá prvních 30 nejbližších sousedů všem 30 tréninkovým vzorům číslice 9. Jejich vzdálenost od testovaného znaku se pohybuje relativně rovnoměrně v intervalu 3,24 až do 11,73. Vzdálenost nemá žádné jednotky, jelikož použitý příznakový vektor nezastupuje žádné reálné či představitelné vzdálenosti. První čtyři nejbližší sousedi jsou potom od vzorku ve vzdálenosti 3,24; 3,40; 4,00 a 4,00. Následující 31. nejbližší trénovací vzor je vzdálen 20,92 a odpovídá znaku „S“. Je tedy patrný téměř dvojnásobný nárůst vzájemné vzdálenosti u prvního neodpovídajícího reprezentanta. Nejevzdálenější vzory zastupují především znaky „4“ a „T“ a jejich vzdálenost od testovacího vzorku je již přes 120.



Obr. 5.20: Klasifikovaný znak pomocí k -NN

5.3.4 Template matching

Klasifikační metoda srovnávání se šablonou, která na rozdíl od k -NN nevyužívá konkrétní reprezentanty z trénovací množiny vektorů, ale hledá maximální podobnost se šablonou ideálního reprezentanta z množiny znaků na Obr. 5.16. Podobnost dvou metrických proměnných, v tomto případě obrazu znaku a šablony, lze postihnout vztahem, jehož míru je možné zjistit korelačním koeficientem.

Korelační koeficient r lze pro dva dvourozměrné obrazy $A(k, l)$ a $B(k, l)$ o rozměrech m, n vypočítat dle vzorce (5.7). Koeficient nabývá hodnot od -1 do 1, které značí perfektní záporný či kladný lineární vztah. V případě neexistence vztahu je hodnota koeficientu rovna 0. Výhodou korelačního koeficientu je nezávislost na jednotkách původních veličin.

$$r = \frac{\sum_{k=1}^m \sum_{l=1}^n (A_{kl} - \bar{A})(B_{kl} - \bar{B})}{\sqrt{(\sum_{k=1}^m \sum_{l=1}^n (A_{kl} - \bar{A})^2)(\sum_{k=1}^m \sum_{l=1}^n (B_{kl} - \bar{B})^2)}} \quad (5.7)$$

Při klasifikaci vzoru je tedy nutné spočítat korelační koeficienty pro každou šablonu. Vzor je poté klasifikován do té třídy, jejíž šablona dosáhla nejvyšší hodnoty korelačního koeficientu. Z výše uvedeného popisu metody srovnání se šablonou vyplývá, že klasifikátor pro svoji funkčnost nepotřebuje žádné vytváření příznakového vektoru, ale pracuje přímo s hodnotami pixelů šablony a vzoru. Což může způsobovat nízkou odolnost vůči šumu a nulovou schopnost generalizace.

Při výpočtu korelačních koeficientů mezi testovaným vzorem z Obr. 5.21 a všemi šablonami vytvořenými z tréninkové množiny z Obr. 5.16 dosáhla nejvyšší hodnoty ($r_6 = 0,798$) třída zastupující znak „6“, což je správně. Druhá nejvyšší hodnota z výsledných korelačních koeficientů náleží číslici „8“ a je tedy $r_8 = 0,692$. Tato skutečnost odpovídá i reálnému vjemu podobnosti „6“ s „8“. Relativně vysoké korelační koeficienty odpovídaly ještě třídám „B“ a „C“ ($r_B = 0,635$, $r_C = 0,590$). Naopak nejmenší korelační koeficient měla třída „T“ s hodnotou $r_T = -0,158$.



Obr. 5.21: Klasifikovaný znak pomocí template matchingu

6 EXPERIMENTÁLNÍ ČÁST

Cílem experimentu bylo ověřit kvalitu implementovaných metod pro lokalizaci registrační značky a pro rozpoznávání znaků ze značky. Vyhodnocení probíhalo postupně po částech. V rámci testování lokalizace se nejdříve určovala celková úspěšnost metod vždy vztažená k jednotlivým databázím a poté byly prozkoumány problémové scény snímků, ze kterých metody nebyly schopné detekovat značky. Při testování rozpoznávání znaků se také nejdříve zjišťovala úspěšnost klasifikace v jednotlivých galeriích. Následně byla provedena analýza špatně rozpoznávaných znaků v rámci jednotlivých klasifikátorů.

6.1 Implementace

Celý vývoj, implementace i testování byly prováděny na přenosném počítači MacBook Air 13' modelu z roku 2013:

- s procesorem 1,3 GHz Intel Core i5,
- pamětí DDR3 4 GB 1600 MHz,
- grafickou kartou Intel HD 5000 a
- 128 GB SSD diskem.

Na notebooku byl nainstalován systém OS X El Capitan verze 10.11.4. Pro vývoj a programování bylo použito vývojové prostředí MATLAB R2015a v edici určené pro systémy Mac OS X. K dispozici byl především Image Processing Toolbox. Naopak vývoj se obešel bez pomoci Computer Vision Toolboxu a Image Acquisition Toolboxu.

6.1.1 Implementace lokalizačních metod

V práci bylo naimplementováno 5 lokalizačních metod využívajících různé přístupy. Tři metody vycházejí z článků [17], [28], [34]. Zbylé dvě jsou dílem autora této práce. Názvy metod jsou stejně jako v kapitole 4 pro přehlednost voleny dle jména prvního autora algoritmu.

Převzaté metody bylo obtížnější reprodukovat, jelikož v člancích nebyly vždy všechny kroky detailně popsány. Proto bylo nutné při implementaci každý krok pečlivě zvážit a číselné konstanty ladit. Zároveň bylo nutné vzít v úvahu, že tři převzaté metody nebyly navrženy přímo na rozpoznávání registračních značek České republiky. Kvůli těmto důvodům lze předpokládat, že metody nebudou dosahovat takové kvality a přesnosti, jaké zmiňovali autoři v člancích.

Aby převzaté metody správně fungovaly, bylo nutné před lokalizací každý obraz z použitých galeriích převést na nižší rozlišení, s nímž pracovali autoři metody. Ti měli ve většině případů fotografie o rozměrech 800 x 600 px nebo menší. Poté se již implementuje konkrétní postup z kapitoly 4. V následujícím textu jsou stručně zmíněny postupy, které se v rámci implementace algoritmů použily.

Metoda mahini

Metoda *mahini* z [17] kombinuje několik principů najednou. Nejdříve se změní rozlišení snímku na malé s šířkou 100 px. Paralelně se z každého snímku vypočte obraz zvýrazňující oblasti s větším nahuštěním vertikálních hran pomocí matematické morfologie, obraz zvýrazňující šedě vypadající oblasti, obraz potlačující barevné oblasti a obraz zvýrazňující světlé regiony. Po složení těchto tří obrazů lze získat potenciální kandidáty registračních značek. Každý kandidát poté projde verifikačním procesem a je buď vyřazen nebo zvolen jako registrační značka. Pokud není žádná značka nalezena, je snímek zvětšen a celý proces se opakuje.

Metoda tarabek

Metoda vychází ze článku [28]. Základním principem je výpočet obrazu hran, na který je aplikováno posuvné okno. Okno po projití celého obrazu cyklicky zvětšuje svoji velikost. Pro každou polohu okna je spočítána hustota hranových bodů. Pokud tato hustota překročí určitý práh a zároveň je rozložení hranových bodů přibližně rovnoměrné, je oblast tohoto okna uložena. Po výpočtu dojde ke sjednocení všech uložených poloh okna a tyto sjednocené oblasti jsou poté považovány za kandidáty. Pokud tento kandidát splňuje podmínky odpovídajícího poměru stran a dostatečně vysokému jasu, je prohlášen za registrační značku.

Metoda zhai

Metoda *zhai* ze článku [34] využívá téměř výhradně matematické morfologické operace s binárními i šedotónovými snímky. Nejdříve se zvýrazní oblasti s potenciálním nahuštěním hran odečtením morfologicky otevřeného obrazu od šedotónového originálního obrazu. Výsledek se prahováním převede na obraz binární. Dalším morfologickým otevřením s malým strukturálním elementem jsou odstraněny drobné objekty. Nakonec jsou blízké objekty spojeny morfologickým uzavřením. Objekty na výsledném binárním obrazu odpovídaly oblastem potenciálních kandidátů. Pokud oblast splňovala poměrové podmínky a zároveň odpovídající výřez obsahoval dostatečný počet vysokých černých objektů, tedy nejspíše alfanumerických znaků, byla prohlášena za registrační značku.

