

# DETECTION, LOCALIZATION AND RECOGNITION OF TRAFFIC SIGNS

**Tomáš Svoboda**

Master Degree Programme (2), FIT BUT

E-mail: xsvobo12@stud.fit.vutbr.cz

Supervised by: Adam Herout

E-mail: herout@fit.vutbr.cz

**Abstract:** This article deals with the localization, detection and recognition of traffic signs. The properties of different kinds of features used for traffic signs recognition are described. It focuses on the features based on histogram of oriented gradients. It describes two methods for selection of the regions with a high possibility of traffic signs presence. Cascades of support vector machines are used for detection and their training method is discussed. In the end, the actual results are presented.

**Keywords:** Traffic signs, histogram of oriented gradients, region selection, cascade of support vector machines

## 1 ÚVOD

V dnešní době rozvoje automobilového průmyslu se velmi uplatňují vestavěné systémy a počítače přímo v automobilech pro řešení různých úloh spojených s dopravou. Jednou z těchto úloh je i detekce, lokalizace a rozpoznání dopravních značek v obraze, jejichž výsledky je možné využít v rámci systému upozornění pro řidiče, modulu pracujícím ve spolupráci s navigačním systémem nebo jako část systémů robotického vozidla. V rámci plnění této úlohy bylo třeba nalézt vhodný popis dopravních značek, zvolit typ klasifikátoru a vyřešit další úkoly, kterými se budu v tomto článku zabývat.

## 2 VOLBA PŘÍZNAKŮ PRO POPIS DOPRAVNÍCH ZNAČEK

Příznaky, které jsem pro svou práci zvolil, jsou založeny na histogramech orientovaných gradientů a jsou popsány v práci autorů Chen, Chen a Gao [1]. Vychází z barevného modelu RGB. Rovnice v této části jsou vztaženy k červené složce modelu. Histogram orientovaných gradientů získávám na základě informací o hranách ve směru osy  $x$  a osy  $y$  (využití konvoluce). Z těchto dvou údajů ( $G_{rx}$  a  $G_{ry}$ ) je spočítána síla gradientu a jeho směr. Pro vyšší rychlost výpočtu počítám složky gradientu ve směru osy  $x$  a osy  $y$ , směr a sílu gradientu v jednom průchodu obrazem.

Směr je rozdělen do 8 intervalů, čímž vzniká 8 „binů“ histogramu. Každý bin  $\Psi_k$  má stejný rozměr jako původní obraz a na příslušných souřadnicích obsahuje nulu nebo hodnotu síly gradientu pro daný pixel, pokud směr gradientu v daném bodě spadá do intervalu představovaného binem histogramu. Na biny histogramu jsou aplikovány masky, tzv. bloky a šablony, které vybírají určitou část obrazu (více viz [1]). Příznak pro červenou složku RGB (pro ostatní obdobně) lze spočítat podle rovnice (1), kde  $C_t$  představuje  $t$ -tou šablonu a  $B_b$   $b$ -tý blok a  $G$  označuje sílu gradientu. Příznaky zachycují tvar značky společně s informací o barvě, která je však uvedena v normalizované podobě a proto jsou příznaky odolné vůči změně světelných podmínek. Celkem je možné získat 1680 příznaků (8 binů, 14 bloků, a 15 šablon), které lze efektivně počítat s využitím integrálního obrazu, čímž jsou získány v konstantním čase.

$$f_r(k, b, t) = \frac{\sum_{(x,y) \in C_t} \Psi_{rk}(x, y)}{\sum_{(x,y) \in B_b} (G_r(x, y) + G_g(x, y) + G_b(x, y))} \quad (1)$$

### 3 DETEKCE S VYUŽITÍM KLASIFIKÁTORU

Pro detekci dopravních značek jsem zvolil využití posuvného okna ( $24 \times 24px$ ), kterým procházím pyramidu obrázků v různých měřítcích vzniklých z původního obrazu. O každém okně klasifikátor rozhodne, zda se jedná o některý typ značky nebo o prvek okolí. Výhodou této metody je její invariance vůči pozici a rozměru značky. Nevýhodou je nutnost vysoké rychlosti klasifikátoru a požadavek na malé množství falešných detekcí.

Pro trénování klasifikátorů jsem vytvořil datové sady pro pět typů dopravních značek a zároveň datovou sadu představující okolí, ze které vybírám náhodné výřezy. Další prvky datových sad značek generuji z anotované sady tak, že anotaci mírně posouvám (v intervalu  $\langle -2, 2 \rangle$  px). Tímto malým posunem dochází k možnosti vytvoření až 625 odlišných vzorků z původního jednoho vzorku. Anotovaný obdelník je následně bilineární transformací zmenšen na velikost posuvného okna.

Pro detekci dopravních značek využívám kaskád klasifikátorů support vector machines (viz [1]). Výhodou tohoto typu klasifikátorů je, že rychle odmítá negativní vzorky, čímž je dosaženo velké rychlosti zpracování obrazu. Stupně kaskády jsou představovány support vectors machines s lineárními jádry. Výsledky lineárního SVM se ukázaly jako dostatečně dobré, a protože jejich implementace například v hardware grafické karty je jednodušší, zůstal jsem u tohoto typu SVM.

