


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 REGISTRAČNÍCH ZNAČEK

LICENCE PLATE RECOGNITION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

ONDŘEJ TRKAL

VEDOUČÍ PRÁCE

SUPERVISOR

doc. Ing. VÁCLAV JIRSÍK, CSc.

BRNO 2014



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav automatizace a měřicí techniky

Bakalářská práce

bakalářský studijní obor
Automatizační a měřicí technika

Student: Ondřej Trkal
Ročník: 3

ID: 146982
Akademický rok: 2013/2014

NÁZEV TÉMATU:

Rozpoznávání registračních značek

POKYNY PRO VYPRACOVÁNÍ:

1. Seznamte se s problematikou popisu a rozpoznávání registračních značek.
2. Vytvořte tréninkovou a testovací množinu z reálných registračních značek.
3. Navrhněte a použijte metodu pro lokalizaci registrační značky v obrazu.
4. Navrhněte a použijte metodu pro popis registračních značek.
5. Vyberte a zrealizujte umělou neuronovou síť pro klasifikaci registračních značek.
6. Zhodnoťte dosažené výsledky při klasifikaci registračních značek.

DOPORUČENÁ LITERATURA:

Šíma J., Neruda R.: Teoretické otázky neuronových sítí. Matfyzpress, Praha 1996, ISBN 80-85863-18-9.
Maceček A.: Rychlost učení vícevrstvé sítě. Bakalářská práce, VUT FEKT v Brně, 2011.

Termín zadání: 10.2.2014

Termín odevzdání: 26.5.2014

Vedoucí práce: doc. Ing. Václav Jirsík, CSc.

Konzultanti bakalářské práce:

doc. Ing. Václav Jirsík, CSc.

Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské 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.

Abstrakt

Tato práce se zabývá rozpoznáváním státních poznávacích značek pomocí neuronových sítí s typem učení backpropagation. V teoretické části textu je stručně shrnuta teorie principu vytváření nových registračních značek, počítačového vidění a vícevrstevných neuronových sítí se způsobem učení typu backpropagation. V praktické části je popsán návrh metod sloužících k rozpoznávání jednořádkových registračních značek osobních automobilů v České republice. V práci bylo vyzkoušeno několik způsobů popisu značek a byl zkoumán vliv těchto popisů a topologie neuronové sítě na kvalitu rozpoznávání registračních značek.

Klíčová slova

Zpracování obrazu, umělé neuronové sítě, backpropagation, počítačové vidění, registrační značky, rozpoznávání registračních značek.

Abstract

This thesis deals with the recognition of license plates using neural networks with backpropagation learning. The theoretical section is a brief summary of the principle of creating a new license plate, computer vision and neural networks with backpropagation learning. The practical part describes the design of methods used to detect single-line license plates of cars in the Czech Republic. In this work has been tested several ways to describe the signs and examined the effect of these descriptions and topology of neural networks for quality license plate recognition.

Keywords

Image processing, artificial neural networks, backpropagation, computer vision, license plate, license plate recognition.

Bibliografická citace:

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.

Prohlášení

„Prohlašuji, že svou bakalářskou práci na téma Rozpoznávání registračních značek jsem vypracoval samostatně pod vedením vedoucího bakalářské 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 bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské 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: **26. května 2014**

.....
podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce doc. Ing. Václavovu Jirsíkovi, CSc. a konzultantovi Ing. Karlovu Horákovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne: **26. května 2014**

.....
podpis autora

Obsah

Seznam obrázků	9
Seznam tabulek.....	10
1 Úvod	11
2 Charakteristika registrační značky	13
3 Počítačové vidění	15
3.1 Diskrétní obraz	15
3.2 Předzpracování obrazu	15
3.2.1 Detekce hran.....	15
3.3 Segmentace obrazu.....	16
3.3.1 Segmentace prahováním.....	16
3.4 Popis objektů	18
3.5 Klasifikace objektů.....	19
4 Vícevrstvé umělé neuronové sítě	20
4.1 Formální neuron	20
4.2 Topologie umělé neuronové sítě	21
4.3 Adaptace.....	22
4.3.1 Celková chyba sítě.....	23
4.3.2 Adaptace vah a prahů	24
4.4 Aktivace.....	25
5 Rešerše prací zabývajících se rozpoznáváním registračních značek.....	26
5.1 Lokalizace	27
5.2 Předzpracování	27
5.3 Segmentace.....	28
5.4 Separace znaků	28
5.5 Popis znaků.....	28
5.6 Klasifikace znaků	29
5.7 Vyhodnocení	29
6 Lokalizace registrační značky	30
6.1 Snímání.....	30
6.2 Předzpracování snímku	30
6.3 Segmentace snímku.....	32
6.4 Výběr kandidáta	33
7 Popis registrační značky	35
7.1 Předzpracování registrační značky	35
7.2 Segmentace znaků	39
7.3 Separace znaků	40
7.4 Normalizace znaků	42
7.5 Popis znaků.....	42
8 Klasifikace registrační značky.....	44
8.1 Tréninková a testovací množina.....	44
8.2 Topologie neuronové sítě	45

8.3 Počáteční hodnoty vah.....	46
8.4 Přenosová funkce	47
8.5 Koeficient učení	48
8.6 Maximální celková chyba naučené sítě.....	48
8.7 Výsledky klasifikace	49
8.8 Heuristiky	52
9 Navržený program	53
10 Závěr.....	55
10.1 Zhodnocení.....	55
10.2 Možnost dalšího vývoje.....	56
Literatura	57
Seznam příloh.....	58

SEZNAM OBRÁZKŮ

<i>Obr. 2.1 Příklad tabulky s registrační značkou.....</i>	<i>14</i>
<i>Obr. 3.1 Registrační značka a její histogram.....</i>	<i>17</i>
<i>Obr. 4.1 Formální neuron.....</i>	<i>20</i>
<i>Obr. 4.2 Čtyřvrstvá umělá neuronová síť.....</i>	<i>22</i>
<i>Obr. 4.3 Názorný průběh chybové funkce.....</i>	<i>24</i>
<i>Obr. 6.1 Příklad dat pořízených k rozpoznávání registračních značek.....</i>	<i>30</i>
<i>Obr. 6.2 Příklad převodní charakteristiky pro zvýšení kontrastu.....</i>	<i>31</i>
<i>Obr. 6.3 Snímek před (vlevo) a po předzpracování.....</i>	<i>31</i>
<i>Obr. 6.4 Snímek po segmentaci s různými prahy.....</i>	<i>32</i>
<i>Obr. 6.5 Příklad výstupu lokalizačního algoritmu.....</i>	<i>33</i>
<i>Obr. 7.1 Značka před předzpracováním.....</i>	<i>35</i>
<i>Obr. 7.2 Šedotónový obraz registrační značky.....</i>	<i>35</i>
<i>Obr. 7.3 Registrační značka po zvýšení kontrastu.....</i>	<i>36</i>
<i>Obr. 7.4 Černobílý binární obraz registrační značky.....</i>	<i>36</i>
<i>Obr. 7.5 Obraz horizontálních hran registrační značky.....</i>	<i>36</i>
<i>Obr. 7.6 Obraz registrační po korekci natočení.....</i>	<i>37</i>
<i>Obr. 7.7 Černobílý obraz registrační značky po korekci natočení.....</i>	<i>37</i>
<i>Obr. 7.8 Horizontální projekce registrační značky.....</i>	<i>38</i>
<i>Obr. 7.9 Šedotónový oříznutý obraz registrační značky.....</i>	<i>38</i>
<i>Obr. 7.10 Registrační značka s přidanými pruhy vlevo a vpravo.....</i>	<i>39</i>
<i>Obr. 7.11 Příklad špatně segmentovaných registračních značek (vpravo) a jejich šedotónové originály (vlevo).....</i>	<i>40</i>
<i>Obr. 7.12 Horizontální projekce před separací jednotlivých znaků.....</i>	<i>41</i>
<i>Obr. 7.13 Příklad objektů vyřazených při separaci.....</i>	<i>41</i>
<i>Obr. 7.14 Řada znaků registrační značky postupně po separaci (nahore), po oříznutí okrajů a po normalizaci.....</i>	<i>41</i>
<i>Obr. 8.1 Tréninková množina alfanumerických znaků.....</i>	<i>44</i>
<i>Obr. 8.2 Závislosti úspěšnosti rozpoznání jednotlivých znaků na počtu neuronů ve skryté vrstvě.....</i>	<i>46</i>
<i>Obr. 8.3 Příklad závislosti úspěšnosti rozpoznání jednotlivých znaků na hodnotě strmosti přenosové funkce hyperbolické tangenty.....</i>	<i>47</i>
<i>Obr. 8.4 Závislost úspěšnosti rozpoznání celých značek (modrá) a jednotlivých znaků (zelená) na velikosti E_c naučené sítě.....</i>	<i>48</i>
<i>Obr. 8.5 Vliv počtu neuronů ve skryté vrstvě na velikost chyby E_c, při které je síť naučená na všechny tréninkové vzory.....</i>	<i>49</i>
<i>Obr. 8.6 Vliv rozlišení obrazu s registrační značkou na kvalitu rozpoznání.....</i>	<i>52</i>
<i>Obr. 9.1 Náhled grafického znázornění výsledku rozpoznání registrační značky.....</i>	<i>54</i>

SEZNAM TABULEK

<i>Tab. 2.1 Seznam písmen označujících jednotlivé kraje</i>	<i>13</i>
<i>Tab. 8.1 Procentuální úspěšnost rozpoznávání jednotlivých znaků pomocí UNS.....</i>	<i>50</i>

1 ÚVOD

Tato práce se zabývá rozpoznáváním registračních značek osobních automobilů v České republice s využitím umělých neuronových sítí jako klasifikátoru pro rozpoznání jednotlivých znaků na značce. Úloha byla řešená jako technický problém s důrazem na největší úspěšnost rozpoznání registračních značek. Jelikož je využití umělých neuronových sítí v technické praxi na vzestupu, nabízí se ověřit jejich klasifikační schopnosti na datech z reálného prostředí.

Výklad v teoretické části práce (kapitola 2, 3, 4) je omezen pouze na nejvýznamnější a nejnütnější teoretické a metodické prvky daného oboru, kterých se dále využívá při konkrétním řešení vyskytujících se problémů v praktické části práce (kapitoly 6 až 9).

V druhé kapitole jsou popsána pravidla, kterými se řídí vydávání nových registračních značek v České republice, tedy rozměry značky, rozměry znaků, jejich poloha, množina znaků objevujících se na značkách, jejich počet atd.

Třetí kapitola se zabývá počítačovým viděním. V kapitole je rozebrán způsob reprezentace digitálního obrazu a hlavně rámcově popsán celý řetězec počítačového vidění (snímání, digitalizace, předzpracování, segmentace, popis, klasifikace) s důrazem na vybrané konkrétní metody použité v praktické části práce. Všechny články řetězce před klasifikací jsou vlastně postupy, kterými musí značka a její jednotlivé znaky projít, než mohou být rozpoznány umělou neuronovou sítí (UNS).

Čtvrtá kapitola je zaměřená na popis vícevrstvých umělých neuronových sítí se způsobem učení backpropagation. Je zde popsán základní stavební prvek všech neuronových sítí, tedy formální neuron. Dále je zmíněno jakým způsobem volit topologii sítě, jakým způsobem probíhá učení a aktivace UNS a proč je zvolený typ sítě využit v této práci.

Pátá kapitola je rešerší prací věnujících se tématu rozpoznání registračních značek nebo jenom znaků. Celá kapitola je zde podle řetězce počítačového vidění rozdělena na podkapitoly, ve kterých se porovnávají různé přístupy řešení konkrétních problémů. Tyto problémy týkající se rozpoznávání registračních značek jsou v různých materiálech řešeny stejným přístupem, proto je rešerše řešena následujícím způsobem. U každé podkapitoly je v úvodu uveden seznam obecně využívaných principů, u kterých je doplněno, ve které literatuře jich bylo využito. Takto je možné určit, které principy jsou používanější, a pokud autoři navrhovali metody s důrazem na nejlepší úspěšnost rozpoznání, lze při jejich využití očekávat lepší výsledky.

Šestá kapitola obsahuje návrh a provedení metody lokalizace registrační značky na snímku. V kapitole jsou zmíněny i výsledky lokalizace a vliv povětrnostních podmínek na úspěšnost lokalizace.

Šedmá kapitola se zabývá problémem předzpracování, segmentace a popisu. Jsou zde zmíněny a řešeny všechny problémy, se kterými se bylo nutné vypořádat při rozpoznávání

značek z reálného prostředí. Také je zde zkoumána kvalita různých metod segmentace obrazu a různých způsobů popisu.

V osmé kapitole je zkoumán vliv parametrů neuronové sítě na úspěšnost rozpoznávání registračních značek. Mezi tyto parametry patří topologie, koeficient učení, celková chyba naučené sítě a další.

V deváté kapitole je rámcově popsán navržený program, který je na základě snímku s registrační značkou schopný tuto značku lokalizovat a následně klasifikovat jednotlivé znaky s využitím navržených metod.

2 CHARAKTERISTIKA REGISTRAČNÍ ZNAČKY

Při tvorbě této kapitoly bylo využito informací ze zdrojů [1], [4], [11].

Státní poznávací značky neboli registrační značky jsou v České republice vydávány podle zákona č. 56/2001 Sb. – o podmínkách provozu vozidel na pozemních komunikacích. Podoba registračních značek je definována v zákoně č. 243/2001 Sb. – o registraci vozidel, který byl v roce 2004 novelizován vyhláškou č. 291/2004 Sb.