Metoda trkal_bp

Tato metoda přejatá z [29] využívá jednoduché skutečnosti, že každá registrační značka je umístěna v černém rámečku, a tento rámeček tedy odděluje bílou plochu značky od okolí. Proto je snímek převeden prahováním na binární a 50 největších bílých oblastí je analyzováno. Za registrační značku je poté prohlášena největší oblast splňující validační podmínky o hustotě hranových bodů.

Metoda trkal_dp

V rámci předzpracování je každý analyzovaný snímek převeden na šedotónový. Kvůli urychlení algoritmu je rozlišení snímku sníženo na šíři 1000 px se zachovaným poměrem výšky snímku. Dále je již jako originál považován právě tento zmenšený obraz.

Dokud není nalezena značka, cyklicky se opakuje tento postup: V prvním cyklu je obraz zmenšen na 10 % původní velikosti. Ve druhém na 20 % atd. Od něho se odečte obraz vzniklý po aplikaci operace morfologického otevření. Tento výsledný rozdíl je pomocí prahování převeden na obraz binární. Poté je každá bílá oblast analyzována a případně je označena za kandidáta, pokud obdélník opsaný této oblasti splňuje patřičné podmínky z kapitoly 4.6.

6.2 Implementace rozpoznávání znaků

V rámci implementace předzpracování registrační značky před rozpoznáváním znaků byly implementovány postupy z kapitoly 5. Předně šlo o korekci kontrastu s využitím převodní charakteristiky. Dále bylo korigováno natočení značky pomocí zjišťování polohy hlavní osy elipsy opsané objektu náležícímu registrační značky. Poté se dojde k přesnému oříznutí přebytečných okrajů kolem znaků.

Při implementaci separace znaků byly naprogramovány oba vyvinuté separační algoritmy, a to separace pomocí amplitudové projekce a separace pomocí geometrických podmínek. Každý separovaný znak byl poté normalizován na konstantní velikost a podle použitého klasifikátoru byl vypočten příznakový vektor pomocí plovoucího okna.

Zároveň byly implementovány tři klasifikátory popsané v kapitole 5.3. Jedná se o *naivní bayesovský* klasifikátor, *k-NN* a klasifikátor využívající *template matching*. Všechny tyto klasifikátory dodržovaly heuristiku využívající znalost o pozici písmen a číslic popsanou v kapitole 5.3.

6.3 Testovací skript

Testovací skript byl naprogramován ve vývojovém prostředí Matlab za účelem vyhodnocení úspěšnosti jednotlivých lokalizačních algoritmů a jednotlivých klasifikátorů. Výsledky lokalizace a rozpoznávání znaků byly kvůli vizuální kontrole aktuálních výsledků přímo zobrazovány na originálním snímku. Zároveň se průběžné výsledky testování ukládaly do paměti a na konci testování dané galerie snímků mohly být vyvolány a zobrazeny.

Skript se na počátku zeptá na cestu k adresáři se snímky. Pokud je ve vybraném adresáři soubor „Anotace.csv“, jsou z něho anotační data načtena do paměti a zároveň je načten seznam snímků z adresáře. Jestliže se tento soubor v adresáři nevyskytuje, je načten pouze seznam snímků a skript pouze zobrazuje výsledky z navrženého systému a testování neprobíhá.

U aktuálního vybraného snímku skript ověří, zda obsahuje anotovanou registrační značku v anotačním souboru. Dále tento skript předá snímek jako vstupní data funkci obstarávající lokalizaci značky, která vrací souřadnice kandidátů registračních značek. Poloha anotovaných značek byla ve snímku zobrazena zeleně i s alfanumerickým kódem značky a poloha kandidátů nalezených lokalizačním algoritmem se zobrazuje modře i s řadou znaků rozpoznaných klasifikátorem. V ideálním případě by se samozřejmě tyto oblasti měly překrývat.



Obr. 6.1: Zobrazení snímku testovacím skriptem

Porovnáním souřadnic načtených z anotací a souřadnic nalezených lokalizačním algoritmem se zjišťuje, zda byla značka správně lokalizována. Pro testovací účely byla tolerována odchylka vzdálenosti každého z rohu značky od jeho správné polohy o maximálně 20 % z šíře anotované značky. Jestliže byla registrační značka opravdu korektně lokalizována, tedy souřadnice všech rohů se překrývaly s uvedenou tolerancí, pak je kandidát označen jako „true positive“. Pokud byla za značku prohlášena oblast, jenž registrační značkou není, je kandidát označen jako „false positive“. V případě, že značka ve snímku je, ale není detekována, je tato značka prohlášena za „false negative“.

Tímto způsobem lze jednoduše porovnávat různé metody lokalizace registračních značek. Zároveň se porovnáváním výstupního řetězce z klasifikátorů znaků a řetězcem zapsaným v anotačním csv souboru určuje úspěšnost klasifikace jednotlivých znaků. Do paměti je ukládán počet správně rozpoznaných znaků, počet špatně rozpoznaných znaků,

počet správně rozpoznaných celých registračních značek a počet špatně rozpoznaných značek. Značka je označena za správně rozpoznanou, pokud je správně klasifikována všech 7 znaků na značce. Značka je označena za špatně rozpoznanou, pokud výstupní řetězec obsahuje 7 znaků, ale nějaký není správně rozpoznáný.

Pro ovládání testovacího skriptu je nutné využívat klávesové zkratky. Zde je uveden seznam ovládacích kláves:

- → ... přechod na další snímek,
- ← ... přechod na předchozí snímek,
- „a“ ... automatické projití celé vybrané galerie,
- „r“ ... vypsaní testovacích výsledků do konzole,
- „m“ ... automatické procházení galerie, které se přerušilo, pokud systém špatně lokalizoval značku nebo špatně rozpoznal nějaký znak.

6.4 Testování lokalizace

Testování lokalizace probíhalo ve dvou fázích. V první se vyhodnocovaly především hodnotící parametry, ze kterých je možné určit kvalitu jednotlivých metod. V druhé části testování jsou analyzovány problémové scény, ve kterých měly lokalizační metody problém nalézt registrační značky.

6.4.1 Celková úspěšnost lokalizace

V rámci testování úspěšnosti lokalizace se u každé metody porovnával počet správně detekovaných značek (TP), počet falešně pozitivně označených oblastí (FP), počet nenalezených značek (FN) a doba trvání analýzy všech snímků v jednotlivých databázích uvedených v kapitole 3. Testování bylo provedeno vždy třikrát, jelikož na pozadí systému probíhají procesy, které nelze uživatelsky uspat, a které proto mohou ovlivňovat dobu zpracování. Pro lepší představivost jsou také časy vztaženy k jednomu snímku.

V běžných čtyřpolních tabulkách se vyskytuje i hodnota TN (správně nenalezená značka). Jelikož ale při testování lokalizace není TN explicitně snadno vyjádřitelné, není jeho hodnota při testování zjišťována a nepoužívá se v hodnotících parametrech.

Z hodnot TP, FP a FN je možné spočítat hodnotící parametry, které dokáží číselně ohodnotit úspěšnost lokalizace jednotlivých metod. Jedná se především o senzitivitu, přesnost, míru opomenutí a F míru. *Senzitivita* (6.1, TPR – true positive rate) udává, jak dobře je lokalizační metoda schopna najít ve snímku registrační značku. Senzitivitu lze vyjádřit i v procentech, potom číslo udává, kolik procent značek bylo nalezeno ze všech správných výsledků. *Přesnost* (6.2, PPV – positive predictive value) je ukazatel, který dokáže ohodnotit, jak moc jsou označené oblasti skutečně registrační značkou. Cílem dobře pracující lokalizační metody je, aby senzitivita i přesnost byly co nejvyšší. *Míra opomenutí* (6.3, FNR – false negative rate) hodnotí míru nenalezení registračních značek, které v obrazu jsou. Je důležité, aby hodnota FNR byla co nejnižší. *F míra* (6.4)

kombinuje přesnost a senzitivitu a je nejnázornějším ukazatelem kvality lokalizační metody.

