

# Detekce a rozpoznání registrační značky vozidla pro analýzu dopravy

Bc. Tereza Černá\*



## Abstrakt

Cílem této práce je detekce registračních značek vozidel. Základním přístupem pro detekci je využití kaskádového klasifikátoru. Práce je rozdělena do tří hlavních kapitol – popis datové sady, detekce značek a diskuze výsledků. Datová sada byla pořízena na území města Brna přímo pro účely této práce. Nasbíraná data byla použita pro přípravu pozitivních a negativních vzorků pro trénování detektora registračních značek a klasifikátoru znaků. V práci je popsáno trénování kaskádového klasifikátoru pro detekci registračních značek. Úspěšnost detekce značek byla vyhodnocena na dvou datových sadách s výsledky 100 % a 98.47 %. Aktuálně se autorka zabývá rozpoznáním znaků a sestavením registrační značky.

**Klíčová slova:** Detekce registračních značek vozidel — Klasifikace znaků — Kaskádový klasifikátor — MSER

**Přiložené materiály:** Zdrojové kódy

\*[xcerna01@stud.fit.vutbr.cz](mailto:xcerna01@stud.fit.vutbr.cz), [xcernatereza@gmail.com](mailto:xcernatereza@gmail.com), Faculty of Information Technology, Brno University of Technology

## 1. Úvod

Detekce registrační značky vozidla a její rozpoznání je klíčovou technikou v mnoha aplikacích souvisejících s analýzou dopravy jako je odcizení vozidel, sledování silničního provozu, kontrola rychlosti vozidel aj.

Proces rozpoznání registračních značek se skládá ze dvou hlavních fází: 1) hledání registrační značky auta a 2) rozpoznání znaků značky. V obou fázích lze zvolit mnoho přístupů. Metody detekce registračních značek jsou postaveny na porovnávání výřezů původního obrazu se šablonami [1], detekci MSER regionů [2], detekci hran [3] za použití vlnkové transformace [4] nebo fuzzy logiky [5], kombinaci houghovy transformace a analýzy kontur [6]. Jiné metody jsou založeny na komponentách a konstruují podmíněná náhodná pole [7] nebo extrahují příznaky SIFT [8].

Metody rozpoznání znaků jsou často založeny na extrakci znaků a jejich porovnání s předdefinovanými šablonami [9]. Další metody jsou založeny na derivacích jádra [10], trénování SVM a jiných detektorů [11] nebo na neuronových sítích [12].

Tato práce pojednává o použití kaskádového klasifikátoru pro vytvoření detektoru registračních značek. Velká část práce se věnována přípravě dat pro trénování detektoru registračních značek a klasifikátoru znaků. Úspěšnost detektoru registračních značek byla vyhodnocena na dvou datových sadách s výsledky 100 % a 98.47 %.

## 2. Kaskádový klasifikátor

Kaskádový klasifikátor slouží pro robustní a rychlou detekci objektů v obraze. Tento přístup publikovali Viola a Jones [13] na příkladu detekce obličeje, ale lze jej použít i pro jiné objekty. Použití kaskádového klasifikátoru poskytuje velkou snímkovou rychlosť.

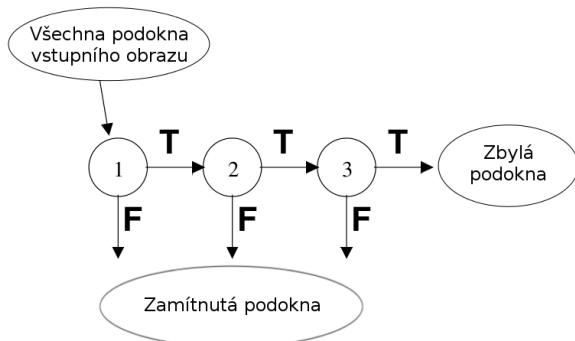
Je zde použita reprezentace obrazu zvaná integrální obraz, která umožňuje velmi rychlé vyhodnocení funkce. Systém detekce pracuje se sadou Haarových obdélníkových příznaků (viz obr. 1).