Od roku 2001 se registrační značky vydávají dle následujících pravidel. Značky obsahují podle typu vozidla pět až sedm znaků, přesněji arabských číslic a písmen latinské abecedy bez diakritiky. Každá značka musí obsahovat minimálně jednu číslici a alespoň jedno písmeno. První písmeno zleva je vždy kód kraje, do jehož obvodu náleží registrační místo, které značku přiděluje (Tab. 2.1) Výjimku tvoří značky diplomatické, cizinecké a registrační značky pro historická vozidla.

Pozice číslic a písmen není přesně určena a znaky mohou být libovolně zpřeházeny, pokud jsou dodržena pravidla uvedená v předchozím odstavci. Zatím se ale kombinace znaků vydávají ve formátu XZX XXXX, kde X značí číslici a Z písmeno. V některých krajích jsou již kombinace předchozího vzorce vyčerpány, a proto se využívá vzorec XZZ XXXX. Z důvodu dobré čitelnosti jsou vynechána písmena G, O, Q a W. V některých krajích jsou vynechána i další písmena, pokud by jejich kombinace dohromady dávala vulgární slovo nebo název zakázané organizace. V levé části tabulky se značkou je modrý proužek s dvanácti žlutými hvězdami a zkratkou státu, tedy ČR.

Tab. 2.1 Seznam písmen označujících jednotlivé kraje

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

K odlišení rozdílných typů registračních značek se používají i různé barvy znaků a pozadí. Nejčastěji se v provozu vyskytuje bílá značka s černými znaky, která přísluší všem osobním a nákladním vozidlům, autobusům a motocyklům. Modré znaky na bílém pozadí přísluší automobilům diplomatických a konzulárních úředníků. Zelené znaky na

bílé tabulce mají vozidla, která nebyla schválena pro provoz na pozemních komunikacích. Zvláštní motorová vozidla mají černé znaky na žlutém pozadí.

Státní poznávací značky vydávané do roku 2001 obsahovaly kombinaci tří písmen a dvou dvojic číslic oddělených pomlčkou. První dvě písmena byla zkratkou okresu, kde byl automobil zaregistrován, a třetí písmeno označovalo sérii značek. Některé lidnatější okresy měly zkratek několik a Prahu označovalo pouze jedno písmeno. Rozvojem automobilového průmyslu však možné kombinace přestaly dostačovat a vznikl způsob vytváření nových poznávacích značek, který byl popsán v předchozích odstavcích. Tímto novým způsobem lze vydat pro celou Českou republiku přes 20 miliard platných značek.

Samotná tabulka značky je vyrobena ze slitin lehkých kovů, musí mít reflexní provedení a ochranné prvky. Po obvodu všech značek je vylisován barevný okraj s šířkou čáry 4 mm. Barva okraje je shodná s barvou alfanumerických znaků. Základní provedení registrační značky je jednořádkové. Na osobních automobilech se nejčastěji vyskytují jednořádkové značky o rozměrech 520 x 110 mm. Při tomto rozměru jsou znaky 75 mm vysoké a 40 mm široké s tloušťkou čáry 10 mm. Modrý pruh obsahující znak Evropské unie a zkratku země musí být alespoň 98 mm vysoký a 49 mm široký (Obr. 2.1).



Obr. 2.1 Příklad tabulky s registrační značkou

3 POČÍTAČOVÉ VIDĚNÍ

Při tvorbě této kapitoly bylo využito informací ze zdrojů [1], [3], [5], [8], [11].

Počítačové vidění je obor, který se pomocí technických prostředků snaží získávat informace ze zachyceného obrazu. Konkrétně jde například o rozpoznávání obrazu, kontrolu polohy předmětů, kontrolu vzorků na lince a mnoho dalšího. Postup zpracování obrazu probíhá v následujících krocích:

- snímání, digitalizace a uložení diskrétního obrazu,
- předzpracování,
- segmentace obrazu na objekty,
- popis objektů,
- klasifikace objektů.

3.1 Diskrétní obraz

Diskrétní obraz je v počítači uchován jako matice čísel. Každý prvek matice odpovídá konkrétnímu pixelu a číselná hodnota prvku určuje jasovou hodnotu pixelu. V praxi se nejvíce používají tři typy obrazů. Šedotónový osmibitový obraz, který je uložen jako jedna dvourozměrná matice s jasovými hodnotami 0 (černá) až 255 (bílá). Barevný RGB obraz má definovány tři dvourozměrné matice pro každou základní barevnou (červenou, zelenou, modrou) složku zvlášť. Každá matice určuje intenzitu jednotlivých spektrálních složek a teprve jejich složením vznikne dojem barevného obrazu. Posledním typem je obraz černobílý, jehož jasové hodnoty obsahují pouze dvě úrovně: 0 (černá) a 1 (bílá).

3.2 Předzpracování obrazu

Předzpracování je část postupu při zpracování obrazu s cílem obraz jistým způsobem upravit pomocí různých transformací. Předzpracováním nelze získat novou informaci, ale vlivem transformací je možné hledané informace zvýraznit. Vstupem i výstupem předzpracování je obraz. Metody předzpracování se dělí na:

- bodové jasové transformace (např.: změna jasu),
- lokální jasové transformace (např.: odstranění šumu, detekce hran),
- globální jasové transformace (např.: Fourierova transformace),
- geometrické transformace (např.: rotace, zkosení, změna měřítko).

3.2.1 Detekce hran

Hrana je oblast v obraze, ve které dochází k razantní změně jasu. Z optického hlediska jsou hrany hlavními nositeli informací o hranicích objektů. Pro vstupní obraz lze vypočítat obraz vertikálních hran, horizontálních hran nebo obojí kombinovat. Změna jasu v okolí jednotlivých pixelů je měřena gradientem obrazu. Gradient obrazové funkce má dvě složky: hodnotu pro horizontální změny a pro vertikální změny, je to tedy vektor.

Ve spojité oblasti jsou obě složky parciálními derivacemi obrazové funkce a v diskrétní oblasti jsou obě složky aproximovány diferencemi. Pro jejich nalezení se využívá výpočtu konvoluce nad obrazem s různými hranovými operátory (3.1). Obrazový element vstupující do transformace bude označován jako $g(x, y)$ a vystupující jako $f(x, y)$.

$$f(x, y) = g(x, y) * h \quad (3.1)$$

Hranové operátory mohou být takové, které aproximují první derivaci (3.2), například Sobelův, Kirschův, Prewittové. Tyto operátory nejsou invariantní vůči rotaci, a proto je nutné pro kompletní obraz hran počítat konvoluci několikrát s různě natočenými operátory a poté jednotlivé obrazy složit do jednoho.

$$h_S = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}, h_K = \begin{bmatrix} 3 & 3 & -5 \\ 3 & 0 & -5 \\ 3 & 3 & -5 \end{bmatrix}, h_P = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \quad (3.2)$$

Duhou skupinou jsou operátory aproximující druhou derivaci (3.3), např. Laplaceův operátor pro čtyřokolí a Laplaceův operátor pro osmiokolí.

$$h_{L4} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}, h_{L8} = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (3.3)$$

3.3 Segmentace obrazu

Cílem segmentace je rozčlenění obrazu do několika částí, které spolu souvisí. V praxi tak dochází k oddělení objektů nebo znaků od pozadí. Metody vycházejí z předpokladu, že hledaný objekt má jiné obrazové vlastnosti (barvu, jas, texturu) než pozadí. Vedlejším efektem je redukce dat a tím dochází k urychlení dalšího procesu zpracování. Výsledkem segmentace by měl být soubor vzájemně oddělených oblastí, které jednoznačně korespondují s objekty.

Problémy mohou nastat, pokud dochází k překrytí několika objektů, případně pokud je obrazová scéna velmi složitá. Samotná segmentace se může provádět několika metodami, ovšem každá metoda přináší rozdílné výsledky, a proto bývá nutné experimentálně určit, která metoda se na zvolený typ úlohy hodí nejlépe.

3.3.1 Segmentace prahováním

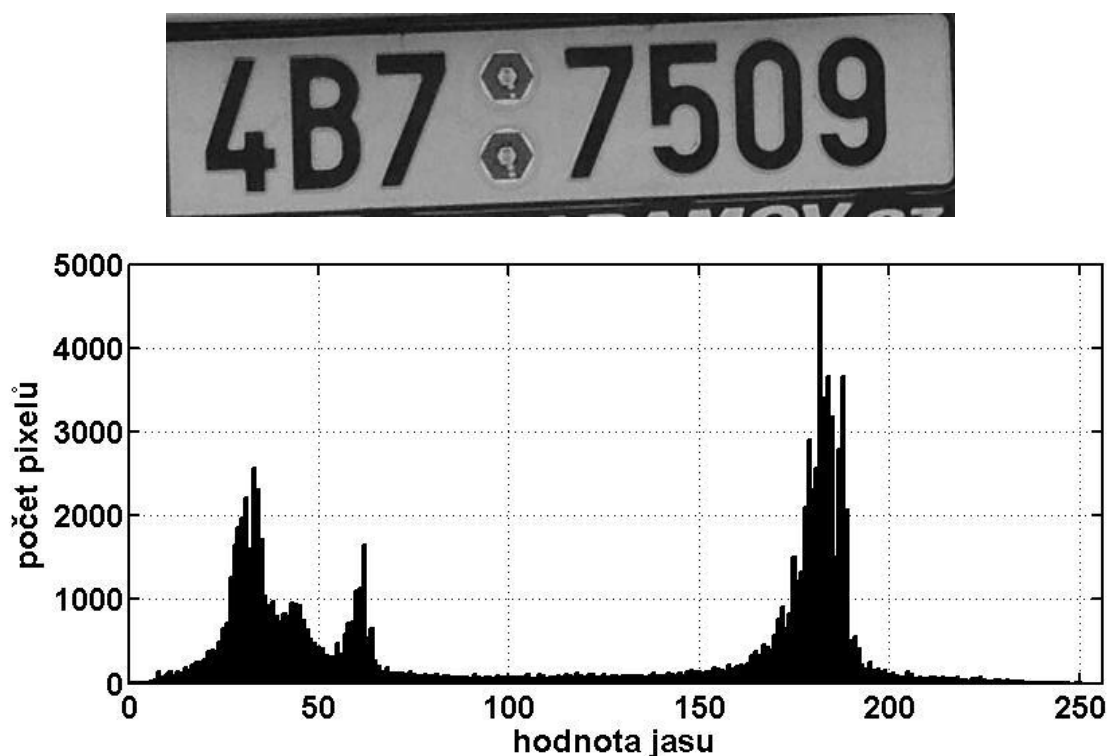
V případě segmentování státní poznávací značky se osvědčila segmentace prahováním. Jedná se o transformaci vstupního obrazu g na výstupní binární obraz f , kde jednotlivé pixely výstupního obrazu mají hodnotu 1 nebo 0 podle toho, zda stejné pixely vstupního obrazu měly hodnotu větší nebo menší než je nastavený práh T (3.4).

$$\begin{aligned}
 f(x, y) &= 1 \quad \text{pro } g(x, y) > T \\
 &= 0 \quad \text{pro } g(x, y) \leq T
 \end{aligned}
 \tag{3.4}$$

Stěžejním problémem této metody je správné nastavení prahu T . Podle typu úlohy a vstupních dat se vybere konkrétní metoda pro určení prahu. Hodnota prahu se může stanovit jedna nebo i více, případně je možné pro rozdílné oblasti určit jiný práh. Při segmentaci registrační značky se však předpokládá, že značka obsahuje pouze tmavé (text) a světlé (bílé pozadí) části, a proto stačí určit jednu hodnotu prahu – prosté prahování. Práh lze určit například experimentálně. Ale pokud je vstupní obraz výrazně světlejší nebo tmavší, segmentace nemusí proběhnout dobře a výsledný obraz může být zkreslený a nevyužitelný pro další zpracování.

Daleko sofistikovanější je určení prahu z histogramu vstupního obrazu, což je graf znázorňující četnost zastoupení jednotlivých jasových úrovní v obraze. Na horizontální ose jsou zastoupeny jasové úrovně a na vertikální ose je počet pixelů s konkrétní jasovou úrovní. Histogramu se také využívá při korekci špatně exponovaných snímků.

Prahová hodnota z histogramu se určí jako lokální minimum mezi dvěma dominantními maximy. V případě prahování registrační značky je tato metoda velmi využitelná, jelikož značka obsahuje primárně světlé a tmavé pixely, což se na histogramu projeví právě jako dominantní maxima (Obr. 3.1).



Obr. 3.1 Registrační značka a její histogram

Další možností je procentní určení prahu. Vychází z předpokladu, že objekt vždy pokrývá určitou konstantní část plochy na snímku, např. 30 %. Proto se práh nastaví tak, aby 30 % pixelů mělo jasovou hodnotu menší než práh T .

Užitečnou metodou je také iterační algoritmus nazvaný Otsu. Metoda iteračně dopočítává hodnotu prahu tak, aby rozptyl hodnot pixelů objektu a zároveň pozadí byl co nejmenší. Existuje několik dalších postupů, jak práh určit. Například výpočtem střední hodnoty jasové úrovně nebo využití mediánu.

3.4 Popis objektů

Každý nalezený objekt je nutné popsat takovým způsobem, aby klasifikátor, v našem případě umělá neuronová síť, mohl úspěšně přiřadit objekt do jedné z předem definovaných tříd. Způsobů, jakým se objekt může popsat, je velké množství, a proto je velmi důležité charakterizovat objekt s ohledem na následující klasifikační algoritmus. Správně zvoleným popisem získáme vektor příznaků, který je pro každý objekt dostatečně odlišný.