U každé galerie je spočítána pouze senzitivita, ze které je ovšem na první pohled vidět, zda je metoda funkční. Ostatní parametry jsou spočteny až v přehledu souhrnných výsledků.

$$TPR = \frac{TP}{TP + FN} \quad (6.1)$$

$$PPV = \frac{TP}{TP + FP} \quad (6.2)$$

$$FNR = \frac{FN}{TP + FN} \quad (6.3)$$

$$F \text{ míra} = \frac{2TP}{2TP + FP + FN} \quad (6.4)$$

Tab. 1: Výsledky detekce registračních značek v databázi „db_parkoviste_zatazeno“

db_parkoviste_zatazeno - 121 snímků, 121 značek									
metoda	TP	TPR	FP	FN	t ₁	t ₂	t ₃	t	t _{photo}
	[-]	[%]	[-]	[-]	[s]	[s]	[s]	[s]	[s]
mahini	118	97,52	1	3	39,1	37,0	36,6	37,6	0,31
tarabek	58	47,93	54	63	27,7	28,8	29,7	28,7	0,24
zhai	106	87,60	12	15	20,2	21,1	19,2	20,2	0,17
trkal_bp	119	98,35	2	2	309,0	296,7	315,5	307,1	2,54
trkal_dp	120	99,17	0	1	20,3	18,7	19,7	19,6	0,16

V tabulce se na každém řádku nachází jednotlivé implementované metody a ve sloupcích jsou postupně hodnoty:

- TP – „true positive“ je počet správně označených registračních značek;
- TPR – senzitivita, procentuální poměr správně nalezených řešení;
- FP – „false positive“ je počet chybně označených oblastí;
- FN – „false negative“ je počet nenalezených registračních značek;
- t_1 až t_3 jsou doby, po kterou probíhala analýza;
- t je průměr z časů t_1 až t_3 , tedy $t = \frac{t_1+t_2+t_3}{3}$;
- t_{photo} je průměrná doba analýzy jednoho snímku.

Tab. 2: Výsledky detekce registračních značek v databázi „db_parkoviste_slunecno“

db_parkoviste_slunecno - 258 snímků, 258 značek									
metoda	TP	TPR	FP	FN	t ₁	t ₂	t ₃	t	t _{photo}
	[-]	[%]	[-]	[-]	[s]	[s]	[s]	[s]	[s]
mahini	214	82,95	5	44	146,5	137,6	145,7	143,3	0,56
tarabek	47	18,22	95	211	49,7	53,4	60,1	54,4	0,21
zhai	215	83,33	42	43	57,8	59,0	59,8	58,9	0,23
trkal_bp	216	83,72	42	42	485,6	479,9	485,1	483,5	1,87
trkal_dp	243	94,19	4	15	62,1	61,3	61,7	61,7	0,24

Tab. 3: Výsledky detekce registračních značek v databázi „db_slunecno“

db_slunecno - 35 snímků, 37 značek									
metoda	TP	TPR	FP	FN	t ₁	t ₂	t ₃	t	t _{photo}
	[-]	[%]	[-]	[-]	[s]	[s]	[s]	[s]	[s]
mahini	12	32,43	0	25	50,1	49,7	48,9	49,6	1,42
tarabek	6	16,22	24	31	9,9	9,6	8,1	9,2	0,26
zhai	11	29,73	4	26	7,2	7,0	7,3	7,2	0,20
trkal_bp	18	48,65	16	19	116,6	109,4	113,0	113,0	3,23
trkal_dp	31	83,78	0	6	37,7	40,1	36,8	38,2	1,09

Tab. 4: Výsledky detekce registračních značek v databázi „db_destivo“

db_destivo - 88 snímků, 87 značek									
metoda	TP	TPR	FP	FN	t ₁	t ₂	t ₃	t	t _{photo}
	[-]	[%]	[-]	[-]	[s]	[s]	[s]	[s]	[s]
mahini	44	50,57	1	43	107,8	102,0	104,8	104,9	1,19
tarabek	34	39,08	22	53	18,7	18,6	18,6	18,6	0,21
zhai	34	39,08	10	53	13,8	14,7	13,0	13,8	0,16
trkal_bp	56	64,37	32	31	243,6	260,3	244,0	249,3	2,83
trkal_dp	83	95,40	1	4	58,6	53,1	50,5	54,1	0,61

Tab. 5: Výsledky detekce registračních značek v databázi „db_tma“

db_tma - 19 snímků, 19 značek									
metoda	TP	TPR	FP	FN	t ₁	t ₂	t ₃	t	t _{photo}
	[-]	[%]	[-]	[-]	[s]	[s]	[s]	[s]	[s]
mahini	2	10,53	0	17	32,1	36,4	35,0	34,5	1,82
tarabek	7	36,84	1	12	3,9	4,0	4,5	4,1	0,22
zhai	8	42,11	0	11	2,8	2,6	2,8	2,7	0,14
trkal_bp	10	52,63	9	9	50,0	54,5	53,3	52,6	2,77
trkal_dp	17	89,47	0	2	7,1	7,5	8,2	7,6	0,40

Tab. 6: Výsledky detekce registračních značek v databázi „mpov_1“

mpov_1 - 90 snímků, 90 značek									
metoda	TP	TPR	FP	FN	t ₁	t ₂	t ₃	t	t _{photo}
	[-]	[%]	[-]	[-]	[s]	[s]	[s]	[s]	[s]
mahini	84	93,33	0	6	38,3	38,3	39,7	38,8	0,43
tarabek	34	37,78	37	56	19,7	19,3	18,9	19,3	0,21
zhai	79	87,78	7	11	16,1	15,1	17,2	16,1	0,18
trkal_bp	82	91,11	8	8	179,0	175,2	182,8	179,0	1,99
trkal_dp	88	97,78	1	2	18,4	19,5	19,2	19,0	0,21

Tab. 7: Výsledky detekce registračních značek v databázi „mpov_2“

mpov_2 - 45 snímků, 45 značek									
metoda	TP	TPR	FP	FN	t ₁	t ₂	t ₃	t	t _{photo}
	[-]	[%]	[-]	[-]	[s]	[s]	[s]	[s]	[s]
mahini	34	75,56	0	11	31,3	29,4	32,2	31,0	0,69
tarabek	7	15,56	12	38	40,1	9,4	9,5	19,7	0,44
zhai	29	64,44	6	16	7,4	7,1	7,5	7,3	0,16
trkal_bp	23	51,11	22	22	131,0	125,0	141,1	132,4	2,94
trkal_dp	40	88,89	1	5	13,8	11,4	11,4	12,2	0,27

Tab. 8: Výsledky detekce registračních značek v databázi „mpov_3“

mpov_3 - 79 snímků, 79 značek									
metoda	TP	TPR	FP	FN	t ₁	t ₂	t ₃	t	t _{photo}
	[-]	[%]	[-]	[-]	[s]	[s]	[s]	[s]	[s]
mahini	74	93,67	1	5	22,6	21,8	21,8	22,1	0,28
tarabek	17	21,52	37	62	18,8	18,2	18,1	18,4	0,23
zhai	75	94,94	7	4	15,2	15,0	15,3	15,2	0,19
trkal_bp	58	73,42	21	21	24,6	23,5	23,1	23,7	0,30
trkal_dp	79	100,0	0	0	10,6	8,7	8,1	9,1	0,12

Z Tab. 1, Tab. 6, Tab. 8 je patrné, že jednotlivé metody dosahují lepších výsledků lokalizace v zataženém počasí než ve slunečném, jelikož značky jsou většinou rovnoměrně osvětleny a nejsou zastíněny jinými objekty. Při slunečném počasí se naopak zvyšuje jasová složitost scén a kvalita detekce klesá, což je vidět především v Tab. 2, Tab. 3.

Nejlepších výsledků dosáhly metody při procházení databáze *db_parkoviste_zatazeno* (Tab. 1), což je nejspíše dáno malou rozmanitostí databáze, jednoduchými scénami a střední velikostí registračních značek na fotografiích. Výjimku tvoří metoda *trkal_dp*, která v databázi *mpov_3* detekovala správně všech 79 registračních značek. Zato jako nejobtížnější galerie pro detekci se jeví *db_slunecno* (Tab. 3) s velmi rozmanitými scénami, různě velkými značkami. Problémem je nejspíše i časté částečné zastínění tabulek s registrační značkou. Největší rozdíly ve výsledcích jsou vidět v tabulce pro *db_tma*, ve které je patrné, že tmavé snímky mnohým metodám vůbec nevyhovují.

Časy detekce vztažené na jeden snímek se u všech metod liší především v závislosti na komplexnosti scény. U metod *mahini* a *trkal_dp* se nejvíce projevuje nepřímá úměrnost, kdy při klesající úspěšnosti detekce stoupá čas potřebný k projití databáze, což vychází z jejich iteračního principu. Nejrychleji metody zvládly zpracovat galerii *mpov_3* (Tab. 8), což je dáno nízkým rozlišením fotografií i velkými značkami.

Speciálním případem testování bylo vyzkoušení, zda budou metody schopny detekovat značky na snímcích z databáze *camea*, které jsou typově odlišné od ostatních. Z Tab. 9 je patrné, že žádná metoda nebyla schopna fotografie správně zpracovat a značky lokalizovat. Důvodem by mohlo být především geometrické zkreslení, které značku deformuje a mění se tedy její poměr stran. Mnoho metod také mátl text, jenž je na fotografiích a který vytváří velké nahuštění hran. Protože žádná metoda nenalezla ani jednu značku, není tato galerie započítána v celkovém souhrnu v Tab. 10.