Trénování kaskády probíhá tak, že natrénuji SVM pro jednotlivé příznaky samostatně, následně vyberu několik nejlepších příznaků, z nichž vytvořím jejich kombinace. SVM pokrývající kombinace příznaků natrénuji s různými parametry a na základě validační sady (odlišná od trénovací) vyberu nový prvek kaskády. Poměr velikostí datových sad je vychýlen ve prospěch negativní datové sady, proto je třeba upravit cenu jednotlivých druhů chyb, tak aby pozitivní vzorky byly zvýhodněny (viz [2]). Odhad ceny pro jednotlivé příznaky provádím na náhodně vybraném vzorku před trénováním jednotlivých SVM pro každý příznak. V případě vyčerpání prvků negativní sady jsou doplněny nové špatně klasifikované výřezy. Vyzkoušel jsem několik metod trénování kaskády především s ohledem na velikost a práci s negativní sadou a jako nejvhodnější se z pohledu rychlosti a délky kaskády jeví relativně větší velikost negativní sady ( $\approx 40000$  prvků) za cenu delšího trénování jednotlivých stupňů kaskády.

Dalším problémem je volba výsledného kandidáta reprezentujícího značku z překrývající se množiny detekcí. Volbu provádím na základě nejvyšší odezvy od kaskády, kde se využívá odezva prvního stupně kaskády, který vybírá z rovnoměrného zastoupení dat. Tato metoda se ukázala jako lepší než např. využití odezvy posledního stupně kaskády. Lokalizaci dále upřesňuji na základě informací o oblastech barvy značky (kapitola 4).

### 4 VÝBĚR OBLASTÍ S VYSOKOU PRAVDĚPODOBNOSTÍ VÝSKYTU ZNAČKY

Pro urychlení procesu detekce značek je vhodné předzpracovat obraz tak, aby byly zpracovávány pouze oblasti, kde se značky mohou vyskytnout a oblasti s vysokou pravděpodobností, že se v nich značky nenalézají, byly vynechány.

Vyzkoušel jsem 5 metod provádějící tento výběr na základě barvy reprezentované v barevných modelech RGB a HSV. Jedna z nejzajímavějších metod popsána v článku autorů Vavilina a Kang [3], která využívá normalizované hodnoty RGB modelu a generuje větší množství regionů, které však obvykle pokryjí všechny značky.

Další zajímavá metoda byla publikována v článku autorů Hu, Zhu a Chen [4] využívá tzv. „barevnou

odchylku“, což je reprezentace obrazu zvýrazňující danou (červenou) barvu. Obraz s touto reprezentací je prahován s využitím Otsuova algoritmu. Tento algoritmus nalezne práh mezi dvěma oblastmi tak, aby rozptyl hodnot pixelů v jednotlivých oblastech byl minimální, čímž maximalizuje rozptyl mezi oběma regiony. Tato metoda nachází menší regiony než předchozí metoda, má však i několik nevýhod. Mezi nevýhody patří, že metoda téměř vždy nalezne nějaké regiony i v případě, že v obraze se regiony výrazné červené barvy nevyskytují. Dále má metoda problémy s oblastmi jasnější červené barvy než jsou hledané značky.

Binárního obrazu reprezentujícího „červené“ pixely využívám pro zpřesnění lokalizace značek. Toto zpřesnění je možné dále řešit rozšířením klasifikátoru o stupeň, který bude vybírat vhodného kandidáta z překrývajících se detekcí.


## 5 ZHODNOCENÍ PRÁCE, ZÁVĚR

Systém je prozatím funkční pro značky typu „dej přednost v jízdě“ a „jednosměrka“ a byl testován na 131 souborech obsahujících 66 značek každého typu. Při použití samostatného klasifikátoru bez výběru oblastí je úspěšnost detekce 100%, ale vzniká celkem 27 chybných detekcí. Průměrná doba zpracování jednoho souboru je 6.58s.

V případě využití výběru oblastí založeném na normalizovaném prostoru RGB dochází k nedetekování jednoho případu značky „jednosměrka“, počet chybných detekcí klesá na 21 a čas zpracování souboru je 3.07s.

Druhá popsaná metoda výběru oblastí byla založena na barevné odchylce, tato metoda je nejrychlejší a průměrná doba zpracování souboru je 0.47s, detekce však není 100%, ale dochází k celkem 7 nedetekování značek, je však nalezena pouze 1 chybná detekce.

Do budoucna bude systém směřován ke zrychlení vlastního zpracování jednoho snímku a praktickým aplikacím při zpracování videa.



**Obrázek 1:** Výstup systému, metoda barevné odchylky. Žluté regiony jsou zvýrazněním skenovaných oblastí. Zeleně je zvýrazněna detekce.

## REFERENCE

- [1] Chen, C.-H., Chen, M., Gao, T.: Detection and Recognition of Alert Traffic Signs [online], Stanford University, [http://ai.stanford.edu/~kosecka/final\\_report\\_final\\_traffic.pdf](http://ai.stanford.edu/~kosecka/final_report_final_traffic.pdf), [cit. 2011-03-01]
- [2] Morik K., Brockhausen P., Joachims T.: Combining Statistical Learning with a Knowledge-Based Approach - A Case Study in Intensive Care Monitoring. In: ICML Proceedings of the Sixteenth International Conference on Machine Learning, Dortmund, 1999, s. 268-277
- [3] Vavilin, A.; Kang, H. J.: Automatic Detection and Recognition of Traffic Signs using Geometric Structure Analysis. In: SICE-ICASE International Joint Conference, Bexco, 2006
- [4] Hu M., Zhu S., Chen K.: An Effective Method for Traffic Signs Segmentation. In: International Conference on Intelligent Human-Machine Systems and Cybernetics, Hangzhou, 2009