Každý segmentovaný objekt je možné v závislosti na zvoleném popisu popsat příznaky neboli deskriptory, které lze rozdělit podle několika hledisek:

- podle domény popisované vlastnosti,
 - fotometrické deskriptory (např.: maximální, minimální jasová úroveň, průměrná jasová úroveň),
 - radiometrické deskriptory (např.: velikost, obvod, kompaktnost, konvexnost),
- podle oblasti výpočtu příznaku,
 - deskriptory založené na hranici (např.: Freemanův kód),
 - deskriptory založené na regionu (příznakový vektor je vypočten na základě hodnot pixelů objektu),
- podle oblasti popisu příznaku,
 - globální deskriptory obrazu (např.: Fourierova transformace, DCT),
 - globální deskriptory objektu (pouze jeden příznak, např.: obvod nebo velikost),
 - lokální deskriptory objektu (příznak vypočten z určité lokální části objektu).

Některé příznaky jsou přímo deterministické, takovými příznaky jsou například velikost, obvod, kompaktnost a další. Jelikož klasifikátorem v této práci je umělá neuronová síť, není nutné, aby ze získaných příznaků bylo možné přímo určit, o jaký objekt se jedná. Proto byly pro popis vybrány takové příznaky, které přímo nesouvisí s vlastnostmi objektů (obvodem, velikostí, podlouhlostí, kompaktností, ...), ale jsou tak obecné, jak to jen bylo možné.

Příkladem velmi obecného popisu může být vektor všech pixelů daného výřezu s objektem. Jelikož je tento způsob popisu závislý na rozměrech, jasu, kontrastu, atd., je velmi důležité objekt před vlastním popisem normalizovat.

3.5 Klasifikace objektů

Klasifikaci objektů má na starost klasifikátor, což je algoritmus, který je při vhodné zvolené a využitelně uložené množině znalostí schopen na základě vstupních dat (v tomto případě příznakového vektoru) přiřadit objekt do jedné z předem určených tříd.

Klasifikačních algoritmů je velmi mnoho, např.: genetické algoritmy, Bayesův odhad, rozhodovací stromy, Markovovy modely, AdaBoost. Jedním z klasifikačních algoritmů jsou také umělé neuronové sítě, které budou, jakožto v této práci využitý klasifikátor, podrobně popsány v kapitole 4.

4 VÍCEVRSTVÉ UMĚLÉ NEURONOVÉ SÍTĚ

Při tvorbě této kapitoly bylo využito informací ze zdrojů [2], [9], [12], [13].

Obecně umělá neuronová síť je matematický algoritmus inspirovaný skutečnými neurony a jejich vzájemným propojením v lidském mozku. Mezi základní výhody neuronových sítí patří především schopnost učit se, to znamená uchovávat znalosti, a schopnost zobecňovat. Znalosti jsou v síti uloženy prostřednictvím vah mezi jednotlivými neurony, což bude vysvětleno v dalším textu.


Umělé neuronové sítě se velmi rychle dostávají do technické praxe, jelikož s narůstajícím výpočetním výkonem není problém používat i topologicky rozměrné sítě, které dříve zpomalovaly celý technický proces. Dnes se neuronové sítě používají k detekci a rozpoznání obličejů, převodu mluveného slova do digitální podoby, předpovídání poruchy systémů, ověřování podpisů, předpovědi počasí a mnoho dalšího. V této práci se využívá schopnosti sítě rozpoznat znaky z obrazových souborů a převodu textu do digitální podoby.

Problematika neuronových sítí je velmi obsáhlá, proto je v této práci výklad omezen na vícevrstvé neuronové sítě s učícím algoritmem zpětného šíření chyby (anglicky error backpropagation). Tento typ sítě je výrazně nejrozšířenějším a nejznámějším modelem, který se používá přibližně v 80 % [12] všech aplikací. Síť má jednoduchý algoritmus učení i vybavení, což usnadňuje programování a implementaci, a přesto je možné dosahovat solidních výsledků v oblasti klasifikací vzorů. Proto nejsou ani jiné sítě v této práci použity.

Obecně si lze vícevrstvou síť představit jako algoritmus, který se snaží pro nějaký vektor vstupních hodnot určitým způsobem přiblížit vektoru výstupnímu tím, že mění hodnoty vah mezi jednotlivými neurony.

4.1 Formální neuron

Formální neuron (Obr. 4.1), dále jen neuron, je základní stavební prvek všech umělých neuronových sítí. Jeho podobnost s biologickým neuronem není náhodná a inspirace v reálném světě je zde více než patrná.



Obr. 4.1 Formální neuron

Formální neuron se skládá z lineární a nelineární části podobných těm z reálného světa. Neuron přijímá signály prostřednictvím n reálných vstupů x_1, x_2, \dots, x_n , stejně jako reálný neuron má pro tuto funkci mnoho dendritů. Všechny vstupy jsou ohodnoceny odpovídající synaptickou vahou w_1, w_2, \dots, w_n , která nabývá hodnot z oboru reálných čísel. Zvážená suma všech vstupních hodnot se nazývá vnitřním potenciálem neuronu ξ . Práh h je zvláštní hodnotou, kterou musí vnitřní potenciál překročit, aby vůbec došlo k průchodu signálu neuronem. Formálně je často záporná hodnota prahu h považována za váhu w_0 příslušící ke vstupu x_0 s konstantní hodnotou 1. Vnitřní potenciál je tedy počítán podle vzorce (4.1).

$$\xi = -h + \sum_{i=1}^n x_i w_i = x_0 w_0 + \sum_{i=1}^n x_i w_i = \sum_{i=0}^n x_i w_i \quad (4.1)$$

Potenciál je poté pomocí přenosové funkce f upraven, případně usměrněn do určitého intervalu. Výstupní hodnotou této přenosové funkce je i výstupní hodnota y (4.2) celého neuronu. U biologického neuronu se tento výstup nazývá axon.

$$y = f(\xi) \quad (4.2)$$

V praxi lze použít několik přenosových funkcí. Nejjednodušším typem přenosová funkce je ostrá nelinearita. Dále je využitelná lineární funkce neboli identita, saturovaná lineární funkce. Velmi využívanými přenosovými funkcemi jsou sigmoida a hyperbolická tangenta (4.3) s nastavitelným parametrem s , jemuž se říká strmost.


$$y = \frac{1 - e^{-s\xi}}{1 + e^{-s\xi}} \quad (4.3)$$

4.2 Topologie umělé neuronové sítě

Obecně umělá neuronová síť je složená z neuronů vzájemně propojených takovým způsobem, že výstup z jednoho neuronu je vstupem do několika dalších neuronů. Topologii umělé neuronové sítě určuje počet neuronů a způsob jejich vzájemného propojení. Topologie sítě typu backpropagation je vícevrstvá a dopředná, což znamená, že informace se v síti šíří pouze jedním směrem. Tedy vazby mezi neurony směřují pouze z nižších (vstupních) vrstev do vyšších (výstupních). Žádné zpětné ani laterální vazby mezi neurony nejsou.

V síti typu backpropagation rozlišujeme tři typy vrstev a tedy i neuronů do nich patřících z hlediska jejich funkce a využití. Jsou to vrstvy vstupní, skryté a výstupní. Neurony v jednotlivých vrstvách jsou propojeny tak, že výstup neuronu dané vrstvy je vstupem do všech neuronů vrstvy následující (Obr. 4.2). Pokud má síť jednu vstupní

vrstvu, jednu skrytou a jednu výstupní, bude v této práci označována jako třívrstvá. V dostupných materiálech se někdy pojmenování liší a výše zmíněná síť by byla označena jako dvouvrstvá.



Obr. 4.2 Čtyřvrstvá umělá neuronová síť

Úkolem vstupní vrstvy je přijetí signálu přivedeného na vstup sítě a jeho delegování do první skryté vrstvy. Počet neuronů ve vstupní vrstvě je dán pouze technickým řešením problému, tedy velikostí dimenze vstupního signálu. Například počet pixelů obrazu 15x15 dává velikost dimenze 225 a je tedy třeba využít síť, která bude mít 225 vstupních neuronů.

Výstupní vrstva slouží k prezentaci výsledků zpracování vstupního signálu neuronovou sítí. Stejně jako ve vstupní vrstvě je počet neuronů ve vrstvě výstupní dán konkrétní aplikací. Příkladem může být neuronová síť sloužící jako klasifikátor číslic. Lze tedy předpokládat, že výstupní vrstva bude mít 10 neuronů, z nichž každý připadá na jednu číslici.

Pokud je tedy nutné nějakým zásadním způsobem ovlivňovat chování a kvalitu umělé neuronové sítě, nezbyvá nic jiného než měnit počet skrytých vrstev a počet neuronů do nich náležících. Většinou je třeba zvolit tyto počty experimentálně s využitím některých heuristik. Podle [6] může být takovou heuristikou pravidlo, že celkový počet vstupních hodnot (počet vstupních vzorů krát dimenze příznakového vektoru) by měl být alespoň desetkrát větší než tzv. stupeň volnosti (počet všech vah a prahových hodnot kromě prahových hodnot vstupní vrstvy).

4.3 Adaptace

Adaptace neboli učení neuronové sítě je algoritmus, při kterém dochází k úpravám vah a prahových hodnot s cílem co nejvíce snížit celkovou chybu neuronové sítě. V neuronové síti se způsobem učení typu backpropagation probíhá učení s učitelem. To znamená, že je známý požadovaný výstup, tudíž je možné vypočítat rozdíl mezi požadovaným a skutečným výstupem a tedy i celkovou chybu sítě, kterou vyžaduje algoritmus pro adaptaci vah.

Učení může probíhat buď tzv. online, nebo dávkově. Při online učení je po každém předloženém tréninkového vzoru adaptovány všechny váhy. Tento algoritmus je výpočetně náročnější než dávkové neboli akumulované učení, při kterém jsou sítě předloženy všechny tréninkové vzory, následně je vypočítána celková chyba sítě a na jejím základě jsou přepočítány i váhy. Tomuto algoritmu se budou věnovat i následující odstavce.

Algoritmus adaptace lze rozdělit na tři etapy:

- dopředné šíření vstupního signálu,
- zpětné šíření chyby – výpočet chyby celkové E_c a vztažené E_h na tréninkové vzory,
- adaptace vah a prahů.

Tyto tři kroky se iteračně opakují, dokud není splněna podmínka pro ukončení adaptace. Tato podmínka většinou bývá stanovena jako jistá hodnota, pod kterou musí klesnout celková chyba sítě. Pojem celková chyba sítě bude vysvětlen v podkapitole 4.3.1.

Význam použitých proměnných v následujících vzorcích:

- L ... počet vrstev neuronů, L -tá vrstva je tedy výstupní,
- y ... současná hodnota výstupu z neuronu,
- d ... žádaná hodnota výstupu z neuronu,
- x ... vstupní hodnota do neuronu,
- i ... index konkrétního neuronu v $L-2$ vrstvě,
- j ... index konkrétního neuronu v $L-1$ vrstvě,
- k ... index konkrétního neuronu ve výstupní vrstvě L ,
- m ... počet neuronů ve výstupní vrstvě,
- p ... počet tréninkových vzorů,
- h ... index konkrétního tréninkového vzoru,
- t ... aktuální iterační krok,
- $t+1$... následující iterační krok,
- ξ ... vnitřní potenciál neuronu.

4.3.1 Celková chyba sítě

Aby bylo možné určit celkovou chybu sítě při učení, musí být k dispozici tréninková množina, což je množina uspořádaných dvojic v podobě vzoru a požadovaného výstupu. Tréninkovou množinou by měl být reprezentativní vzorek vstupních dat, která bude neuronová síť rozpoznávat. Kvalita tréninkové množiny výrazně ovlivňuje kvalitu naučené neuronové sítě.

Celková chyba sítě tedy udává míru naučenosti sítě, což je odchylka mezi požadovanými a skutečnými hodnotami výstupů pro dané tréninkové vzory. Vzhledem k jednomu h -tému vzoru je chyba E_h dopočítávána podle vzorce (4.4) jako polovina


součtu čtverců rozdílů výstupů y všech výstupních neuronů od požadovaných hodnot výstupů d všech výstupních neuronů, jejichž počet je m .

$$E_h = \frac{1}{2} \sum_{j=1}^m (d_{hj} - y_{hj})^2 \quad (4.4)$$

Celková chyba E_c (4.5) umělé neuronové sítě je potom součet chyb E_h všech tréninkových vzorů h , jejichž počet je p .

$$E_c = \sum_{h=1}^p E_{hp} = \frac{1}{2} \sum_{h=1}^p \sum_{j=1}^m (d_{hj} - y_{hj})^2 \quad (4.5)$$

Průběh celkové chyby v čase, respektive v závislosti na počtu vykonaných iterací adaptace, znázorňuje tzv. chybová funkce (Obr. 4.3).



Obr. 4.3 Názorný průběh chybové funkce

4.3.2 Adaptace vah a prahů

V této kapitole je adaptace prahů zobecněna na adaptaci vah pro vstup do neuronu s hodnotou 1. V následujících vzorcích se vyskytuje přenosová funkce typu hyperbolický tangens (4.3). Tato funkce je pro použití ve vzorcích velmi výhodná, jelikož je derivovatelná v celém svém definičním oboru.