Tab. 9: Výsledky detekce registračních značek v databázi „camea“

camea - 21 snímků, 42 značek									
metoda	TP	TPR	FP	FN	t ₁	t ₂	t ₃	t	t _{photo}
	[-]	[%]	[-]	[-]	[s]	[s]	[s]	[s]	[s]
mahini	0	0,00	0	42	37,8	38,5	38,1	38,1	1,82
tarabek	0	0,00	21	42	5,7	5,3	5,4	5,5	0,26
zhai	0	0,00	0	42	3,9	3,5	3,5	3,6	0,17
trkal_bp	0	0,00	21	42	9,6	9,2	9,3	9,4	0,45
trkal_dp	0	0,00	0	42	17,9	17,1	16,9	17,3	0,82

Tab. 10: Souhrnné výsledky všech galerií bez databáze „camea“

všechny galerie, 735 snímků, 736 značek									
metoda	TP	TPR	FP	FN	PPV	FNR	Fm	t	t _{photo}
	[-]	[%]	[-]	[-]	[-]	[-]	[-]	[s]	[s]
mahini	582	79,08	8	154	0,986	0,209	0,878	461,6	0,63
tarabek	210	28,53	282	526	0,427	0,715	0,342	172,4	0,23
zhai	557	75,68	88	179	0,864	0,243	0,807	141,4	0,19
trkal_bp	582	79,08	152	154	0,793	0,209	0,792	1540,0	2,10
trkal_dp	701	95,24	7	35	0,990	0,048	0,971	221,5	0,30

- *TP* – „true positive“ je počet správně označených registračních značek;
- *TPR* – senzitivita, procentuální poměr správně nalezených řešení;
- *FP* – „false positive“ je počet chybně označených oblastí;
- *FN* – „false negative“ je počet nenalezených registračních značek;
- *PPV* – přesnost, $PPV = \frac{TP}{TP+FP}$;
- *FNR* – míra opomenutí, $FNR = \frac{FN}{TP+FN}$;
- *Fm* – F míra, $Fm = \frac{2TP}{2TP+FP+FN}$;
- *t* je průměrná doba zpracování všech snímků;
- *t_{photo}* je průměrná doba analýzy jednoho snímku.

Nejhorších výsledků celkově dosahuje metoda *tarabek*. Pouhých 28,53 % správně rozpoznaných značek a velmi vysoká míra opomenutí. Ač je průměrný čas zpracování jedné fotografie druhý nejlepší, nelze metodu považovat za použitelnou. I přesnost 0,427 je velmi nízká, jelikož algoritmus generuje velké množství *FP* i *FN* výsledků. Nelze tedy ani rozhodnout, zda jsou verifikační kritéria metody přísná či nikoliv. Nejlepší detekce bylo metodou dosaženo v databázi *db_parkoviste_zatazeno* ($TPR = 47,93 \%$), naopak nejhůře metoda detekovala v *db_tma* ($TPR = 15,56 \%$).

Metoda *zhai* dosáhla druhé nejhorší hodnoty $TPR = 75,68 \%$, což je ovšem i tak téměř třikrát lepší než *tarabek*. Nejlépe metoda lokalizovala registrační značky v *mpov_3* ($u_{gal} = 94,94\%$). Dle průměrného času $t_{photo} = 0,19$ s je tento algoritmus nejrychlejší ze všech vyzkoušených.

Algoritmy *mahini* a *trkal_bp* měly celkovou poměr správně detekovaných značek TPR shodný a to mírně přes 79 %. Ovšem metoda *mahini* má proti *trkal_bp* méně než třetinový čas detekce na jednom snímku a zároveň má mnohem lepší přesnost ($PPR = 0,986$). I dle F míry lze tedy usoudit, že *mahini* je lepší než *trkal_bp*. U *mahini* jsou velmi nízká čísla *FP* a naopak vysoká *FN*, z toho lze odvodit, že metoda má nejspíše velmi přísné verifikační podmínky. *Trkal_bp* je zdaleka nejpomalejším implementovaným algoritmem ($t_{photo} = 2,10$ s), což ale vychází z potřeby, aby na vstupu byly fotografie s nejvyšším možným rozlišením. To je vidět i v Tab. 8., ve které je sice relativně nízký čas zpracování, ale klesla i úspěšnost detekce.

Nejlepších výsledků dosáhla metoda *trkal_dp* s celkovou nejvyšší senzitivitou $TPR = 95,24 \%$, přesností $PPV = 0,990$ i F mírou $= 0,971$. Nejlépe si *trkal_dp* poradila s databází *mpov_3*. Rychlost algoritmu velmi záleží na komplexnosti galerií. Pokud algoritmus na dané galerii dobře detekuje, je i velmi rychlý. Relativní dobrá kvalita je také dána tím, že metoda byla laděna právě na dostupném souboru galerií. Zároveň s dobře nastavenou detekcí kandidátů a kvalitním verifikačním algoritmem bylo proto nejlepších výsledků dosaženo právě touto vlastní metodou.

6.4.2 Problémové scény

V následující části jsou rozebrány a prozkoumány scény a umístění registračních značek ve scéně, které dělají jednotlivým metodám problémy při detekci. Na snímcích níže jsou zobrazeny právě chybně zpracované scény. Modře jsou označeny oblasti, které vybral lokalizační algoritmus, a zeleně je označeno správné řešení.

Algoritmus *mahini* má problém především se zastíněnými a zároveň špinavými registračními značkami ve scéně, jenž je pořízena za slunečného počasí. Relativně malé značky jsou také velmi často špatně detekovány. Metoda naopak málokdy označí oblast jako značku, pokud tato oblast značkou není. Občas je v označené oblasti značka, ale tato oblast je větší, než je únosné. Snímky pořízené za tmy byly pro tuto metodu také velmi problémové.



Obr. 6.2: Některé chybně detekované registrační značky metodou mahini, správné řešení zeleně, nalezené modře

Metoda *tarabek* téměř nikdy nedetekuje menší tmavší značky na snímcích v deštivém počasí. Zároveň neoznačuje oblasti se značkami přesně. Právě naopak je běžné, že oblasti jsou větší než značka nebo je označena pouze část. Běžně je označena i oblast s větším nahuštěním hran, ve které značka není.

Zhai metoda nejčastěji nedetekuje menší a špinavé značky. Druhou nejčastější chybou je nepřesně označená oblast s registrační značkou. Většinou je oblast rozšířena buď vertikálně, nebo horizontálně. Problém s přesností je ovšem komplexní a i oblasti, které jsou nakonec uznány jako dobře detekované registrační značky, nekorrespondují s tabulkou registrační značky úplně přesně.

Nedokonalostí metody *trkal_bp* je, že vždy označí právě jednu oblast na snímku jako registrační značku a to tu oblast, která nejlépe splňuje verifikační podmínky. A právě u chybně detekovaných značek to byly například oblasti, jenž byly světlejší nebo celkově větší než registrační značka. Tento algoritmus má obecně problémy s rozmazanými snímky nebo se značkami, které nemají výrazný tmavý rámeček okolo světlé tabulky.

Poslední metoda *trkal_dp* nejhůře detekuje registrační značky, které jsou celkově velmi tmavé. Tedy značky špinavé či zastíněné. Tyto značky buď nejsou nalezeny vůbec, nebo je nalezena pouze jejich část. Dále algoritmus nenajde malé registrační značky, pokud se ve snímku nachází i nějaká jiná velká.



Obr. 6.3: Některé chybně detekované registrační značky metodou tarabek, správné řešení zeleně, nalezené modře



Obr. 6.4: Některé chybně detekované registrační značky metodou zahi, správné řešení zeleně, nalezené modře



Obr. 6.5: Některé chybně detekované registrační značky metodou `trkal_bp`, správné řešení zeleně, nalezené modře



Obr. 6.6: Některé chybně detekované registrační značky metodou `trkal_dp`, správné řešení zeleně, nalezené modře

6.4.3 Shrnutí lokalizace

Z hodnocení celkové kvality a především z Tab. 10 je patrné, že nejlépe na dostupných fotografiích detekuje značky algoritmus *trkal_dp*. Tento výsledek ovšem odpovídá i skutečnosti, že metoda byla vytvořena přímo galeriím na míru. Správně označila 95,24 % registračních značek, přičemž metoda generuje pouze malé množství falešně pozitivních označení. Ve scénicky konzistentních databázích pořízených při zataženém počasí bylo dosaženo i přes 97 % správně detekovaných značek.