Obrázek 1. Ukázka haarových příznaků

Klasifikátor je zkonstruován výběrem malého počtu důležitých rysů algoritmu AdaBoost. V rámci zajištění rychlé klasifikace musí proces učení vyloučit většinu možných objektů a zaměřit se na malý soubor zásadních rysů.

Celková podoba procesu detekce je konstrukce rozhodovacího stromu, který je nazýván kaskáda (viz obr. 2). Série klasifikátorů postupně zpracovává všechna podokna vstupního obrazu. Iniciální klasifikátor eliminuje velký počet negativních podoken s velmi krátkou dobou zpracování. Následující klasifikátor odstraňuje další negativní podokna, ale vyžaduje delší zpracování. Po několika stupních kaskády je počet podoken radikálně snížen. Kaskádou projdou pouze pozitivní podokna.

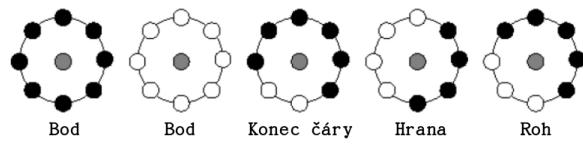


Obrázek 2. Schematický popis kaskádového klasifikátoru

Kaskádový klasifikátor byl poprvé použit pro detekci obličejů v obraze. Výsledný klasifikátor pracoval s úspěšností 93.9 %.

Tento klasifikátor umí pracovat nejen s Haarovými příznaky, ale také s příznaky LBP, HOG a dalšími. LBP příznaky neboli příznaky místních binárních vzorů jsou získány pro všechny pixely v obraze. Pro každý pixel je spočítán váhový součet okolních pixelů po prahování. Příznaky jsou zobrazeny na obrázku 3. LBP příznaky

byly použity v této práci pro vytvoření detektoru registračních značek.



Obrázek 3. Ukázka LBP příznaků

## 3. Datová sada

### 3.1 Pořízení datové sady

Pro dobrý výsledek detekčních úloh je zásadní pořídit velkou datovou sadu. Čím větší datová sada, tím je výsledný detektor robustnější. Datová sada použitá v této práci byla získána v terénu na území města Brna. Kamera byla umístěna:

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

Bylo natočeno 25 použitelných videí, z nichž 23 bylo použito pro trénování detektoru a zbylé 2 videa byla vyčleněna pro vyhodnocení úspěšnosti. Videa byla natočena v délce od 30 s do 200 s. Průměrná délka jednoho videa byla 1 min 50 s.

Jelikož by byla práce se všemi snímkami nasbíraných videí zbytečná, tak z nich byl vyříznut každý 25 snímek, který pak byl na vstupu učení detektoru. Ze získaných snímků byly vymazány ty, na kterých se nevyskytovalo žádné vozidlo. Tím došlo k omezení velmi shodných snímků se stejnými informacemi.

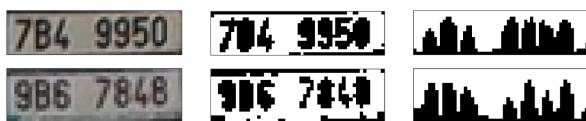
### 3.2 Datová sada pro detekci registračních značek

Pro vytvoření detektoru registračních značek byl zvolen kaskádový klasifikátor knihovny OpenCV. Tento detektor vyžaduje pro trénování klasifikátoru velkou sadu obrázků pozitivních a negativních případů a k nim odpovídající seznamy s cestami k obrázkům. Pro přípravu dat vznikly v rámci této práce dvě aplikace:

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

Jednoduchý detektor je založen na detekci MSER regionů [14] ve vstupním snímku. Pro každý region je zkontrolována jeho velikost, poměr stran a úhel

sklonu vzhledem ke spodnímu okraji snímku, čímž dojde k omezení množství regionů. Nad zbylými regiony je provedena binární analýza pixelů, při které jsou sečteny počty černých pixelů ve všech sloupcích (viz obrázek 4). V místech výskytu písmen jdou vidět shluky černých pixelů. V ideálním případě by měla analýza zobrazit 7 shluků. Jelikož může být kvalita obrazu horší, pak je výřez prohlášen za registrační značku, pokud obsahuje alespoň 3 tyto shluky.