Adaptace váhy mezi výstupní vrstvou L a poslední skrytou vrstvou $L-1$ se vypočítá podle následujících vzorců:

$$w_{jk}(t + 1) = w_{jk}(t) + \Delta w_{jk}(t + 1) \quad (4.6)$$

$$\Delta w_{jk} = -\mu \frac{\delta E_c}{\delta w_{jk}} = -\mu \sum_{h=1}^p \frac{\delta E_h}{\delta w_{jk}} \quad (4.7)$$

$$\frac{\delta E_h}{\delta w_{jk}} = \frac{\delta E_h}{\delta y_k} \frac{\delta y_k}{\delta \xi_k} \frac{\delta \xi_k}{\delta w_{jk}} = (d_k - y_k) \frac{s_k}{2} (1 - y_k^2) x_j \quad (4.8)$$

Ve vzorci (4.7) se vyskytuje parametr μ , který se nazývá koeficientem učení. Jeho hodnota se volí experimentálně ještě před začátkem učení v intervalu $(0, \infty)$. Pokud se zvolí velmi malá hodnota, chybová funkce konverguje k maximální zvolené chybě velmi pomalu, případně k naučení nemusí vůbec dojít. Naopak vysoký koeficient učení může mít za následek rozkmitání chybové funkce. V tomto případě také nemusí vůbec dojít k naučení sítě nebo je naučení výsledkem náhody.

Adaptace vah mezi vrstvami L-1 a L-2 se vypočte analogicky až na parciální derivaci chyby E_h podle y_k , viz následující vzorce:

$$w_{ij}(t + 1) = w_{ij}(t) + \Delta w_{ij}(t + 1) \quad (4.9)$$

$$\Delta w_{ij} = -\mu \frac{\delta E_c}{\delta w_{ij}} = -\mu \sum_{h=1}^p \frac{\delta E_h}{\delta w_{ij}} \quad (4.10)$$

$$\frac{\delta E_h}{\delta w_{ij}} = \frac{\delta E_h}{\delta y_j} \frac{\delta y_j}{\delta \xi_j} \frac{\delta \xi_j}{\delta w_{ij}} = \frac{\delta E_h}{\delta y_j} \frac{s_j}{2} (1 - y_j^2) x_i \quad (4.11)$$

$$\frac{\delta E_h}{\delta y_j} = \sum_{k=1}^m \frac{\delta E_h}{\delta y_k} \frac{\delta y_k}{\delta \xi_k} \frac{\delta \xi_k}{\delta y_j} = \sum_{k=1}^m (d_k - y_k) \frac{s_k}{2} (1 - y_k^2) w_{jk} \quad (4.12)$$

A po dosazení (4.8) do (4.7) vychází:

$$\frac{\delta E_h}{\delta w_{ij}} = \sum_{k=1}^m (d_k - y_k) \frac{s_k}{2} (1 - y_k^2) w_{jk} \frac{s_j}{2} (1 - y_j^2) x_i \quad (4.13)$$

Jelikož ve zbytku textu nebudou použity jiné sítě než s jednou skrytou vrstvou, jsou výše uvedené vzorce dostatečné pro praktický výpočet adaptace všech vah.

4.4 Aktivace

Aktivace neuronové sítě probíhá postupně, kdy se na vstupní vrstvy přivede signál. Od vstupních vrstev směrem k výstupním se dopočítávají výstupy neuronů podle vzorců (4.1) a (4.2). Aktivace je kompletní po vypočtení výstupů u neuronů ve výstupní vrstvě, tyto hodnoty jsou zároveň výstupem celé neuronové sítě.

5 REŠERŠE PRACÍ ZABÝVAJÍCÍCH SE ROZPOZNÁVÁNÍM REGISTRAČNÍCH ZNAČEK

Problémem rozpoznání státní poznávací značky se zabývají soukromé firmy i akademické práce. Problém je ovšem velmi komplexní, proto existuje několik způsobů, jak rozpoznávání vyřešit. Řešení se nejvíce liší ve způsobech vyhledání registrační značky v obraze, v popisu jednotlivých znaků a ve způsobu klasifikace znaků pomocí různých klasifikátorů. Proto je tato kapitola rozdělena na víc podkapitol, jejichž názvy korespondují s jednotlivými kroky řetězce zpracování obrazu. U každého kroku jsou uvedeny principy či metody, které byly využity ve zkoumaných textech, a využitelné informace, které mohly přispět k lepšímu řešení problému této práce.

V rámci rešerše byly zahrnuty i ty práce, které nerozpoznávaly registrační značky pomocí umělých neuronových sítí nebo naopak pomocí neuronových sítí rozpoznávaly pouze samostatné znaky. Pro lepší orientaci v rešerši je zde uveden seznam prozkoumaných prací:

[1] ADAMEC, Václav. *Zpracování a rozpoznání obrazu*. Olomouc, 2011. Bakalářská práce. Přírodovědecká fakulta univerzity Palackého. Vedoucí práce Mgr. Eduard Bartl, Ph.D.

[3] ČERNÝ, Matěj. *Rozpoznávání registračních značek motorových vozidel*. Pardubice, 2010. Diplomová práce. Univerzita Pardubice. Vedoucí práce Ing. Martin Dobrovolný, Ph.D.

[5] DOBROVOLNÝ, Martin. *Rychlý algoritmus rozpoznání registračních značek vozidel*. 2009, čtvrtý ročník, č. 3.

[9] 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.

[11] SMÉKAL, 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.

[13] VALA, Tomáš. *Rozpoznávání SPZ z jednoho snímku*. Uherské Hradiště, 2006. Diplomová práce. Univerzita Karlova v Praze. Vedoucí práce RNDr. Jana Štanclová.

5.1 Lokalizace

Prvním krokem při rozpoznávání registrační značky je nalezení samotné tabulky v obraze. Lze najít několik způsobů, jak lokalizaci provést. Hodně postupů vychází ze stejných či podobných principů:

- a) metoda hledající předem definovaný blok pixelů obsahující velké množství vertikálních hran (využito v: [1], [5], [11], [13]),
- b) metoda využívající dvourozměrnou korelaci uměle vytvořené masky registrační značky a zvoleného regionu v obraze (využito v: [5]).

ad a) Tato metoda se považuje za obvyklou při lokalizaci registračních značek. Tento postup lokalizuje značku spolehlivě, pokud se v obraze nevyskytují oblasti s podobnými vlastnostmi, např. vertikální mřížkou na automobilu. Autorovi článku [5] ovšem nevyhovovala přesnost, s jakou algoritmus označil registrační značku. Autor práce [13] rozdělil lokalizaci na hrubou a jemnou, přesto se mu nepodařilo lokalizovat značku s vysokou úspěšností. Proto musel rohy RZ označovat ručně.

ad b) Přesnost lokalizace registračních značek se při použití této metody v článku [5] zvýšila natolik, že všechny výřezy nalezených značek byly téměř identické a absolutní poloha znaků se shodovala.

5.2 Předzpracování

Před samotnou segmentací bylo téměř ve všech případech nutné provést drobné či větší korekce, protože vliv reálného prostředí způsobuje vždy určitou míru zkreslení. Zároveň po oddělení jednotlivých znaků bylo nutné provést další předzpracování. Mezi základní korekce patřilo:

- a) filtrování šumu (využito v: [11], [13]),
- b) detekce hran (využito v: [3], [11], [13]),
- c) oprava natočení značky (využito v: [5], [13]),
- d) mapování výřezu SPZ do definovaného obdélníka (využito v: [13]),
- e) normalizace znaků (využito v: [3], [5], [11], [13]),
- f) oříznutí bílých okrajů (využito v: [3], [5], [13]),
- g) ekvalizace histogramu (využito v: [3], [11], [13]),
- h) a další.

ad b) Pro detekci hran se využívá korelace obrazu s hranovým operátorem. Často používaným byl Sobelův operátor. Některé aplikace využily Prewittův operátor.

ad g) Tato úprava byla aplikována na již vyříznutou registrační značku a způsobila v práci [13] téměř dvojnásobnou úspěšnost rozpoznání znaků.

5.3 Segmentace

Jelikož na precizním provedení segmentace závisí úspěšnost následné klasifikace znaků, hodně materiálů obsahuje postupy, jak docílit správné segmentace, ale téměř všechny články využívaly segmentaci prahováním.

V práci [13] využil autor metodu prahování, která hledá hodnotu prahu v určitém okolí právě zpracovávaného pixelu. Nejlépe se mu osvědčilo okolí 21x21 pixelů. Hodnotu prahu určil autor jako vážený součet okolí se střední hodnotou v právě zpracovávaném pixelu. V práci [5] a [11] využili autoři metodu Otsu, která adaptivně vypočítá práh. Práce [1] využila napevno stanovený práh.

5.4 Separace znaků

Všechny klasifikační metody v prostudovaných materiálech rozpoznávaly registrační značky po jednotlivých znacích. Proto bylo vždy nutné znaky od sebe oddělit a klasifikačním algoritmům je předkládat samostatně.

Velmi často využívanou metodou pro separaci objektů je využití vertikálních a horizontálních projekcí černých pixelů. V těchto projekcích jsou potom nalezeny úseky odpovídající jednotlivým objektům. Této metody využil autor v práci [13], když takto odděloval řádky dvouřádkové registrační značky i znaky v jednotlivých řádcích. Následně normalizoval oddělené znaky do čtverce o velikosti 30x30 pixelů s tím, že nedošlo k deformaci (změně poměru) znaků.

Autor v článku [5] po segmentaci indexoval všechny spojité regiony v obraze. Následně byla pro každý objekt nalezena minimální a maximální souřadnice a znak byl vyříznut.

5.5 Popis znaků

Jelikož každá metoda klasifikace znaků vyžaduje jiný přístup a jiné vstupní hodnoty, liší se i příznakový vektor, který autoři zvolili jako vhodný pro jejich práci. Příznakový vektor se liší primárně různými hodnotami a jejich počtem dle zvoleného popisu. Přestože způsoby popisu jsou velmi rozmanité, nelze považovat žádný za nejlepší a je třeba vyzkoušet několik možností a ověřit, které se nejlépe hodí pro řešení daného problému.

Příklad příznakových vektorů, které se vyskytly ve zkoumané literatuře:

- a) hodnoty všech pixelů obrazu (využito v: [13]),
- b) hodnoty vypočtené jako poměr nenulových pixelů ku ploše okna o velikosti 6x6 pixelů, které postupně prochází celý obraz (využito v: [13]),
- c) normalizované hodnoty vertikální a horizontální projekce černých pixelů složené za sebou (využito v: [13]),
- d) hodnoty normalizovaných centrálních momentů (využito v: [9], [13]).

ad d) Využití normalizovaných centrálních momentů se jeví jako dobré, jelikož tento popis je invariantní vůči posunutí, otočení a změně měřítka.

5.6 Klasifikace znaků

Pro rozpoznání neboli klasifikaci objektů (znaků) bylo v prostudovaných pracích využito těchto prostředků:

- a) umělých neuronových sítí (využito v: [11], [13]),
- b) skrytých Markovových modelů (využito v: [13]),
- c) metoda porovnávání se šablonami (využito v: [1], [5], [3], [13]).

ad a) Výsledky v práci [9] vedou k domněnce, že úspěšnost rozpoznání objektů nezávisí na počtu neuronů ve skryté vrstvě neuronů v UNS ve třívrstvé síti, pokud jich je dostatek k tomu, aby se síť dostatečně naučila. Ale naopak závisí na koeficientu učení, strmosti přenosové funkce ve smyslu nepřímé úměrnosti a na hodnotě celkové chyby sítě, která byla stanovena na 0,025 jako optimální.

ad c) Metoda porovnává objekt s danými šablonami a po nalezení extrému shody funkce je vybrán kandidátní znak. Tato metoda je velmi citlivá na posunutí a rotaci, proto úspěšnost správného rozpoznání závisí na kvalitním předzpracování a segmentaci.

5.7 Vyhodnocení

Výše uvedenými postupy dosahovali autoři velmi rozdílných výsledků úspěšnosti rozpoznávání registračních značek v rámci testovací množiny. Tato úspěšnost pochopitelně závisí na různorodosti testovací množiny, na využití reálných dat a především na cílevědomosti autorů vypořádat se všemi možnými problémy a vyladěním rozpoznávání do úplné dokonalosti.

V práci [9] dosáhl autor úspěšnosti rozpoznání 99,23 % na uměle vytvořených datech pomocí třívrstvých neuronových sítí. Těmito daty byla prostá písmena, různě otočená a zmenšená.

Autor v práci [13] rozpoznával reálná data a to registrační značky s latinskými a emirátskými číslicemi. Přestože vyzkoušel několik klasifikátorů, neuronové sítě měly nejlepší výsledky rozpoznání. S úspěšností 97 % rozpoznávaly latinské číslice a emirátské číslice byly rozpoznávány s 89 % úspěšností.

V práci [1] autor rozpoznával vlastnoručně nafocené snímky s úspěšností 80,7 %. Práce [3] se zabývala rozpoznáváním českých registračních značek. Testovací data z reálného provozu si autor pořídil sám. Jím navržená metoda dokázala rozpoznávat registrační značky s úspěšností 63 %.

6 LOKALIZACE REGISTRAČNÍ ZNAČKY

Kvalitní lokalizace registrační značky v obrazu je sice nezbytný, ale náročný proces. Vytvořit univerzální a kvalitní algoritmus pracující ve všech světelných podmínkách a s různými pixelovými rozměry registrační značky na snímku je velmi obtížné. Protože se tato práce zaměřuje primárně na využití neuronových sítí jako klasifikátoru znaků, je při návrhu lokalizace využíváno především algoritmicky jednodušších metod.