Při zkoumání problémových scén bylo zjištěno, že všem implementovaným metodám dělají problémy podobné scény. Nejhůře byly detekovány špinavé zastíněné malé značky, kde je malý kontrast mezi černými znaky a bílým pozadím. Obecně lze konstatovat, že metody špatně lokalizují značky nasnímané z větších úhlů, což způsobuje deformaci značky na snímku.

Ze všech metod naprosto nejhůře detekovala metoda *tarabek*, která vlivem velmi nepřesného označování registračních značek dosáhla velmi nízké kvality lokalizace. To může být způsobeno i vysokým počtem pevných konstant v implementaci, jejichž hodnoty byly převzaty z [28], a které nemusejí být ideální pro soubor dostupných galerií.

6.5 Testování rozpoznávání znaků

V této kapitole jsou zobrazeny a zhodnoceny výsledky rozpoznávání jednotlivých znaků z registračních značek. V rámci testování byly vyzkoušeny všechny tři implementované klasifikátory na výstupu lokalizační metody *trkal_dp* ve všech dostupných databázích s výjimkou galerie *camea*, ve které se nepodařilo správně detekovat žádnou značku.

6.5.1 Celková kvalita rozpoznávání znaků

Kvalitu rozpoznávání znaků ovlivňuje kvalita vstupních dat, kterou zajišťuje separační algoritmus, a především použitý klasifikátor. Výběrem optimálního separačního algoritmu již je zajištěno, že na vstupy všech tří testovaných klasifikátorů přicházela shodná data. V následujících tabulkách jsou tedy zaznamenány výsledky testování implementovaných klasifikátorů, a to *naivního bayesovského*, *k-NN* a *template matchingu*.

Celý proces testování byl zautomatizován v testovacím skriptu tak, aby kvalita lokalizace a separace negativně neovlivňovala výsledky rozpoznávání znaků. Proto byly testovány pouze správně lokalizované značky, ze kterých bylo vyseparováno přesně 7 znaků. Všechny ostatní značky byly z testování vyřazeny. Z toho důvodu není počet testovaných značek v každé galerii shodný s počtem skutečně přítomných značek udávaným při testování lokalizace.

Pokud by se při testování stalo, že by bylo vyseparováno 7 znakům neodpovídajících segmentů, uměle by se tím zhoršila úspěšnost klasifikátorů, protože klasifikované segmenty by byly porovnávány se správným řetězcem z anotátoru. Jelikož by se ale chyba projevila při testování všech klasifikátorů stejně, neměla by na jejich vzájemné porovnání žádný vliv, a proto nebylo nutné zajišťovat její eliminaci manuálním procházením všech snímků.

Pro každý klasifikátor byl tedy testován počet správně a špatně klasifikovaných znaků, počet správně a špatně rozpoznaných celých registračních značek a procentuální úspěšnost rozpoznávání znaků i značek. Správně rozpoznanou registrační značkou se myslí značka, ze které jsou správně klasifikovány všechny znaky.

Tab. 11: Výsledky klasifikace znaků v databázi „db_parkoviste_zatazeno“

db_parkoviste_zatazeno – 120 značek a 840 znaků ke klasifikaci						
klasifikátor	Znaky		Značky		Úspěšnost	
	správně	špatně	správně	špatně	znaky	značky
	[-]	[-]	[-]	[-]	[%]	[%]
Naivní bayes	828	12	111	9	98,57	92,50
k-NN	840	0	120	0	100,00	100,00
Template matching	836	3	117	3	99,52	97,50

V tabulce se na každém řádku nachází jednotlivé implementované klasifikátory a ve sloupcích jsou postupně hodnoty:

- *znaky správně* - počet správně klasifikovaných znaků;
- *znaky špatně* - počet chybně klasifikovaných znaků;
- *značky správně* - počet správně rozpoznaných celých značek;
- *značky špatně* - počet chybně rozpoznaných celých značek;
- úspěšnost znaky = $\frac{\text{znaky správně}}{\text{počet znaků ke klasifikaci}} * 100$;
- úspěšnost značky = $\frac{\text{značky správně}}{\text{počet značek ke klasifikaci}} * 100$;

Tab. 12: Výsledky klasifikace znaků v databázi „db_parkoviste_slunecno“

db_parkoviste_slunecno – 241 značek a 1687 znaků ke klasifikaci						
klasifikátor	Znaky		Značky		Úspěšnost	
	správně	špatně	správně	špatně	znaky	značky
	[-]	[-]	[-]	[-]	[%]	[%]
Naivní bayes	1604	83	178	63	95,08	73,86
k-NN	1677	10	233	8	99,41	96,68
Template matching	1678	9	235	6	99,47	97,51

Tab. 13: Výsledky klasifikace znaků v databázi „db_slunecno“

db_slunecno – 28 značek a 196 znaků ke klasifikaci						
klasifikátor	Znaky		Značky		Úspěšnost	
	správně	špatně	správně	špatně	znaky	značky
	[-]	[-]	[-]	[-]	[%]	[%]
Naivní bayes	187	9	21	7	95,41	75,00
k-NN	194	2	26	2	98,98	92,86
Template matching	193	3	26	2	98,47	92,86

Tab. 14: Výsledky klasifikace znaků v databázi „db_destivo“

db_destivo – 73 značek a 511 znaků ke klasifikaci						
klasifikátor	Znaky		Značky		Úspěšnost	
	správně	špatně	správně	špatně	znaky	značky
	[-]	[-]	[-]	[-]	[%]	[%]
Naivní bayes	480	21	53	20	93,93	72,60
k-NN	503	8	69	4	98,43	94,52
Template matching	503	8	69	4	98,43	94,52

Tab. 15: Výsledky klasifikace znaků v databázi „db_tma“

db_tma – 13 značek a 91 znaků ke klasifikaci						
klasifikátor	Znaky		Značky		Úspěšnost	
	správně	špatně	správně	špatně	znaky	značky
	[-]	[-]	[-]	[-]	[%]	[%]
Naivní bayes	85	6	8	5	93,41	61,54
k-NN	90	1	12	1	98,90	92,31
Template matching	88	3	10	3	96,70	76,92

Tab. 16: Výsledky klasifikace znaků v databázi „mpov_1“

mpov_1 – 89 značek a 623 znaků ke klasifikaci						
klasifikátor	Znaky		Značky		Úspěšnost	
	správně	špatně	správně	špatně	znaky	značky
	[-]	[-]	[-]	[-]	[%]	[%]
Naivní bayes	585	38	64	25	93,90	71,91
k-NN	614	9	84	5	98,56	94,38
Template matching	615	8	84	5	98,72	94,38

Tab. 17: Výsledky klasifikace znaků v databázi „mpov_2“

mpov_2 – 41 značek a 287 znaků ke klasifikaci						
klasifikátor	Znaky		Značky		Úspěšnost	
	správně	špatně	správně	špatně	znaky	značky
	[-]	[-]	[-]	[-]	[%]	[%]
Naivní bayes	257	30	22	19	89,55	53,66
k-NN	279	8	37	4	97,21	90,24
Template matching	280	7	39	2	97,56	95,12

Tab. 18: Výsledky klasifikace znaků v databázi „mpov_3“

mpov_3 – 78 značek a 546 znaků ke klasifikaci						
klasifikátor	Znaky		Značky		Úspěšnost	
	správně	špatně	správně	špatně	znaky	značky
	[-]	[-]	[-]	[-]	[%]	[%]
Naivní bayes	525	21	60	18	96,15	76,92
k-NN	545	1	77	1	99,82	98,72
Template matching	544	2	76	2	99,63	97,44

Z Tab. 12 až Tab. 18 je patrné, že napříč všemi galeriemi jsou kvality u jednotlivých klasifikátorů relativně konzistentní a nikde nedochází k velkým výkyvům úspěšnosti. Výjimkou jsou hodnoty pro klasifikátor *template matching* u galerie *db_tma*, kde úspěšnost rozpoznávání značek klesla o více než 15 % proti průměrné hodnotě. Tento pokles je ovšem dán nízkým počtem snímků v galerii, a proto i vysokou odezvou výsledků na chybu klasifikace.

Ve všech osmi galeriích byl nejhorší *naivní bayesovský* klasifikátor. *Template matching* byl nejlepší ve třech galeriích, a to v *db_parkoviste_zatazeno*, *mpov_1* a *mpov_2*. Oproti tomu *k-NN* z použitých klasifikátorů nejlépe rozpoznával ve čtyřech galeriích, a to v *db_parkoviste_zatazeno*, *db_slunecno*, *db_tma* a v *mpov_3*. V galerii *db_destivo* dosáhly oba poslední zmíněné klasifikátory shodných výsledků.