Obrázek 4. Ukázka analýzy pixelů

Mezi získanými výřezy se nachází registrační značky vozidel, ale také obrázky se šumem. Pro odstranění těchto mylných značek je potřeba, aby uživatel ručně prošel adresář s obrázky a smazal ty, které nepředstavují registrační značky aut.

Následně jsou již připraveny textové soubory pro trénování klasifikátoru. Je vytvořen adresář obsahující pozitivní vzorky, do něhož jsou uloženy původní obrázky z dopravy, a soubor se seznamem pozitivních vzorků v podobě:

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

kde proměnné x, y, šířka a výška určují přesnou pozici registrační značky v obraze.

Současně je vytvořen soubor se seznamem cest k negativním vzorkům a adresář, do něhož jsou uloženy obrázky s celou scénou, v nichž jsou na nalezené registrační značky začerněny. Zde je opět nutný zásah uživatele, který musí projít adresář s negativními snímkami a začernit zbývající viditelné značky, které by úspěšnost klasifikátoru výrazně zhoršily.

### 3.3 Datová sada pro rozpoznání znaků

Před začátkem trénování detektorů znaků bylo třeba opět zajistit pozitivní a negativní sadu znaků. Pro tento účel vznikla aplikace **extract-letters**.

Vstupem této aplikace je adresář obsahující obrázky s vyříznutými registračními značkami. Značky jsou postupně ukazovány uživateli, který napíše na klávesnici znaky z registrační značky. Uživatel dále nakliká myší středy znaků. Aplikace poté vyřízne jednotlivé znaky a uloží je do obrázků náležejícím danému znaku. Vznikají tak sady pozitivních vzorků všech znaků (viz obrázek 5). Současně vzniká i negativní datová sada. V aktuální zobrazené registrační značce dojde k začernění daného znaku, např. A. Tato značka je poté uložena do negativní sady náležející znaku A. Pokud se ve značce některý ze znaků nevyskytuje, pak je do

jeho negativní sady uložena celá značka beze změny. Ukázka negativní sady znaku 1 je vidět na obrázku 6.



Obrázek 5. Ukázka vyextrahovaných znaků.



Obrázek 6. Ukázka negativní sady znaku 1.

Kvalita některých znaků je velmi malá, proto byla vytvořena aplikace **sort-to-categories**, která roztrídí znaky z obrázku 5 do tří kategorií: dobré, střední a špatné. Rozdíl mezi kategoriemi je zobrazen na obrázku 7. Pro trénování budou použity nejdříve znaky z kategorie dobré. Zbylé kategorie jsou nachystány pro experimenty.



Obrázek 7. Ukázka roztríděných znaků dle kvality. Vlevo kategorie "dobré", vpravo kategorie "špatné".

V tabulce 1 jsou zobrazeny počty vyextrahovaných znaků z registračních značek testovací datové sady. Na území města Brna se nepodařilo nasbírat dostatečný počet všech písmen abecedy. Pro tato písmena nebude možné natrénovat kvalitní klasifikátor, a proto nejsou ani uvedena v tabulce.

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

Tabulka 1. Počty vyextrahovaných znaků

## 4. Detekce registračních značek

### 4.1 Trénování detektoru registračních značek

Pro detekci registračních značek byl zvolen kaskádový klasifikátor knihovny OpenCV. Použity byly dvě základní funkce `opencv_createsamples` a `opencv_traincascade` [15].

Pro trénování byly použity obrázky dopravy, v nichž je registrační značka rovnoběžná se spodní hranou obrázku, případně s mírným sklonem. V tabulce 2 jsou uvedeny počty použitých snímků. Na začátku trénování byly obrázky negativní datové sady rozsekány na menší podokna, která se použila pro samotné trénování. Pro trénování byla použita datová sada popsána v kapitole 3.2.