6.1 Snímání

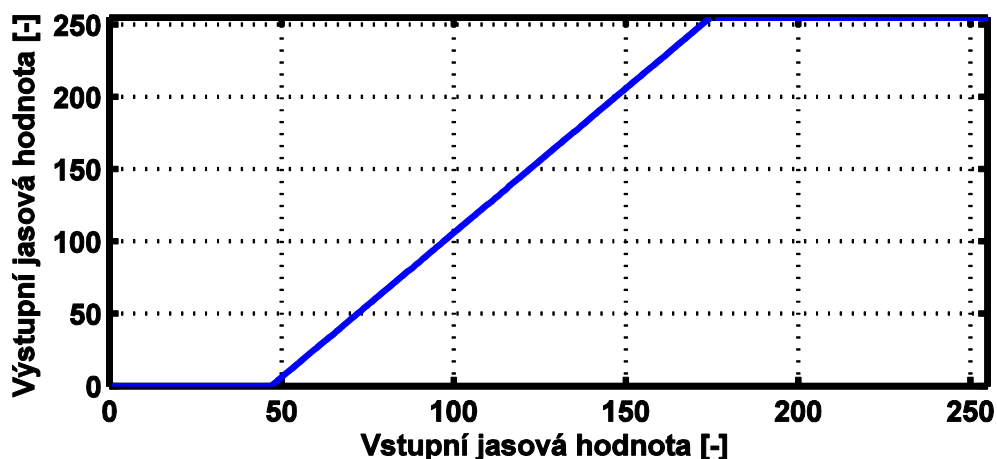
Data, respektive fotografie se značkami (Obr. 6.1) byly pořízeny v exteriéru za běžného počasí (slunečno, oblačno i deštivo). Snímky tedy obsahovaly všechny nedostatky reálného prostředí, například znečištěné značky, poškozené, natočené atd. Fotografie byly pořízeny mobilním telefonem s rozlišením 8 MPx ze vzdálenosti přibližně tří metrů a kolmo na značku. V praxi tato pozice odpovídá automobilu, který přijede před vstupní bránu, zastaví se a proběhne pořízení snímku. Po rozpoznání registrační značky může například dojít k porovnání s databází značek, na jehož základě je automobil vpuštěn dále.



Obr. 6.1 Příklad dat pořízených k rozpoznávání registračních značek

6.2 Předzpracování snímku

Předzpracování bylo prováděno s ohledem na nejlepší možné dosažené výsledky po segmentaci. Cílem předzpracování snímku bylo zvýraznění registrační značky ve smyslu zesvětlení bílé části registrační značky a naopak ztmavení rámečku kolem tabulky. Toho se dosáhlo, pokud byla využita bodová jasová transformace zvýšení kontrastu. Obraz byl barevný (RGB), proto bylo nutné zvýšit kontrast u všech tří barevných hladin. Převodní charakteristika jednotlivých jasových bodů je zobrazena na Obr. 6.2.



Obr. 6.2 Příklad převodní charakteristiky pro zvýšení kontrastu

Zlomové body na charakteristice byly spočítány pro každý snímek separátně na šedotónovém obraze. Zlomový bod s nižší jasovou úrovní byl dopočítán jako jasová hodnota, pod kterou se nachází jas 10 % ze všech pixelů v obraze. Naopak druhý zlomový bod byl určen jako jasová hodnota, nad kterou se nachází jas 40 % pixelů obrazu. Tyto hodnoty byly zvoleny experimentálně. Zvýšení jasu světlých částí na snímku s registrační značkou mělo především pozitivní efekt u snímků celkově tmavších, pořízených například v šeru nebo při podmračeném počasí (Obr. 6.3).



Obr. 6.3 Snímek před (vlevo) a po předzpracování

Naproti tomu snížení jasu u částí tmavých bylo výhodné na obrazech slunečných, na kterých docházelo k odleskům i na rámečku kolem značky, což dále mohlo vést ke špatné segmentaci.

6.3 Segmentace snímku

Žádoucím výsledkem segmentace pro další zpracování byla bílá tabulka se značkou a černý, v žádném místě nepřerušný rámeček okolo. Na kvalitě segmentace znaků, samolepek nebo vlajce Evropské unie nezáleželo.

Během návrhu systému byly vyzkoušeny dvě varianty segmentace prahováním. Prvním způsobem bylo prahování šedotónového snímku s pevně nastaveným a experimentálně určeným prahem, případně s prahem vypočítaným pomocí metody Otsu (kapitola 3.3.1, [7]).

Druhou variantou bylo prahování každé barevné složky RGB zvlášť a následné složení tří binárních snímků dohromady pomocí logické funkce and. Pokud tedy měl pixel na stejné pozici ve všech separátních binárních obrazech hodnotu 1, měl i pixel ve výsledném obraze hodnotu 1. V opačném případě byla výsledná hodnota pixelu rovna 0. Právě druhá varianta dosahovala lepších výsledků, jelikož dokázala eliminovat barevné objekty na snímku a naopak zvýraznila pouze bílé nebo světlešedé části. Prahy pro segmentaci barevných složek snímku byly zvoleny experimentálně na pevnou hodnotu vzhledem k důvodu, že světlost samotné značky a rámečku nezávisela na celkové světlosti snímku. Pokud tedy byl na snímku světlý automobil a hodně oblohy, ale registrační značka byla ve stínu, nebyl problém s jejím zvýrazněním. Naopak dopočítávání prahu pomocí Otsu metod nebo s využitím průměrných jasových úrovní snímku by mělo za následek ztmavení oblasti s registrační značkou.

Pro další zvýšení úspěšnosti lokalizace byla druhá varianta prahování provedena dvakrát s různými prahy. Jedna hodnota prahu byla vyladěna pro značky ve stínu, naopak druhá hodnota měla smysl pro sluncem osvětlené značky. Na Obr. 6.4 jsou vidět výsledky segmentace s různými prahy. V tomto případě je značka lokalizovatelná na obou výstupech, ale v jiných případech mohla být značka výrazná pouze na jednom.



Obr. 6.4 Snímek po segmentaci s různými prahy

6.4 Výběr kandidáta

Na segmentovaných černobílých snímcích bylo nutné najít oblast, ve které se nachází registrační značka. K tomu byla využita indexace bílých oblastí. To znamená, že na obou snímcích byla nalezena každá bílá černě-ohraničená oblast. Tyto oblasti se postupně procházely od oblastí s největším počtem bílých pixelů a u každé právě analyzované oblasti byl nalezen obdélník opsaný této oblasti. Tímto způsobem bylo analyzováno 20 největších bílých oblastí na obou snímcích.

Pokud opsaný obdélník splňoval základní podmínky:

- poměr šířky ku výšce byl mezi 3 až 6,
- poměr bílých pixelů ku počtu všech pixelů v obdélníku byl větší než 0,4,

byla jeho velikost a pozice využita jako výřez z původního barevného snímku. Všechny takto vzniklé výřezy byly považovány za kandidáty. Ty byly převedeny na šedotónový formát a u každého kandidáta byly nalezeny vertikální hrany. S využitím poznatku, že registrační značka obsahuje vysoký počet vertikálních hran, byl u každého výřezu vypočten právě počet hran respektive hranových bodů. Kandidát, který obsahoval největší počet hran vzhledem ke svému rozměru, byl označen jako registrační značka a pokračoval k dalšímu zpracování. Několik takto lokalizovaných značek je ukázáno na Obr. 6.5.



Obr. 6.5 Příklad výstupu lokalizačního algoritmu

Takto navrhnutým lokalizačním algoritmem bylo nalezeno 450 registračních značek z 527 snímků. Po vyřazení slovenských nebo jinak nevyhovujících značek zbylo pro další testování 420 vyřiznutých registračních značek.

7 POPIS REGISTRAČNÍ ZNAČKY

Kvalita popisu a tedy i klasifikace registrační značky do značné míry závisí také na kvalitě předzpracování a segmentace obrazu registrační značky, proto jsou v této kapitole tyto části zpracování obrazu také zahrnuty.

7.1 Předzpracování registrační značky

Následující postupy jsou pro správné rozpoznání jednotlivých znaků naprosto klíčové. Výstup lokalizačního algoritmu, tedy výřez (Obr. 7.1) nebyl vždy stejný, proto bylo nutné značku před separací jednotlivých znaků upravit, aby byly jednotlivé znaky co nejvíce podobné tréninkové množině. Správně a kvalitně provedeným předzpracováním bylo možné velmi zvýšit kvalitu klasifikace jednotlivých znaků.



Obr. 7.1 Značka před předzpracováním

Před konkrétními úpravami se nejdříve barevný RGB výřez převedl na šedotónový (Obr. 7.2) pomocí vzorce (7.1).

$$f_{\text{šed}}(x, y) = C_R \cdot g_R(x, y) + C_G \cdot g_G(x, y) + C_B \cdot g_B(x, y) \quad (7.1)$$



Obr. 7.2 Šedotónový obraz registrační značky

Hodnoty koeficientů $C_R = 0,299$, $C_G = 0,587$, $C_B = 0,114$ byly empiricky zvoleny na základě informací z [8].

Podobně jako v kapitole 6.2 byl zvýšen kontrast šedotónového snímku pomocí převodní charakteristiky, jejíž zlomový bod s nižší jasovou úrovní byl dopočítán jako jasová hodnota, pod kterou se nachází jas 10 % ze všech pixelů v obraze. Naopak druhý zlomový bod byl určen jako jasová hodnota, nad kterou se nachází jas 30 % pixelů obrazu. Hodnoty byly stanoveny experimentálně.




Obr. 7.3 Registrační značka po zvýšení kontrastu

Bylo běžné, že nasnímaná tabulka registrační značky byla o několik stupňů pootočená. Buď vlivem nesprávného přichycení tabulky k automobilu, nebo nakloněným snímacím zařízením. Nakloněná značka je velmi nežádoucím případem pro další úpravy, jelikož naklonění v jednotkách stupňů téměř znemožňuje separaci jednotlivých znaků navrženou metodou. A v důsledku rozdílného natočení rozpoznávaného znaku a vzoru velmi snižuje úspěšnost samotné klasifikace objektu. Proto byla využita metoda korekce natočení značky.



Obr. 7.4 Černobílý binární obraz registrační značky

Nejdříve se značka převedla na černobílou pomocí prahování (Obr. 7.4, kapitola 7.2), poté bylo nutné detekovat horizontální hrany na značce. To se provedlo pomocí dvourozměrné konvoluce obrazu se Sobelovým operátorem. Tímto se na snímku zvýraznily dvě hrany (nahore a dole, Obr. 7.5).



Obr. 7.5 Obraz horizontálních hran registrační značky

Následně se vypočítaly horizontální projekce světlých bodů, které značily hrany, pro různá naklonění značky. Úhel korekce byl nalezen jako úhel, při kterém dosahovalo globální maximum konkrétní projekce nejvyšší hodnoty ze všech spočítaných projekcí. Jako dostačující se ukázalo počítat různé náklony po půl stupních. Jelikož výřez značky

již nemá vysoké rozlišení, bylo by zbytečné počítat jemnější rozdíly náklonů, protože hrubé rozlišení obrazu by nebylo schopné tyto mírné náklony přesně zobrazit. Následně se o korekční úhel otočila i původní šedotónová značka.



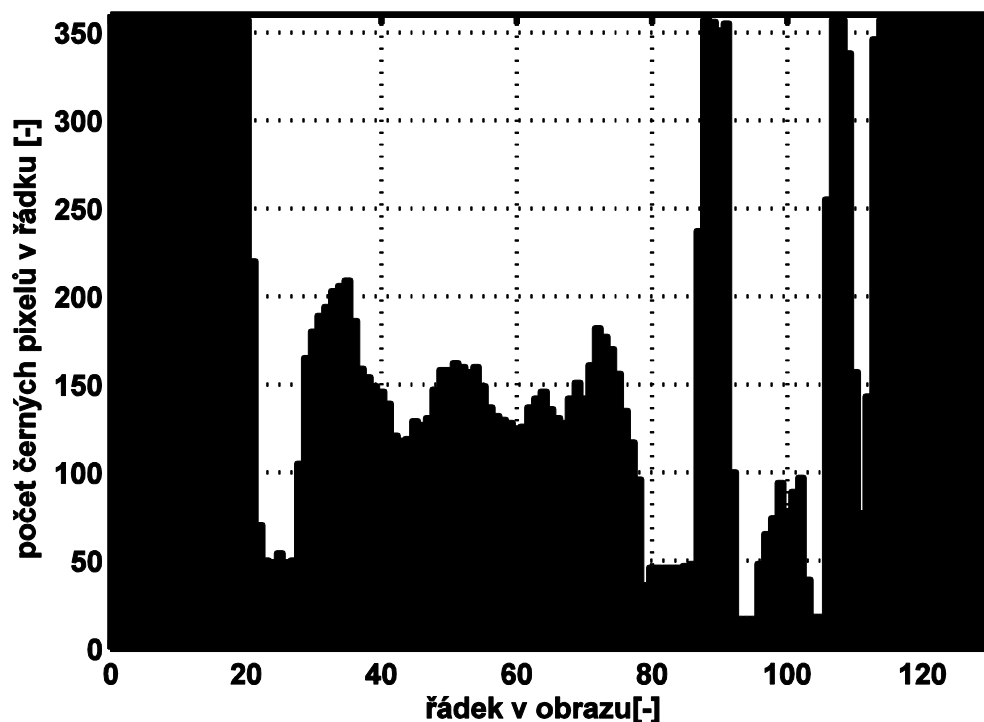
Obr. 7.6 Obraz registrační po korekci natočení

Další korekce, která proběhla téměř vždy, měla za úkol odstranění neoříznutých okrajů nahoře a dole. Tato korekce také nejdříve využila binární snímek z korekce natočení. Nejdříve se sečetly černé pixely v jednotlivých řádcích černobílého obrazu (Obr. 7.7), čím vznikla horizontální projekce obrazu, realizovaná jako vektor s počtem prvků rovnajícím se počtu řádků obrazu.