Z hodnot v Tab. 17 je vidět, že zřejmě nejobtížnější galerie pro klasifikaci znaků je *mpov_2*. Větší chybovost zde zřejmě podporuje velké množství snímků s geometrickými deformacemi samotných značek. Naopak nejlepších výsledků bylo dosaženo v galerii *db_parkoviste_zatazeno*, v níž dokonce klasifikátor *k-NN* dokázal správně klasifikovat všech 840 znaků.

Z výsledků je rovněž patrné, že na kvalitu klasifikace mají povětrnostní podmínky minimální vliv. Na rozdíl od lokalizace registračních značek a separace znaků, které jsou na přímé osvětlení značky slunečním světlem citlivé, rozpoznávání znaků odlesky nebo stíny příliš neovlivňují.

Tab. 19: Výsledky klasifikace znaků souhrnně ze všech galerií

všechny galerie - 683 značek a 4781 znaků ke klasifikaci						
klasifikátor	Znaky		Značky		Úspěšnost	
	správně	špatně	správně	špatně	znaky	značky
	[-]	[-]	[-]	[-]	[%]	[%]
Naivní bayes	4551	220	517	166	95,19	75,70
k-NN	4742	39	658	25	99,18	96,34
Template matching	4737	43	656	27	99,08	96,05

Ze souhrnných výsledků z Tab. 19 je patrné, že nejhůře znaky rozpoznává *naivní bayesovský* klasifikátor, jenž špatně klasifikoval 220 znaků ze 4781. To odpovídá úspěšnosti rozpoznávání 95,19 %, což není špatné. Ovšem při řešení problému automatického rozpoznávání registračních značek je důležité, aby byly správně rozpoznány všechny znaky na značce. Proto je také důležitá hodnota úspěšnosti rozpoznávání celých značek, a tu má *naivní bayesovský* klasifikátor pouze 75,70 % správně rozpoznávaných značek ze 683.


Druhým nejlepším použitým klasifikátorem je *template matching*. Ze všech znaků jich dokázal správně rozpoznat 99,08 %, což odpovídá 96,05 % správně rozpoznávaným celým značkám. Tento klasifikátor ale celkově rozpoznal pouze o 2 značky z 683 méně než nejlepší klasifikátor *k-NN*.

K-NN špatně rozpoznal pouze 39 znaků z celkového počtu 4781 znaků. To znamená, že z celkového počtu bylo správně klasifikováno 99,18 % znaků a 96,34 % registračních značek. Z použitých klasifikátorů lze tedy za nejlepší považovat *k-NN*, ač se kvalitou od *template matchingu* liší pouze minimálně.

6.5.2 Problémové znaky


V následujícím textu jsou analyzovány znaky, které byly u jednotlivých klasifikátorů chybně rozpoznány. Zároveň jsou prozkoumány značky, ze kterých jsou znaky separovány, a je hledána souvislost mezi podobou registrační značky a důvodem, proč byl znak špatně klasifikován.

Naivní bayesovský klasifikátor měl nejvyšší chybovost i proto, že často chyboval u zdánlivě jednoznačných segmentů. Zdá se, že i malé zkosení v kombinaci s drobnou nečistotou může způsobit špatnou klasifikaci. V několika případech byl znak chybně určen i bez jakéhokoliv viditelného důvodu. Je možné, že vybraný příznakový vektor není pro použití s *naivním bayesovským* klasifikátorem příliš vhodný a znaky se klasifikátoru nejeví příliš odlišně.




Obr. 6.7 Příklad chybně detekovaných znaků naivním bayesovským klasifikátorem

Klasifikátor k -NN má na použitých snímcích dle předchozích srovnání nejlepší schopnosti rozpoznávání, i proto jsou chybně detekované znaky většinou silně porušeny nebo jsou vlivem šumu či nečistot velmi zkresleny. Příklady nesprávně klasifikovaných znaků klasifikátorem k -NN jsou na Obr. 6.8.



Obr. 6.8: Příklad chybně detekovaných znaků klasifikátorem k -NN

Klasifikátor *template matching* také není příliš citlivý na drobná zkreslení a ve většině případů špatně klasifikuje pouze u výraznějších geometrických deformací, především u velkého zkosení. Chybná klasifikace se dále vyskytuje u porušených znaků. Některé z chybně rozpoznávaných případů jsou znázorněny na Obr. 6.9.



Obr. 6.9: Příklad chybně detekovaných znaků klasifikátorem *template matching*

6.5.3 Shrnutí klasifikace znaků

Z výsledků testování celkové kvality klasifikace znaků je patrné, že nejlepším použitým klasifikátorem je k - NN , který z dostupných 4781 znaků z reálných snímků dokázal správně rozpoznat 99,18 % znaků. Zároveň to znamená, že bylo správně rozpoznáno 658 celých registračních značek z 683, tedy 96,34 %. Klasifikátor *template matching* byl horší pouze o 4 správně rozpoznané znaky. A nejhorším použitým klasifikátorem je tedy *naivní bayesovský*.

Zároveň při prozkoumání výsledků klasifikace z jednotlivých galerií bylo zjištěno, že aktuální povětrnostní podmínky při snímání obrazu se značkou nemají přímý vliv na úspěšnost rozpoznávání znaků. Proti tomu zřejmě nejvyšší degradující vliv na úspěšnost klasifikace znaků má vliv přítomnost snímků s větším geometrickým zkreslením.

Analýzou chybně klasifikovaných znaků bylo zjištěno, že jednotlivé klasifikátory jsou více či méně citlivé na tři vyskytující se defekty, a to na zkosení, na výskyt přebytné nečistoty a na porušení znaku. Nejvíce je na tyto chyby citlivý *naivní bayesovský* klasifikátor. Naopak klasifikátor k - NN je ve většině případů schopný uvedené defekty zanedbat a segment klasifikovat správně. Celkově všechny klasifikátory měly největší problém rozlišovat mezi dvojicemi znaků „8“ - „B“ a „0“ - „D“ na pozicích, na kterých se může vyskytovat i číslice i písmeno.

6.6 Citlivostní analýza

Cílem této kapitoly je zjištění limitů celého rozpoznávacího řetězce v případě vybrání nejlepších metod pro lokalizaci značky, separaci znaků a klasifikaci znaků. Vzhledem k předchozím výsledkům byla tedy pro lokalizaci vybrána metoda *trkal_dp*, separace znaků se prováděla pomocí amplitudových projekcí a jako klasifikátor byl použit *k-NN*.

Během testování byla zkoumána odezva systému na výstupu s přihlédnutím ke změně vstupních dat. Pro tyto účely byly uměle vytvořeny soubory snímků simulující právě změnu či degradaci vstupních dat. Jednalo se především o simulaci náklonu značky, snižování kontrastu snímku a zvyšování šumu ve snímku. Všechny takto provedené úpravy vycházely ze snímku na Obr. 6.10. Jedná se o snímek se středně složitou scénou pořízený v deštivém počasí, na kterém je registrační značka rovnoměrně osvětlena.



Obr. 6.10: Originální snímek pro degenerační úpravy

Sada snímků simulujících rotaci značky je na Obr. 6.11. Obsahuje 61 jednotlivých snímků, které jsou uměle otočeny od -30° až do $+30^\circ$ s krokem po 1° . Při testování bylo zjištěno, že rozpoznávací systém dokáže najít a rozpoznat značku při maximálním náklonu vlevo o -12° a vpravo o 11° . Tyto mezní hodnoty jsou ukázány na Obr. 6.12. Uvedené limity jsou dány verifikačními podmínkami v lokalizaci, které hodnotí, zda je poměr stran obdélníka opsaného registrační značce ve stanoveném intervalu. Jelikož se z principu metody opisuje obdélník vždy rovnoběžný se vstupním snímkem, je potom evidentní, že se při náklonu značky začne poměr stran měnit. Při dosažení minima intervalu již nejsou splněny verifikační podmínky a značka není lokalizována.



Obr. 6.11: Příklad ze sady simulující rotaci, vlevo rotováno o -20° , vpravo o 20°



Obr. 6.12: Limitní meze rotace, vlevo rotováno o -12° , vpravo o 11°

Sada simulující snižování kontrastu byla vytvořena snižováním intervalu používaných hodnot jednotlivých pixelů. Tedy například snížení kontrastu na 50 % znamená, že místo běžného intervalu od 0 do 255 hodnot pro každou barvu v každém pixelu je dostupný pouze interval od 63 do 191 hodnot. A potom se tedy hodnoty pixelů původního snímku pomocí lineární převodní charakteristiky transformují do tohoto intervalu. Na Obr. 6.13 je patrné, že snižováním kontrastu ubývá detailů a všechny barvy se limitně přibližují střední šedé.