Počet snímků pozitivní sady	2745
Počet snímků negativní sady	236

**Tabulka 2.** Počty vstupních souborů

První funkce `opencv_createsamples` vytvořila pozitivní vzorky z jednoho obrázku či kolekce obrázků. Funkce byla spuštěna s následujícími parametry:

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

Samotné trénování kaskády proběhlo spuštěním funkce `opencv_traincascade`. Trénování proběhlo v deseti iteracích, do každé iterace šlo 1000 pozitivních a 1000 negativních vzorků. Pro trénování byly použity příznaky LBP. Použitý příkaz pro spuštění:

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

Výsledný detektor byl natrenován na minimální velikost registrační značky, ve které zůstanou informace o jejích znacích, a to  $60 \times 16$  pixelů.

### 4.2 Aplikace vyhodnocení detektoru

Pro vyhodnocení úspěšnosti bylo nejprve potřeba vytvořit soubor s anotacemi, kde se vyskytují registrační značky ve snímcích z dopravy. Pro tento účel vznikla aplikace `create-annotation`. Postupně se ukazují obrázky, ve kterých uživatel označí levý horní roh a pravý dolní roh textu na značce. Získané informace se vypisují na standardní výstup terminálu, které lze přesměrovat do souboru. Výstup aplikace je v podobě:

cesta-k-obrázku N x1 y1 x2 y2 ...,  
kde N je počet RZ v obrázku, x1 a y1 udávají souřadnice levého horního rohu znaků v RZ a x2 a y2 udávají souřadnice pravého dolního rohu.

Samotné vyhodnocení úspěšnosti provádí aplikace `automatic-evaluation`. Jejím vstupem je soubor s anotacemi a natrenovaný detektor. Aplikace porovnává, zda anotace registrační značky odpovídá některému výřezu nalezenému detektorem. V průběhu zpracování se počítá celkové množství registračních značek v anotovaném souboru a počet správně nadetekovaných značek. Tyto hodnoty jsou vypsány na standardní výstup terminálů společně s procentuálním vyjádřením úspěšnosti.

## 5. Výsledky detektoru registračních značek

Výstup detektoru obsahuje většinu registračních značek, ale také spoustu chybě nalezených výřezů (FP - false positives). FP není třeba řešit, protože na získané výřezy vstupního snímku bude puštěn klasifikátor znaků a ten tyto výřezy zamítne.

Vyhodnocení úspěšnosti detektoru probíhalo na dvou datových sadách, které byly pořízeny na různých místech a jejichž registrační značky byly čitelné. Datové sady se lišily i v dalších faktorech:

- Dataset A – kamera snímal zadní část aut z nadhledu pod úhlem  $50^\circ$  k vozovce,
- Dataset B – kamera snímal přední část aut, byla umístěna na jejich úrovni pod úhlem  $65^\circ$  k vozovce.