Obr. 7.7 Černobílý obraz registrační značky po korekci natočení

Pokud se tento vektor graficky znázorní (Obr. 7.8), mezery mezi neoříznutým okrajem a znaky se v grafu jeví jako dvě minima relativně souměrná kolem středu grafu.




Obr. 7.8 Horizontální projekce registrační značky

Z tohoto předpokladu také vychází navržený algoritmus, který postupně prošel celý vektor hodnot, a pokud našel tato minima, vyříznul z šedotónového obrazu pouze řadu znaků bez okrajů nahoře i dole (Obr. 7.9).



Obr. 7.9 Šedotónový oříznutý obraz registrační značky

Protože lokalizace neproběhla vždy stejně a dostatečně přesně, stávalo se, že vyříznutá značka obsahovala na okrajích tmavé pruhy, což bývaly části modrého obdélníka Evropské unie nebo kus plastového držáku na tabulku registrační značky. Pokud byl takový okraj dostatečně úzký, mohlo se stát, že prošel celým procesem rozpoznávání a byl klasifikován jako písmeno I. Aby se tomu předešlo, bylo po segmentaci (kapitola 7.2) na pravý a levý okraj obrazu přidáno dodatečně černé pole o velikosti 10 % šířky celého obrazu (Obr. 7.10). Tato pole se spojila s původním úzkým okrajem a dohromady vytvořily velký široký objekt, který navržený separační algoritmus vyřadil jako nevyhovující.



Obr. 7.10 Registrační značka s přidávanými pruhy vlevo a vpravo

V rámci předzpracování bylo vyzkoušeno využití filtrace šumu i morfologických operací pro zvýšení komplexnosti znaků, ale v obou případech úspěšnost rozpoznání spíše klesla, proto nebyly tyto metody v rámci rozpoznávání aktivní.

7.2 Segmentace znaků

Po provedení všech kroků v rámci předzpracování se následně obraz převedl na černobílý (binární) pomocí metody prahování (Obr. 7.10). Výsledkem této úpravy by měly být zvýrazněné (segmentované) jednotlivé znaky, případně štítky z měření emisí a neoříznuté okraje okolo celé tabulky.

Jelikož na správné volbě prahu závisí úspěšné provedení segmentace, bylo vyzkoušeno několik metod volby prahu. Úspěšnost každé metody byla posouzena na základě algoritmu, který porovnával, zda segmentovaná značka má správný počet znaků (ve většině případů tedy 7). Pokud tato podmínka nebyla splněna, byla značka započítána jako špatně segmentovaná.

První metoda volby prahu využívala konstantní hodnotu prahu - konkrétně 128. Pokud tedy byla jasová úroveň konkrétních pixelů vstupního obrazu nad touto hodnotou, byla výsledná hodnota pixelu výstupního 1. Všechny ostatní pixely potom měly hodnotu 0. V důsledku zvýšení kontrastu v předzpracování využívajícího relativní hodnoty zlomových bodů v převodní charakteristice dosáhla tato metoda výsledku 16 špatně segmentovaných registračních značek ze 420.

Druhá metoda volila jako hodnotu prahu průměrnou jasovou hodnotu celého obrazu. Výsledkem bylo 35 špatně segmentovaných značek.

Třetí metoda využila barevný původní obraz s tím, že každá barevná složka byla segmentována separátně a výsledný obraz poté vzniknul složením všech tří černobílých obrazů dohromady pomocí logického součinu. S touto metodou nebylo možné dosáhnout lepších výsledků než 100 chybně segmentovaných registračních značek.

Čtvrtý způsob určení prahu využíval histogram obrazu. Vždy bylo nalezeno lokální minimum mezi dvěma dominantními maximy, které představovaly tmavé a světlé pixely v obraze. Tato metoda ale silně selhávala, pokud byla část značky zastíněná nebo nerovnoměrně osvětlená, protože poté se na histogramu objevilo více dominantních maxim a nebylo jasné, v jakém místě hledat lokální minimum. Metoda chybně segmentovala 79 značek.

Pátá metoda je iterační a je založena na prostém faktu, že aktuální práh od sebe dělí právě dvě množiny pixelů, tj. pixely pozadí a pixely objektů. V každé iteraci je stanovena průměrná hodnota pixelů pozadí a průměrná hodnota pixelů objektů a z těchto dvou

hodnot je stanoven práh další iterace jako jejich aritmetický průměr. Pro první iteraci byl uvažován práh 1, to znamená pozadí je tvořeno pixely s jasovou hodnotou 0, ostatní pixely se považují za objekty. Metoda špatně segmentovala 15 registračních značek.


Šestou metodou je také iterační algoritmus Otsu. S touto metodou bylo dosaženo nejlepšího výsledku 14 špatně segmentovaných značek, příklad je vidět na Obr. 7.11.




Obr. 7.11 Příklad špatně segmentovaných registračních značek (vpravo) a jejich šedotónové originály (vlevo)

7.3 Separace znaků

Jednotlivé znaky se separovaly téměř shodným způsobem, jako se odstranily přebytečné okraje v předchozím kroku. Hlavním rozdílem bylo sečtení černých pixelů v jednotlivých sloupcích a jako minima na grafickém znázornění (Obr. 7.12) se projevíly mezery mezi jednotlivými znaky. Při separaci každého znaku se ihned ověřovalo, zda se jedná přímo o alfanumerický znak nebo o vadu v obraze případně neoříznutý okraj vpravo nebo vlevo značky zesílený přidanými černými pruhy.




Obr. 7.12 Horizontální projekce před separací jednotlivých znaků



Obr. 7.13 Příklad objektů vyřazených při separaci

Pokud separovaná oblast byla užší než určitý poměr k celkovému obrazu nebo pokud poměr černých ku celkovému počtu pixelů byl velmi vysoký, nebo naopak nízký, byla oblast zahozena jako rušivý artefakt. Všechny hodnoty byly stanoveny experimentálně. Takto byly detekovány zbytky okolí značky, šrouby přidržující značku nebo nečistoty. Tímto způsobem navržený algoritmus byl natolik robustní, že nebylo třeba filtrovat jakýkoliv šum.



Obr. 7.14 Řada znaků registrační značky postupně po separaci (nahore), po oříznutí okrajů a po normalizaci

Určení, zda se jedná o přední nebo zadní značku, proběhlo na základě přítomnosti samolepek z měření emisí a STK. Pokud byl součet černých pixelů na prostředních řádcích objektu roven téměř nule, byl objekt identifikován jako samolepky a vyřazen z dalšího zpracování. Informace, že se jedná o zadní značku, mohla být zachována.

7.4 Normalizace znaků

Každý separovaný znak prošel dalšími úpravami, aby se zajistila nejvyšší možná podobnost odpovídajících si znaků. To znamená, že byly odstraněny všechny přebytečné bílé okraje a znak byl normalizován na stejné rozměry (Obr. 7.14).

Rozměry se určily dle požadované velikosti výsledného příznakového vektoru. Je zřejmé, že větší rozměry znaků musely způsobovat větší časovou náročnost naučení neuronové sítě i rozpoznání samotných znaků. Ovšem na základě zkušeností nabytých během optimalizace celého rozpoznávacího procesu bylo zjištěno, že přílišná minimalizace rozměrů znaků způsobuje větší chybovost rozpoznání, a to i při takových rozměrech, kdy je znak naprosto zřetelný a člověk nemá nejmenší problém s jeho přečtením. Minimální rozměr pro smysluplné rozpoznávání se lišil podle metody popisu.

7.5 Popis znaků

V této práci byly vyzkoušeny tři způsoby popisu znaků. Vždy byl vyzkoušen popis s různě velkým příznakovým vektorem a hledala se závislost úspěšnosti rozpoznání na velikosti tohoto vektoru.

Nejjednodušším popisem a tomu odpovídajícím příznakovým vektorem je využití hodnot všech pixelů obrazu. Nevýhodou tohoto popisu je vysoká dimenze příznakového vektoru. Například pro obraz 15x15 pixelů má příznakový vektor 225 hodnot. Tím rostou nároky na rozsáhlost neuronové sítě, která bude objekty klasifikovat. Zároveň se prodlužuje doba učení i aktivace UNS.

Vertikální a horizontální projekce černých pixelů složených za sebou se využily jako druhý typ příznakového vektoru. Pro obraz o rozměrech 15x15 pixelů má příznakový vektor velikost dimenze 30. V rámci zjednodušení učení se ukázalo jako výhodné všechny prvky příznakového vektoru vydělit maximální možnou hodnotou obou projekcí.

Třetí způsob popisu, který byl použit a který se osvědčil v práci [4], využívá posuvné čtvercové okno, které postupně procházelo celý obraz po krocích o velikosti poloviny rozměru tohoto okna a pro každou pozici okna byl vypočítán poměr bílých ku celkovému počtu pixelů v tomto okně. Rozměr okna se nastavoval v závislosti na rozměru vstupního obrazu. V této práci bylo aplikováno čtvercové okno o velikosti 2x2, 4x4 a 6x6 na obraz o rozměrech od 10x10 pixelů po 30x30 pixelů.

Použitím výše uvedených popisů se mohla nejvíce projevit kvalita neuronové sítě a její schopnost generalizace, jelikož síti byly předkládány naprosto nedeterministické příznaky. Toto je také hlavní výhoda použití neuronových sítí oproti jiným způsobům

klasifikace. Nevýhodou výše uvedených příznaků bylo to, že nejsou invariantní vůči změně měřítka, rotaci a translaci, proto je pro správnou klasifikaci nutné naprosto precizní provedení předzpracování a segmentace.

Výsledky úspěšnosti rozpoznávání jsou uvedeny v kapitole 8.7.

8 KLASIFIKACE REGISTRAČNÍ ZNAČKY

Automobily, které bylo možné potkat na komunikacích, mohly mít v době tvorby této práce dva typy značek. Rozšířenějším typem byly značky vydávané po roce 2001, ovšem i značky vydávané před tímto rokem se vyskytovaly v nezanedbatelném počtu, a proto bylo potřeba systém optimalizovat pro oba typy registračních značek. Z pohledu rozlišení obou typů je nejdůležitějším patrným znakem pomlčka na šestém místě všech znaků.

Jelikož je jednoznačně dané, že starší typ značek obsahuje na prvních třech pozicích písmena a na zbylých čtyřech číslice, mohlo by být výhodné tyto značky předem detekovat a rozpoznání provést pomocí jiných neuronových sítí rozpoznávající pouze písmena nebo číslice, čímž by se jistě zvýšila pravděpodobnost správného rozpoznání. V následujícím zpracování se ale s oběma typy značek zacházelo shodně.

Z teorie v úvodních kapitolách vyplývá, že kvalita rozpoznání jednotlivých znaků může být ovlivněna především nastavením topologie neuronové sítě, počátečních hodnotách vah, koeficientu učení, maximální přípustné celkové chybě naučené sítě na tréninkových vzorech a na samotné tréninkové množině.

Všechny výpočty učení probíhaly přesně podle vzorců uvedených v teoretické kapitole 4.3 o adaptaci neuronových sítí. Učení probíhalo jako akumulované učení.

Aktivace sítě probíhala podle vzorců uvedených v kapitole 4.4 o aktivaci neuronových sítí. Výstupní neuron, který měl na výstupu nejvyšší hodnotu, určoval třídu, do které byl zařazen rozpoznávaný znak.

8.1 Tréninková a testovací množina

Ukázalo se, že vybrat správnou tréninkovou množinu mělo velmi významný vliv na úspěšnost rozpoznávání znaků. Pokus využít reálně získané znaky byl po testech zamítnut, protože i shodné znaky od sebe byly příliš odlišné (různě silné a natočené, s chybami), proto byla úspěšnost klasifikace neuronové sítě naučené na tyto vzory velmi nízká. Jako tréninková množina byly využity vzory číslic a písmen vyskytujících se v zákoně č. 243/2001 Sb. – o registraci vozidel. Neuronová síť naučená právě na tyto vzory (Obr. 8.1) dosahovala nejlepších výsledků, jelikož vzory přesně a bez zkreslení zobrazovaly daný znak. V sadě znaků podle teorie z kapitoly 0 chybí písmena G, O, Q, W, která se na značkách nevyskytují.

**0123456789 ABCDEF
HI JKLMNPRSTUVXYZ**

Obr. 8.1 Tréninková množina alfanumerických znaků

Testovací množina obsahovala 420 vyříznutých značek pomocí lokalizačního algoritmu (kapitola 6). Až na jednu výjimku bylo na každé 7 znaků, to znamená, že při aktivaci klasifikační umělé neuronové sítě mohlo být v ideálním případě na její vstup přivedeno téměř 2940 možných objektů k rozpoznání. V praxi nakonec tohoto čísla nebylo dosaženo, jelikož především vlivem stínů a velkého znečištění nebylo možné všechny značky naprogramovaným algoritmem automaticky převést do formy vhodné pro přivedení na vstup klasifikátoru. Získané značky byly přední i zadní a obsahovaly různé vlivy z reálného prostředí, některé tedy byly špinavé, natočené, špatně oříznuté. Dokonce několik značek mělo výrazné šrouby, kterými byly přimontovány, ač by všechny tabulky měly být pouze nacvaknuté do plastového držáku.