Postupným testováním bylo zjištěno, že rozpoznávací algoritmus je schopný na testovacím snímku lokalizovat značku a rozpoznat znaky i při snížení kontrastu na 6 %. Při dalším snižování již znaky systém nerozpozná správně, registrační značku je ale schopný nalézt i při snížení kontrastu na pouhých 2 %. Při této hodnotě je problém značku na snímku nalézt i samotným okem, jak je vidět na Obr. 6.14



Obr. 6.13: Příklad ze sady simulující snížení kontrastu, vlevo na 60 %, vpravo na 20 %



Obr. 6.14: Limitní meze snížení kontrastu, vlevo na 6 % - klasifikuje i znaky, vpravo na 2 % - nalezne značku, ale znaky nerozpozná správně

Sada simulující šum v obrazu je vytvořena aplikací šumu typu pepř a sůl na původní testovací snímek. Hodnota šumu je určována procentuálním zastoupením pixelů, které šum postihne. Testováním bylo zjištěno, že navržený rozpoznávací systém je schopný detekovat značku a nalézt znaky při 7 % postihnutých pixelů (Obr. 6.16 vlevo). Při 10 % šumu ještě systém značku lokalizuje, ale znaky již správně nerozpozná (Obr. 6.16 vpravo).



Obr. 6.15: Příklad ze sady simulující zvýšený šum, vlevo 5 % šumu, vpravo 15 %



Obr. 6.16: Limitní meze šumu, vlevo 7% šum - klasifikuje i znaky, vpravo 10% - ještě detekuje registrační značku

Pro detekční systémy je také důležité, aby nenacházel značku tam, kde registrační značka není, tedy aby počet falešně pozitivních kandidátů byl co nejmenší. Pro tyto účely byla modifikována galerie *mpov_1*, jak je vidět na Obr. 6.17. Všechny registrační značky byly rozmazány vyhlazovacím kruhovým filtrem o průměru poloviny výšky registrační značky tak, aby značky nebyly okem rozpoznatelné.

Celkem tedy bylo k dispozici 90 snímků bez rozpoznatelných registračních značek. Cílem testování bylo projít celou tuto modifikovanou galerii a ověřit, zda nebude nějaká oblast označena za registrační značku, i když se nikde detekovatelná značka nevyskytuje. Po analýze se potvrdilo, že skutečně žádná oblast označena nebyla, takže počet falešně pozitivních kandidátů byl po projití celé galerie nulový. To znamená, že tento test byl splněn se 100% přesností.



Obr. 6.17: Příklad ze sady simulující nepřítomnost registrační značky ve snímku

7 ZÁVĚR

7.1 Zhodnocení

Cílem této práce bylo zajistit dostatečně širokou galerii snímků s registračními značkami, porovnat metody pro lokalizaci tabulky registrační značky v obraze a srovnat vybrané klasifikátory pro rozpoznávání jednotlivých znaků.

Aby bylo pochopeno co nejvíce souvislostí, zpracoval jsem kapitolu o podobách registračních značek v České republice i ve světě. Bylo zjištěno, že značky nových formátů všech zemí Evropské unie mají velmi blízký grafický vzhled. Podobný je rozměr tabulek i přítomnost modrého pole se znakem EU. Naopak typ písma i způsob kódování se liší. Proto se kvůli jednotnosti tato práce nadále soustředila pouze na české jednořádkové registrační značky.

Celkově bylo pro testování k dispozici 735 snímků obsahujících registrační značky, jež byly rozděleny do devíti galerií především podle doby pořízení a podle zdroje dat. Měl jsem pět vlastních galerií a čtyři převzaté z jiných zdrojů. Snímky byly velmi rozmanité a pořízené za různých povětrnostních podmínek. Registrační značky na fotografiích se lišily nasnímáním z rozdílných vzdáleností i úhlů, čistotou, někdy i drobným poškozením.

V kapitole o lokalizaci registračních značek jsem shrnul nejčastější přístupy při návrhu lokalizačních algoritmů a problémy, které mohou ovlivňovat kvalitu detekce. Mezi oblíbené přístupy patří využití hranových detektorů a následné vyhledávání větších hranových nahuštění. Často je také využíváno matematických morfologických operací s šedotónovými či binárními snímky. Mezi prozkoumanými metodami se vyskytovaly i takové, jež využívaly komplexnější nástroje či vzájemné kombinace více přístupů. Dále jsem podrobně analyzoval čtyři vybrané lokalizační metody, na jejichž základě jsem navrhl metodu vlastní.

Při návrhu postupu rozpoznávání znaků jsem určil způsob předzpracování výřezu s registrační značkou. Jednalo se o korekce jasů, korekci natočení a oříznutí přebytečných okrajů. Dále jsem vyzkoušel dva způsoby separace jednotlivých znaků, z nichž se více osvědčil ten, který využíval vertikální amplitudové projekce. Pro správnou funkčnost klasifikace jsem vybral tréninkové množiny a vhodný způsob kódování segmentu se znakem do příznakového vektoru. Nakonec jsem implementoval tři rozdílné klasifikátory, a to k-NN, naivní bayesovský a klasifikátor využívající korelaci se šablonou.

V rámci další implementace jsem převzal a upravil anotátor, s jehož pomocí byly anotovány všechny registrační značky na snímcích v dostupných galeriích. Tímto bylo možné automaticky vyhodnocovat úspěšnost detekce jednotlivých lokalizačních metod a kvalitu klasifikátorů. Čtyři implementované lokalizační metody byly rekonstruovány podle vědeckých článků a jednu jsem navrhl sám dle vlastních zkušeností. Tyto metody

byly implementovány jako funkce ve vývojovém prostředí Matlab, které byly volány testovacím skriptem, jenž umožňoval procházení fotografií a vyhodnocování výsledků testování.

Během experimentů jsem nejdříve testoval jednotlivé lokalizační metody. V první fázi proběhlo automatické testování pomocí testovacího skriptu. Zde jsem zjišťoval především procentuální úspěšnost správně detekovaných značek, přesnost, F míru, počet falešně pozitivních i falešně negativních kandidátů a výpočetní náročnost metod. V druhé fázi jsem hledal problémové scény, s nimiž měly jednotlivé metody největší problémy, což byly například vyfotografované špinavé značky nebo značky snímané z větší dálky.

Poté jsem testoval tři implementované klasifikátory. Zjišťoval jsem především počty správně a chybně rozpoznaných znaků a také počty správně a chybně rozpoznaných celých registračních značek. Nakonec jsem analyzoval chybně klasifikované znaky, což vedlo k zjištění, že klasifikátory nejhůře rozpoznávají znaky deformované geometrickým zkosením.

Nejlepší úspěšnost lokalizace vykazovala mnou navržená metoda, která kombinuje několik přístupů. Metoda správně detekovala 95,24 % ze všech anotovaných registračních značek s velmi malým počtem falešně označených oblastí. Při testování klasifikátorů jsem zjistil, že znaky nejlépe rozpoznává k-NN, konkrétně 4-NN klasifikátor, jenž dokázal správně rozpoznat 99,18 % znaků ze 4781.

Protože celý navržený řetězec „lokalizace – separace znaků – rozpoznávání znaků“ má povahu kaskády a tedy obsahuje pouze dopředné vazby, stačí pro nalezení globálního optima (v našem případě maximální úspěšnosti rozpoznání RZ) vybrat vždy nejlepší metody z každého kroku. Tím dostávám ze všech možných kombinací zaručeně nejlepší systém pro automatické rozpoznávání registračních značek a tím pádem není nutné zkoušet možné kombinace lokalizace a OCR. Klíčové vlastnosti navrženého systému jsou potom dány vlastnostmi navržené lokalizační metody, vlastnostmi separace pomocí amplitudové projekce a vlastnostmi klasifikátoru k-NN zjištěnými při jejich testování.

7.2 Budoucí vývoj

V rámci dalšího vývoje by bylo vhodné vyzkoušet jiné způsoby separace jednotlivých znaků, především takové, které nebudou příliš citlivé na částečné zastínění značky. Pro zkvalitnění výstupních údajů by dále bylo užitečné navrhnout testy pro ověřování věrohodnosti rozpoznaných znaků.

Dále by bylo vhodné analyzovat ještě další nevyzkoušené metody pro lokalizaci registračních značek. V případě nalezení postupů, které by bylo možné využít pro zdokonalení vlastní navržené metody, by bylo dobré tyto postupy implementovat a vylepšenou metodu znovu otestovat.