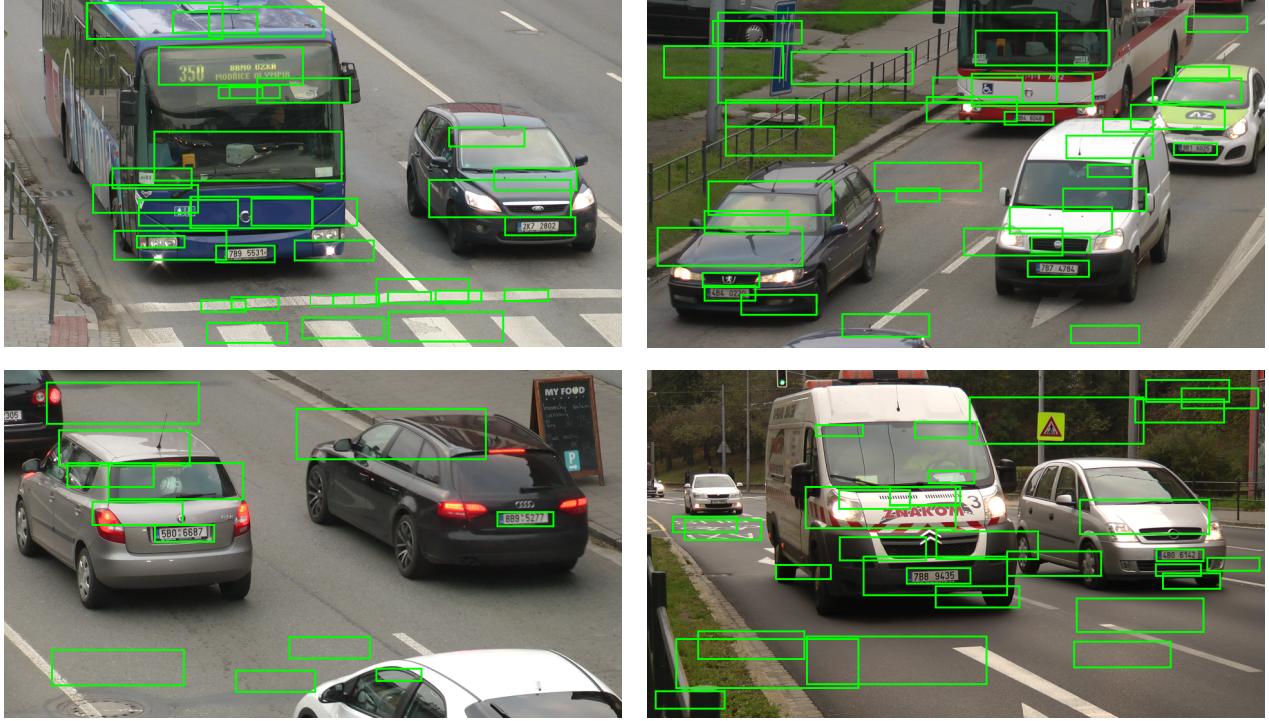
Výsledky detektoru jsou zobrazeny v tabulce 3. Výsledný detektor umí částečně najít registrační značky, které jsou z části skryté za jiným autem, ale tyto částečné detekce nebyly hodnoceny.

Na obrázku 8 jsou zobrazeny výstupy detekce registračních značek. V zelených rámečcích jsou zobrazeny plochy, které detektor považuje za registrační značky.

	Dataset A	Dataset B
Počet snímků	75	103
Počet RZ	96	131
Počet nalezených RZ	96	129
Počet nenalezených RZ	0	2
Úspěšnost	100 %	98.47 %

**Tabulka 3.** Výsledky detektoru registračních značek

Srovnání výsledků detektoru vytvořeného v rámci této práce s přístupy některých metod zmíněných v úvodu práce je znázorněno v tabulce 4.



**Obrázek 8.** Ukázka výstupu detektoru registračních značek.

Metoda	Úspěšnost
Detekce použitím NN [12]	98.51 %
Kaskádový klasifikátor	98.47 %
Konstrukce CRF [7]	97.1 %
Porovnání se šablonami [1]	96.6 %
Detekce použitím MSER [2]	83.3 %

**Tabulka 4.** Srovnání výsledků detektoru s dalšími přístupy.

## 6. Závěr

Cílem této práce bylo detektovat registrační značky ve vstupním obrazu ze silniční dopravy. V kapitole 2 byl představen kaskádový klasifikátor. Kapitola 3 se zabývala pořízením datové sady a zpracováním vstupních snímků pro trénink detektoru registračních značek a klasifikaci znaků. Následující kapitola hovořila o nácviku detektoru registračních značek a jeho hodnocení. Předposlední kapitola shrnuje dosažené výsledky.

Hlavním přístupem této práce bylo využití kaskádového klasifikátoru. Jeho použitím pro detekci registračních značek vznikl detektor, který dosahoval úspěšnosti 100 % a 98.47 % na dvou testovacích datových sadách.