Pokud je v následujícím textu a grafech zmínka o úspěšnosti rozpoznání registračních značek, je myšlena úspěšnost vypočítaná podle vzorce (8.1).

$$\text{úspěšnost}_{rz} = \frac{\text{počet správně rozpoznaných RZ}}{\text{počet všech rozpoznávaných RZ}} * 100 [\%] \quad (8.1)$$

Druhou v textu se vyskytující úspěšností je úspěšnost rozpoznání jednotlivých znaků, která lépe popisuje kvalitu naučené neuronové sítě, coby klasifikátoru znaků. Vypočítává se dle rovnice (8.2)


$$\text{úspěšnost}_{zn} = \frac{\text{počet správně rozpoznaných znaků}}{\text{počet všech rozpoznávaných znaků}} * 100 [\%] \quad (8.2)$$

Z výpočtu této úspěšnosti jsou vyřazeny registrační značky, které byly v rámci automatického předzpracování (kapitola 7.1) chybně zpracovány.

8.2 Topologie neuronové sítě

Počet vstupních neuronů je dán počtem prvků v příznakovém vektoru, což závisí na zvoleném popisu. Počet výstupních neuronů byl vždy 32, jelikož se na registračních značkách vyskytuje 10 číslic a 22 písmen. V ideálním případě se předpokládalo, že výstupem všech neuronů bude 0, až na jeden, na kterém bude hodnota 1. Pořadí jedničkového neuronu určovalo index v poli znaků, čímž se určil znak odpovídající výsledku rozpoznání.

Jelikož neexistuje spolehlivé pravidlo, které by určilo počet skrytých vrstev a počet neuronů v nich, bylo nutné určit optimální hodnoty experimentálním způsobem. V prostudovaných materiálech týkajících se neuronových sítí nebylo prokázáno, že by počet skrytých vrstev nějakým způsobem kladně ovlivňoval kvalitu rozpoznání znaků, proto byla ve všech případech použita třívrstvá síť, tedy síť s jednou skrytou vrstvou. Vliv počtu neuronů ve skryté vrstvě na úspěšnost rozpoznání znaků je znázorněn na Obr. 8.2.



Obr. 8.2 Závislosti úspěšností rozpoznání jednotlivých znaků na počtu neuronů ve skryté vrstvě

V grafu jsou znázorněny tři průběhy, každý je pro jinak vygenerované počáteční hodnoty vah a prahů v intervalu $-0,1$ do $0,1$. Sítě měly stejně nastavené parametry: koeficient učení $0,02$, strmost přenosové funkce 2 , chyba E_c $0,01$ a příznakový vektor měl 81 prvků. Z vykreslené závislosti je patrné, že nejlepší rozpoznávací úspěšnosti vykazují neuronové sítě s 50 až 90 skrytými neurony. Pokud se zvolilo málo skrytých neuronů, v tomto případě méně než 30 , síť ani nebyla schopná naučit se tréninková data s požadovanou maximální chybou E_c . Naopak nebylo prokázáno, že by mnoho skrytých neuronů mělo za následek přeučení a ztrátu schopnosti generalizace neuronové sítě.


8.3 Počáteční hodnoty vah

Počáteční hodnoty vah všech spojů mezi neurony a prahové hodnoty skrytých a výstupních neuronů byly stanoveny náhodně v intervalu od $-0,1$ do $0,1$. Změna velikosti tohoto intervalu neměla žádný konkrétní vliv na kvalitu rozpoznávání. Náhodná volba hodnot způsobovala mírné rozdíly v kvalitách rozpoznávání. Dvě neuronové sítě se stejnými tréninkovými vzory, stejnou topologií i maximální přípustnou chybou při učení naučené ihned po sobě, se v úspěšnosti rozpoznání testovací množiny jednotlivých znaků lišily v některých případech maximálně o 2 procenta. Jelikož je při návrhu

rozpoznávacího systému důležité hledat zlepšení v řádech desetin procenta, bylo nutné stejně nastavené neuronové sítě učit několikrát a vždy vybrat síť s nejvyšší úspěšností rozpoznání testovacích dat. Počáteční prahová hodnota vstupních neuronů byla nastavena na 0.

8.4 Přenosová funkce

Dalším parametrem, který byl nutný zvolit, byla přenosová funkce neuronů. Lineární funkce se směrnici 1 neboli identita byla zvolena jako přenosová funkce všech vstupních neuronů. Všechny ostatní neurony měly za přenosovou funkci zvolenu hyperbolickou tangentu. Konkrétní průběhy závislosti úspěšnosti na hodnotě strmosti hyperbolické tangenty jsou vidět na Obr. 8.3.



Obr. 8.3 Příklad závislosti úspěšnosti rozpoznání jednotlivých znaků na hodnotě strmosti přenosové funkce hyperbolické tangenty


Všechny parametry sítí byly stejné: topologie 81-80-32, koeficient učení 0.03, interval počátečních hodnot vah a prahů od -0,1 do 0,1. Lišily se pouze uložené počáteční hodnoty vah pro každý průběh. Protože nebyla nalezena žádná závislost úspěšnosti rozpoznávání na hodnotě strmosti ani pro jednu stejně nastavenou síť s jinými počátečními vahami, nemělo význam hledat tuto závislost u topologicky rozdílných sítí. Podle průběhů modré, červené a světlemodré závislosti by se mohlo zdát, že se snižující se strmostí přenosové funkce stoupá úspěšnost rozpoznávání, stejně jako určil autor v [9]. Tuto domněnku ale vyvrací zelený průběh, který jde přesně opačně. Optimální hodnota vzhledem k nejlepšímu výsledku klasifikace byla vždy jiná pro různé nastavení sítě a pro různé počáteční hodnoty vah a prahů.

8.5 Koeficient učení

V rámci učení sítě bylo dopředu nutné nastavit dva parametry. Prvním byl koeficient učení, jehož hodnota se po experimentálním zkoušení zastavila na čísle 0,02, ale optimální hodnota pro nejlepší rozpoznávání se pro každou konkrétní síť lišila. Nepodařilo se tedy prokázat závislost kvality rozpoznávání na velikosti koeficientu učení.

8.6 Maximální celková chyba naučené sítě

Druhým parametrem byla maximální celková chyba naučené sítě na tréninkových vzorech, jejíž hodnota byla určena z grafické závislosti na Obr. 8.4.




Obr. 8.4 Závislost úspěšnosti rozpoznání celých značek (modrá) a jednotlivých znaků (zelená) na velikosti E_c naučené sítě

Nejlépeších výsledků bylo dosahováno při chybě E_c kolem 0,01. Další snižování chyby již nemělo na úspěšnosti rozpoznání žádný vliv ani při snížení chyby pod $3 \cdot 10^{-5}$. Následkem bylo pouze prodlužování doby učení neuronové sítě, která měla v tomto případě 81 vstupních neuronů, 50 skrytých a 32 výstupních, strmost přenosové funkce 2, koeficient učení 0.02 a jako popis bylo využito plovoucí okno.

Naopak zvyšování chyby přes určitou hodnotu mělo za následek nenaučení sítě na všechny tréninkové vzory. Tyto mezní hodnoty chyb jsou zobrazeny na Obr. 8.5. Zkoumání vlivu E_c na úspěšnost rozpoznání již nemělo vypovídající hodnotu, pokud chyba E_c překročila právě mezní hodnotu.

Zobrazená závislost je pouze příkladem konkrétní nastavené neuronové sítě a konkrétních uložených počátečních hodnot vah a prahů. Tato síť měla topologii 81-74-32. Z grafu je patrné, že síť byla schopná při jakékoliv topologii rozpoznat všechny tréninkové vzory při chybě E_c menší než 1,7.



Obr. 8.5 Vliv počtu neuronů ve skryté vrstvě na velikost chyby E_c , při které je síť naučená na všechny tréninkové vzory

8.7 Výsledky klasifikace

V této kapitole je sledován vliv různých parametrů na úspěšnost rozpoznávání znaků a značek. Jedná se o vliv počasí, rozlišení snímku a způsobu popisu. Vlivy nastavení neuronové sítě byly zkoumány v kapitolách 8.1 až 8.6.

Úspěšnost rozpoznání znaků z registračních značek v závislosti na způsobu popisu a na velikosti normalizovaného znaku je zobrazena v Tab. 8.1. Rozpoznávaných znaků bylo 2840. Vzhledem k důsledku, že náhodně nastavené počáteční hodnoty prahů ovlivňují

úspěšnost rozpoznávání, lze v tabulce vidět vždy 3 měření s různou úspěšností rozpoznání při stejně nastavených parametrech sítě.

Tab. 8.1 Procentuální úspěšnost rozpoznávání jednotlivých znaků pomocí UNS

Popis	Velikost normalizovaného znaku [px]	Úspěšnost rozpoznání znaků [%]			
		1. měření	2. měření	3. měření	
pixely	10x10	91,0211	92,2183	91,4789	
	15x15	96,2324	96,5141	96,5493	
	20x20	95,8803	95,3873	96,5141	
	25x25	97,6056	96,9366	97,1831	
	30x30	96,7958	97,8169	97,3239	
	35x35	97,3944	96,6901	97,2183	
projekce	10x10	56,2676	56,4789	57,3239	
	15x15	65,3521	67,1831	67,6408	
	20x20	66,4085	66,2676	66,2324	
	25x25	60,5986	62,0423	63,9789	
	30x30	60,4225	60,8803	60,4930	
	35x35	68,4859	66,3028	65,1056	
plovoucí okno – velikost [px]	2x2	10x10	96,3732	96,1620	95,7394
	4x4	16x16	95,5634	96,3380	95,8451
		20x20	97,8873	98,0282	98,2394
		24x24	97,6761	97,9225	97,6056
	5x5	30x30	97,2183	97,3239	96,9366
	6x6	24x24	96,3028	96,9014	96,4789

Nejlepším z vyzkoušených příznaků pro rozpoznávání registračních značek bylo plovoucí okno. Úspěšnost rozpoznávání s jeho využitím se pohybovala velmi vysoko, v některých případech dosahovala až 98,45 %. Druhým nejlepším příznakem bylo využití jednotlivých pixelů. Úspěšnost rozpoznání s tímto příznakem se pohybovala kolem 95 % a nejlepším výsledkem bylo 97,8 %. Jako téměř nepoužitelný příznak bylo využití obou projekcí. Úspěšnost v žádném případě nepřesáhla 70 %.

Vliv počtu neuronů ve skryté vrstvě měl na výslednou úspěšnost rozpoznání pouze malý vliv a konkrétní závislost nebyla nalezena. Různá úspěšnost rozpoznání při různém počtu skrytých neuronů by mohla být přisouzena spíše náhodně nastavovaným vahám.

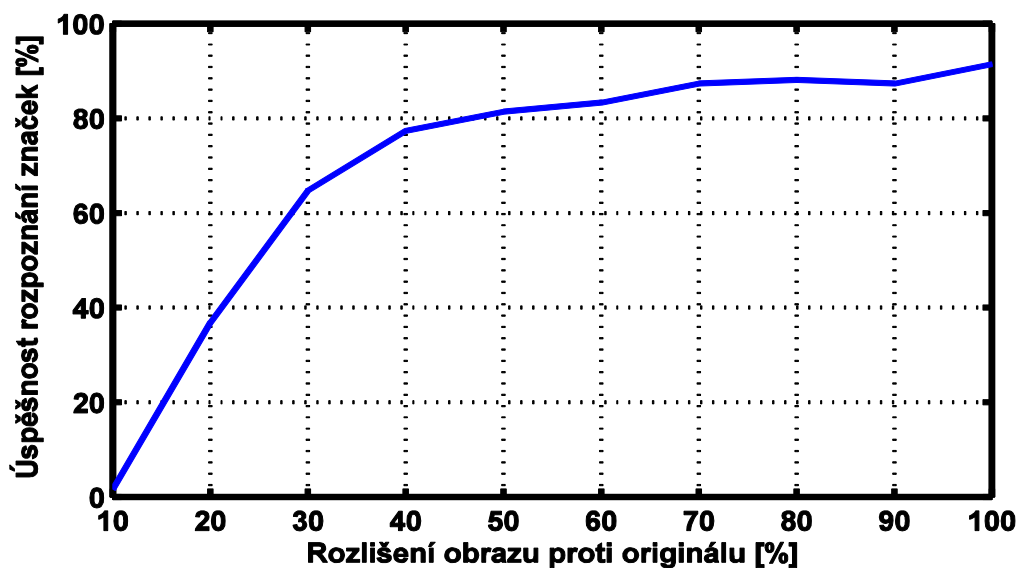
Cílem bylo vybrat naprosto nejlepší síť, která mohla být vygenerována a uložena. Z tabulky Tab. 8.1 je evidentní, že nejlepším popisem je posuvné okno o velikosti 4x4 pixely aplikované na znak normalizovaný na rozměr 20x20 pixelů. Neuronová síť využívající tento popis dosahuje nejlepších výsledků, pokud obsahuje přibližně 50 až 90 neuronů ve skryté vrstvě. Nelze ale přesně určit, jaký počet je nejvhodnější, jelikož se ideální počet skrytých neuronů mění v závislosti na náhodné volbě vah a prahů. Proto bylo nutné vždy vygenerované počáteční hodnoty vah a prahů uložit a vyzkoušet všechny hodnoty počtu skrytých neuronů z intervalu 50 až 90.

Následně proběhlo vyhodnocení, při kterém byla vybrána topologie s nejlepší úspěšností rozpoznání jednotlivých znaků. Na této topologii a se stále uloženými počátečními hodnotami vah bylo vyzkoušeno učení s různými velikostmi koeficientu učení v intervalu 1 až 40 tisícín. Tímto způsobem se vybrala síť s nejlepší klasifikační schopností, která dosahovala úspěšnosti v konkrétním nejlepším případě 98,70 %. Vybrání takto nejlepší klasifikační sítě byl časově velmi náročný proces trvající až několik hodin. S touto úspěšností rozpoznávání jednotlivých znaků bylo správně rozpoznáno 91,43 % značek.