Literatura

- [1] ABOLGHASEMI, Vahid Abolghasemi a Alireza AHMADYFARD. An edge-based color-aided method for license plate detection. *Image and vision computing*, 2009, (27)
- [2] ADAMEC, Václav. *Zpracování a rozpoznání obrazu*. Olomouc, 2011. Bakalářská práce. Přírodovědecká fakulta univerzity Palackého. Vedoucí práce Mgr. Eduard Bartl, Ph.D.
- [3] BISKUP, Roman. *Možnosti neuronových sítí*. Praha, 2009. Disertační práce. Česká zemědělská univerzita v Praze. Vedoucí práce prof. RNDr. Anna Čermáková, CSc.
- [4] CONINX, Jeroen. *License Plate Mania* [online]. 2012 [cit. 2016-01-26]. Dostupné z: <http://www.licenseplatemania.com>
- [5] ČERNÝ, Matěj. *Rozpoznávání registračních značek motorových vozidel*. Pardubice, 2010. Diplomová práce. Univerzita Pardubice. Vedoucí práce Ing. Martin Dobrovolný, Ph.D.
- [6] Česká republika. Zákon č. 243/2001 Sb. - o registraci vozidel. V: 2001.
- [7] DOBROVOLNÝ, Martin. Rychlý algoritmus rozpoznání registračních značek vozidel. 2009, čtvrtý ročník, č. 3.
- [8] DUAN, Tran Duc a Tran Le Hong DU. Building an Automatic Vehicle License-Plate Recognition System. *Intl. Conf. in Computer Science*. 2005, 59-63.
- [9] DUDA R. O., HART P. E., STORK D. G. *Pattern classification*. 2. vyd. John Wiley & Sons, 2000. 680 s. ISBN 978-0-471-05669-0.
- [10] ENYEDI, Balazs a Lajos KONYHA. Strategies for Fast Licence Plate Number Localization. *46th International Symposium Electronics in Marine*. 2004.
- [11] FEICHTINGER, František. *Studium vlivu parametrů vybraných segmentačních metod na analýzu obrazů buněk*. Brno, 2008. Diplomová práce. Masarykova univerzita, Fakulta informatiky. Vedoucí práce RNDr. Pavel Matula, Ph.D.
- [12] HORÁK, Karel. *Zpracování vícerozměrných signálů: Computer Vision* [online]. [cit. 2013-12-27]. Dostupné z: http://midas.uamt.feec.vutbr.cz/ZVS/zvs_cz.php
- [13] HSIEH, Jun-Wei a Shih-Hao YU. Morphology-based License Plate Detection from Complex Scenes. *IEEE*. 2002, (02).
- [14] CHANG, S.-L., L.-S. CHEN, Y.-C. CHUNG a S.-W. CHEN. Automatic License Plate Recognition: a publication of the IEEE Intelligent Transportation Systems Council. *IEEE Transactions on Intelligent Transportation Systems*. 2004, 5(1): 42-

53. DOI: 10.1109/TITS.2004.825086. ISSN 1524-9050. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1271288>
- [15] KUSTERMANN. *Licence Plates of the World* [online]. 2010 [cit. 2016-01-26]. Dostupné z: <http://www.worldlicenseplates.com>
- [16] MACEČEK, A. *Rychlost učení vícevrstvé sítě*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 58 s. Vedoucí bakalářské práce doc. Ing. Václav Jirsík, CSc.
- [17] MAHINI, Hamid a Faezeh DORRI. An Efficient Features–Based License Plate Localization Method. [EDITORS, Y. *The 18th International Conference on Pattern Recognition proceedings: 20 - 24 August, 2006, Hong Kong*. Los Alamitos, Calif. [u.a.]: IEEE Computer Society, 2006, (1). ISBN 0769525210. ISSN 0-7695-2521-0.
- [18] MATAS, Jiri a Karel ZIMMERMANN. Unconstrained Licence Plate and Text Localization and Recognition. *CONEX GZ 45.535*. 2007.
- [19] MOLČÁNY, Peter *Zpracování obrazu v systému Android - detekce a rozpoznání SPZ/RZ a využití externí databáze zájmových vozidel*: diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky, 2015. 63 s.
- [20] MAZEL, Michal a Oldřich KRULÍK. Možnosti a perspektiva využití automatického rozeznávání registračních značek vozidel. *Bezpečnostní sbory.cz* [online]. [cit. 2016-03-26]. Dostupné z: http://bezpecnostni-sbory.wbs.cz/clanky/2-2013/2013_bezpecnostni-sbory_anpr_podklad.pdf
- [21] MAZEL, Michal a Oldřich KRULÍK. Registrační značky vozidel: srovnávací studie pro země Evropské unie I: Belgie, Bulharsko, Dánsko, Estonsko, Finsko, Francie. *Bezpečnostní sbory.cz* [online]. [cit. 2016-01-26]. Dostupné z: http://bezpecnostni-sbory.wbs.cz/clanky/1-2013/2013_bezpecnostni-sbory_rz1_podklad.pdf
- [22] MAZEL, Michal a Oldřich KRULÍK. Registrační značky vozidel: srovnávací studie pro země Evropské unie II: Irsko, Itálie, Kypr, Litva, Lotyšsko. Lucembursko, Maďarsko, Malta, Německo. *Bezpečnostní sbory.cz* [online]. [cit. 2016-01-26]. Dostupné z: http://bezpecnostni-sbory.wbs.cz/clanky/1-2013/2013_bezpecnostni-sbory_rz1_podklad.pdf
- [23] MOUCHA, Jan. Americké "espézetky". *Gate Náchod* [online]. 2005 [cit. 2016-01-26]. Dostupné z: http://www.gatenachod.cz/anglictina/z014_spzusa.htm
- [24] PIRNER, Ivan. *Předzpracování pro segmentaci obrazových dat v lékařství*. Plzeň, 2010. Diplomová práce. Západočeská univerzita v Plzni. Vedoucí práce Ing. Miloš Železný, PhD.

- [25] SAHA, Satadal a Subhadip BASU. License Plate Localization from Vehicle Images: An Edge Based Multi-stage Approach. *International Journal of Recent Trends in Engineering*. 2009, (1).
- [26] SMĚKAL, David. *Detekce státní poznávací značky pro dohledové systémy*. Brno, 2013. 42 l. Bakalářská práce. Vysoké učení technické v Brně. Vedoucí práce Ing. Jiří Přinosil, Ph.D.
- [27] ŠÍMA, Jiří. *Teoretické otázky neuronových sítí*. Vyd. 1. Praha: MATFYZ press, 1996, 390 s. ISBN 80-858-6318-9
- [28] TARABEK, Peter. *A Real-Time License Plate Localization Method Based on Vertical Edge Analysis*. M. GANZHA, M.L. Proceedings of the Federated Conference on Computer Science and Information Systems, September 9-12, 2012, Wrocław, Poland fedCSIS. Warsaw: Polskie Towarzystwo Informatyczne, 2012, , 149-156. ISBN 9788360810514. ISSN 978-83-60810-51-4.
- [29] TRKAL, O. *Rozpoznávání registračních značek*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2014. 58s. Vedoucím bakalářské práce byl doc. Ing. Václav Jirsík, CSc.
- [30] VALA, Tomáš. *Rozpoznávání SPZ z jednoho snímku*. Uherské Hradiště, 2006. Diplomová práce. Univerzita Karlova v Praze. Vedoucí práce RNDr. Jana Štanclová.
- [31] VEHICLE REGISTRATION PLATES OF CANADA. *Self Gutenberg* [online]. [cit. 2016-01-26]. Dostupné z: http://self.gutenberg.org/articles/vehicle_registration_plates_of_canada
- [32] ZAPLETAL, O. *Srovnání správnosti klasifikace pomocí tradičních modelů a meta-modelů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2014. 63 s. Vedoucí bakalářské práce Ing. Petr Honzík, Ph.D.
- [33] ZÁTOPEK, M.. *Metody strojového vidění pro rozpoznávání dopravního značení*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. 113s. Vedoucí diplomové práce byl Ing. Karel Horák, Ph.D.
- [34] ZHAI, Xiaojun, Faycal BENSSALI a Soodamani RAMALINGAM. License Plate Localisation based on Morphological Operations. IEEE. *11th International Conference on Control, Automation, Robotics: 7 - 10 Dec. 2010, Singapore*. Piscataway, NJ: IEEE, 2010, (10), 1028-1032. ISBN 9781424478156. ISSN 978-1-4244-7815-6.

Seznam příloh

Příloha 1.: DVD s databázemi snímků a se zdrojovými kódy
- program se spouští skriptem „main_LPR.m“