Budoucí činnost bude zaměřena na vytvoření SVM klasifikátoru pro rozpoznání znaků a následné sestavení registrační značky. Dále bude vytvořena aplikace, která spojí detekci registračních značek a rozpoznání znaků. Na závěr proběhne vyhodnocení úspěšnosti celé aplikace.

## Literatura

- [1] Amir Hossein Ashtari, Mohd Jan Nordin, and Seyed Mostafa Mousavi Kahaki. A new reliable approach for persian license plate detection on colour images. In *ICEEI*, pages 1–5. IEEE, 2011.
- [2] Wei Wang, Qiaojing Jiang, Xi Zhou, and Wenyin Wan. Car license plate detection based on MSER. In *Consumer Electronics, Communications and Networks (CECNet), 2011 International Conference on*, pages 3973–3976, April 2011.
- [3] Z. Musoromy, S. Ramalingam, and N. Bekooy. Edge detection comparison for license plate detection. In *Control Automation Robotics Vision (ICARCV), 2010 11th International Conference on*, pages 1133–1138, Dec 2010.
- [4] Z. Musoromy, F. Bensaali, S. Ramalingam, and G. Pissanidis. Comparison of real-time dsp-based edge detection techniques for license plate detection. In *Information Assurance and Security (IAS), 2010 Sixth International Conference on*, pages 323–328, Aug 2010.
- [5] Shyang-Lih Chang, Li-Shien Chen, Yun-Chung Chung, and Sei-Wan Chen. Automatic license plate recognition. *Intelligent Transportation Systems, IEEE Transactions on*, 5(1):42–53, March 2004.
- [6] Tran Duc Duan, Duong Anh Duc, and Tran Le Hong Du. Combining hough transform and contour algorithm for detecting vehicles licence

- plates. In *International Symposium on Intelligent Multimedia, Video and Speech Processing*, pages 747–750, 2004.
- [7] Bo Li, Bin Tian, Ye Li, and Ding Wen. Component-based license plate detection using conditional random field model. *IEEE Transactions on Intelligent Transportation Systems*, 14(4):1690–1699, 2013.
  - [8] Wengang Zhou, Houqiang Li, Yijuan Lu, and Qi Tian. Principal visual word discovery for automatic license plate detection. *IEEE Transactions on Image Processing*, 21(9):4269–4279, 2012.
  - [9] P. Cika, M. Zukal, and M. Sebela. Detection and recognition of license plates of czech vehicles. In *ElektroRevue*, volume 2, December 2011.
  - [10] Zhen Chao Zhang and Yuan Yan Tang. License plate recognition algorithm based on derived kernel. In *Wavelet Analysis and Pattern Recognition (ICWAPR), 2012 International Conference on*, pages 238–243, July 2012.
  - [11] L. Neumann. Vyhledání a rozpoznání textu v obrazech reálných scén, diplomová práce, Praha, ČVUT, 2010 [cit. 2015-03-29].
  - [12] J.A.G. Nijhuis, M.H. ter Brugge, K.A. Helmholt, J.P.W. Pluim, L. Spaanenburg, R.S. Venema, and M.A. Westenberg. Car license plate recognition with neural networks and fuzzy logic. In *Neural Networks, 1995. Proceedings., IEEE International Conference on*, volume 5, pages 2232–2236 vol.5, Nov 1995.
  - [13] Paul Viola and Michael Jones. Rapid object detection using a boosted cascade of simple features. In *Accepted Conference on Computer Vision and Pattern Recognition*, pages 511–518, 2001.
  - [14] J. Matas, O. Chum, M. Urban, and T. Pajdla. Robust wide baseline stereo from maximally stable extremal regions. In *In British Machine Vision Conference*, pages 384–393, 2002.
  - [15] Cascade classifier training. [http://docs.opencv.org/doc/user\\_guide/ug\\_traincascade.html](http://docs.opencv.org/doc/user_guide/ug_traincascade.html). [cit. 2015-03-16].