V ideálním případě by bylo vhodné vyzkoušet všechny kombinace počtu skrytých neuronů, koeficientu učení a strmosti přenosové funkce pro konkrétní vygenerované počáteční hodnoty vah a prahů a následně vybrat kombinaci s nejlepšími výsledky. Dostupným výpočetním výkonem nebylo možné z výpočetních časových důvodů tuto kombinaci hledat.

Rozpoznávací algoritmus dosahoval nejlepších výsledků, pokud byly rozpoznávané značky vyfoceny v oblačném počasí, při kterém je osvětlení registrační značky rovnoměrné. Naopak snímky pořízené za slunečných podmínek obsahující výrazné stíny nebo odlesky byly často špatně zpracovány, což vedlo i k větší chybovosti při klasifikaci.

Rozlišení vyříznutých registračních značek se většinou pohybovalo kolem hodnot 500 pixelů na šířku a 120 pixelů na výšku. Umělým snižováním rozlišení lze simulovat vzdálenější umístění registrační značky od snímacího zařízení nebo jeho nižší snímací rozlišení. Vliv snižování rozlišení na úspěšnost rozpoznání značek je zachycen na Obr. 8.6.



Obr. 8.6 Vliv rozlišení obrazu s registrační značkou na kvalitu rozpoznání

8.8 Heuristiky

Zkoumáním špatně klasifikovaných znaků bylo zjištěno, že při rozpoznávání měly neuronové sítě největší problém s rozlišováním některých konkrétních znaků. Ve většině případů šlo o chybně klasifikovaný znak B, který byl klasifikován jako číslo 8. Chybovost se zvětšovala při větší deformaci vlivem perspektivy.

Podle informací z kapitoly 0 lze odhadnout, že mnoho písmen B bude na druhé pozici v sadě znaků registrační značky. Proto byl k celkovému souboru metod přidán algoritmus, který zjišťuje jaký znak je klasifikován na druhé pozici a v případě, že je tam nalezeno číslo 8, je přepsáno na znak B.

Pokud bylo zjištěno atypické uspořádání sady znaků, například počet znaků byl jiný než 7, byl algoritmus zablokován.

Využitím heuristik byla zvýšena úspěšnost rozpoznání jednotlivých znaků na 98,98 % a rozpoznání všech registračních značek na 93,10 %.

9 NAVRŽENÝ PROGRAM

Navržený program byl napsán jako skript v programu MATLAB R2012b od společnosti MathWorks. V rámci programu byly využívány funkce speciálně napsané i funkce implementované přímo od výrobce. Navržený skript typu m-file, kterým se rozpoznávání aktivuje, se nazývá „licencePlate.m“. Kód je napsaný s ohledem na výzkumné účely, není proto odolný vůči nesprávnému uživatelskému zacházení. Skript přesně kopíruje posloupnost algoritmů a metod zmíněných v kapitolách 6 až 8 a lze jej pomyslně rozdělit do čtyř částí.


V první části dochází k počáteční inicializaci hodnot různých parametrů, například nastavení rozsahu stupňů, pro které bude vypočtena korekce naklonění registrační značky, nastavení parametrů pro učení neuronové sítě, nastavení rozměru normalizovaného znaku a podobně. Dále dochází k načtení názvů souborů, které budou rozpoznávány, a k načtení databáze správných textových řetězců testovací množiny.

Ve druhé části je spuštěna napsaná funkce „licencePlate_adaptation.m“, která na základě hodnot nastavených v inicializaci zvolí topologii neuronové sítě a dle určených parametrů sítí naučí na zvolenou tréninkovou množinu. Při učení lze zvolit koeficient učení, strmost přenosové funkce a celkovou chybu, při které je učení ukončeno. Učení je automaticky ukončeno po 30 000 adaptačních cyklech.

Ve třetí části jsou zapsány algoritmy zajišťující lokalizaci, předzpracování, segmentaci a popis značky. Algoritmy a metody popsané v kapitole 6 a 7 jsou v tomto pořadí také implementovány v kódu a obrázky v těchto kapitolách jsou mezivýsledky zpracování konkrétní registrační značky v rámci tohoto skriptu.

Čtvrtá část se spolu se třetí částí cyklicky opakuje pro každou rozpoznávanou registrační značku. Zde dochází k aktivaci naučené neuronové sítě, určení třídy, do které patří rozpoznávaný objekt, využití heuristik a k vyhodnocení správného rozpoznání celé registrační značky na základě porovnání s databází správných hodnot registračních značek. Dále je vypočtena průběžná úspěšnost rozpoznávání značek i jednotlivých znaků, která je vypisována do konzole. Každý výsledek rozpoznání byl také graficky zobrazen v okně výsledků, kde je vidět vstupní snímek se zvýrazněnou značkou, segmentovaný snímek, originální obraz registrační značky a segmentovaný obraz s registrační značkou. Výsledný textový řetězec je zde barevně zvýrazněn. Náhled okna výsledků je na Obr. 9.1. Mezi jednotlivými snímky lze přecházet stiskem libovolné klávesy a rozpoznávání je možno ukončit stiskem klávesy Esc.

V rámci příloh této práce byl program duplikován do dvou adresářů. V jednom lze sítí pouze učit a ověřovat její schopnosti na testovací množině. Ve druhém lze naopak lokalizovat a rozpoznávat značky, které si do příslušných adresářů nakopíruje uživatel.



Obr. 9.1 Náhled grafického znázornění výsledku rozpoznání registrační značky

10 ZÁVĚR

10.1 Zhodnocení

Cílem této bakalářské práce bylo navrhnout systém, který lokalizuje registrační značku v obraze a využije vhodně vybraný popis, na jehož základě pomocí správně nastavené neuronové sítě rozpozná všechny znaky z vyříznuté registrační značky.

V kapitolách 0 až 4 jsem zpracoval obecnou teorii týkající se způsobu tvorby státní poznávací značky, řetězce zpracování obrazu a umělých neuronových sítí s typem učení backpropagation. U každého tématu byly vybrány základní a nejdůležitější body, na kterých je postaven daný obor a z kterých byly čerpány informace vhodné pro řešení všech bodů zadání této práce.

Aby bylo možné provést navrhnutí všech metod pro rozpoznávání registračních značek, provedl jsem rešerši prací zabývajících se rozpoznáváním SPZ. Tato rešerše je zpracována v kapitole 5 a v rámci jejího textu bylo rozebráno šest prací, ze kterých je patrné, že samotné rozpoznávání registračních značek lze řešit velmi rozmanitě. Z jejich výsledků nebylo možné určit, zda je nějaký způsob řešení rozpoznávání lepší než jiný.

V kapitolách 6 až 8 jsem navrhl komplet metod sloužící k lokalizaci a rozpoznání registračních značek. Rozpoznávání bylo omezeno na české jednořádkové značky staršího i nového formátu. Fotografie automobilů s těmito značkami byly pořízeny v reálných podmínkách v exteriéru.

V první fázi rozpoznávání bylo nutné lokalizovat značku s tabulkou registrační značky v obraze. Proto jsem navrhl algoritmus lokalizace, který využívá základní postupy počítačového zpracování obrazu, jako je změna kontrastu, prahování, detekce hran, indexace oblastí a další. Takto bylo správně nalezeno 85,4 % registračních značek z 527 snímků.

V dalším kroku byl barevný snímek s registrační značkou převeden na černobílý pomocí prahovací metody Otsu. S využitím detekce hran bylo vyrovnáno nesprávné natočení značky a pomocí horizontálních projekcí byly nalezeny a odříznuty přebývající okraje nad a pod samotnými znaky. Segmentací prahováním byly odděleny samotné znaky od pozadí a separovány s využitím vertikálních projekcí. Od odděleného znaku byly odstraněny všechny bílé okraje a následně byl znak normalizován na velikost 20x20 pixelů, případně i jinou, pokud to vyžadoval použitý popis. Po vhodně zvoleném popisu byl vzniklý příznakový vektor přiveden na vstup umělé neuronové sítě, která znak přiřadila do určité třídy, čímž určila konkrétní hodnotu znaku.

Nejlépeších výsledků dosahovaly metody s využitím popisu posuvného okna. Tímto popisem byl získán příznakový vektor s velikostí dimenze 81. Tento vektor byl přiveden na vstup třívrstvé neuronové sítě s 81 vstupními, 80 skrytými a 32 výstupními neurony. Při správně naučené neuronové síti a s využitím heuristik bylo dosaženo 98,98 % rozpoznání z 2840 testovacích znaků. Pokud se tato úspěšnost převede na správné

rozpoznání celých sad znaků, bylo takto korektně rozpoznáno 93,10 % registračních značek z celkového počtu 420.

Během zkoumání vlivu parametrů topologie a učení neuronové sítě na úspěšnost rozpoznávání nebyla zjištěna žádná konkrétní závislost úspěšnosti na počtu neuronů ve skryté vrstvě, hodnotě koeficientu učení a na hodnotě strmosti přenosové funkce hyperbolické tangenty. U všech těchto parametrů bylo nutné zjišťovat optimální hodnoty experimentálně. Naopak byla zjištěna závislost hodnoty chyby E_c ve smyslu čím menší chyba, tím lepší úspěšnost rozpoznání.

V deváté kapitole jsem rámcově popsal mnou navržený program, který využívá uvedené metody s cílem dosáhnout nejlepší možnou úspěšnost rozpoznávání.

10.2 Možnost dalšího vývoje

Vzhledem k tomu, že lokalizace v této práci byla pouze prostředkem, jak se dostat k reálným datům, skrývá v sobě lokalizační algoritmus jisté rezervy. Pochopitelně existují sofistikovanější způsoby, které umožňují značku vyhledat s větší úspěšností. Bylo by vhodné vyzkoušet metody vyhledávající značku na základě hustoty vertikálních hran v obrazu nebo metody lokalizující registrační značku pomocí horizontálních hran značky a Houghovy transformace.

Protože navržený soubor metod sloužící k rozpoznávání registračních značek není univerzální a odolný vůči možným zkreslením z reálného prostředí, bylo by vhodné tento soubor doplnit ještě dalšími vylepšeními. Jedním z nich by mělo být doplnění korekce zkreslení lokalizované značky, které bylo způsobeno perspektivou, čímž by se celý rozpoznávací algoritmus stal ještě univerzálnějším.

V teorii o způsobu popisu registračních značek bylo řečeno, že možných popisů je velmi mnoho, proto by bylo vhodné zjistit, zda některé nevyzkoušené, případně jinak zvolené vyzkoušené popisy nenapomáhají dosažení lepších výsledků rozpoznání.

Jelikož vliv topologie umělých neuronových sítí a parametrů zvolených při učení na kvalitu rozpoznání je opravdu veliký, bude nutné podrobněji proměřit vlivy těchto hodnot na celkovou kvalitu. Ale aby bylo možné jednoduše porovnávat kvality, bude nutné z návrhu vyřadit náhodný prvek, kterým je náhodné volení počátečních hodnot vah, a určit jednotný algoritmus, pomocí kterého budou počáteční hodnoty vždy stejné pro stejně nastavené neuronové sítě.

Pro ověření univerzálnosti navržených metod by mohlo být zajímavé vyzkoušet kvalitu rozpoznání pro značky, které budou záměrně křivé, zastíněné, malé, velké nebo špinavé. S tím by bylo vhodné doplnit metodu pro určení pravděpodobnosti, s jakou byla značka rozpoznána. Tato pravděpodobnost by se mohla určit například z rozkolísanosti hodnot jednotlivých výstupních neuronů po aktivaci.

LITERATURA

- [1] ADAMEC, Václav. *Zpracování a rozpoznání obrazu*. Olomouc, 2011. Bakalářská práce. Přírodovědecká fakulta univerzity Palackého. Vedoucí práce Mgr. Eduard Bartl, Ph.D.
- [2] BISKUP, Roman. *Možnosti neuronových sítí*. Praha, 2009. Disertační práce. Česká zemědělská univerzita v Praze. Vedoucí práce prof. RNDr. Anna Čermáková, CSc.
- [3] ČERNÝ, Matěj. *Rozpoznávání registračních značek motorových vozidel*. Pardubice, 2010. Diplomová práce. Univerzita Pardubice. Vedoucí práce Ing. Martin Dobrovolný, Ph.D.
- [4] Česká republika. Zákon č. 243/2001 Sb. - o registraci vozidel. In: 2001.
- [5] DOBROVOLNÝ, Martin. *Rychlý algoritmus rozpoznání registračních značek vozidel*. 2009, čtvrtý ročník, č. 3.
- [6] 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.
- [7] 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.
- [8] HORÁK, Karel. *Zpracování vícerozměrných signálů: Computer Vision* [online]. [cit. 2013-12-27]. Dostupné z: http://midas.uamt.feec.vutbr.cz/ZVS/zvs_cz.php
- [9] 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.
- [10] PIRNER, Ivan. *Předzpracování pro segmentaci obrazových dat v lékařství*. Plzeň, 2010. Diplomová práce. Západočeská univerzita v Plzni. Vedoucí práce Ing. Miloš Železný, Ph.D.
- [11] SMÉKAL, 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.
- [12] ŠÍMA, Jiří. *Teoretické otázky neuronových sítí*. Vyd. 1. Praha: MATFYZ press, 1996, 390 s. ISBN 80-858-6318-9
- [13] VALA, Tomáš. *Rozpoznávání SPZ z jednoho snímku*. Uherské Hradiště, 2006. Diplomová práce. Univerzita Karlova v Praze. Vedoucí práce RNDr. Jana Štanclová.

SEZNAM PŘÍLOH

Příloha 1.: DVD se zdrojovými kódy a databází fotografií