


Detekce dopravních značek z kamery ve vozidle

Michal Jurča



Abstrakt

Cílem této práce je detekovat a klasifikovat dopravní značky. Řešení je rozděleno na dvě části detekci a klasifikaci. Detekce je založená na kaskádě klasifikátorů a klasifikace pomocí klasifikace do více tříd. Tento článek popisuje existující řešení, návrh a použité datové sady. V další kapitole je popsána implementace a vyhodnocení testovacích sadě. Pro vyhodnocení natrénovaných modelů byla využita metoda křížové validace a metrika F-measure. Na testovací sadě detektor dosahoval úspěšnosti 0.812 a klasifikátor do více tříd 0.99 a výsledná aplikace 0.674. Aplikace umožňuje zpracovávat vstup pomocí video souboru nebo přímo z kamery. Rychlost zpracování při rozlišení 640x480 dosahuje 16 FPS.

Klíčová slova: Detekce dopravních značek, Klasifikace dopravních značek, Kaskádový klasifikátor, Support Vector Machines

Přiložené materiály: N/A

*xjurca07@fit.vutbr.cz, Faculty of Information Technology, Brno University of Technology

1. Úvod

Dopravní značky jsou klíčové pro zajištění bezpečnosti a efektivitu provozu. Bohužel se stává mnoho nehod, protože řidiči přehlédli dopravní značku. Proto stále více automobilů jsou vybaveny kamerovým systémem, který detekuje a klasifikuje dopravní značky.

Tato práce využívá kaskádový klasifikátor jako detektor dopravních značek. Kde pomocí plouvoucího okna prohledává snímek a nalezené objekty jsou pak následně klasifikovány do tříd pomocí Support Vector Machines (SVM).

2. Existující řešení

Procesem detekcí a klasifikací značek se věnuje mnoho vědeckých skupin a stále vytvářejí nové postupy, pro přesnější a rychlejší detekování a klasifikování značek. Existují různé přístupy řešící detekci.

Autoři článku [1] udělali souhn nejlepších dostupných řešení zabývajících se detekcí a klasifikací dop-


ravních značek. Kde metody založené na příznacích ChnFtrs a AdaBoost dosahovali úspěšnosti 96%-100%. Dále ve své práci srovnávají dostupné datové sady.

Mathias [2] aplikoval Integral Channel Features detector. Detektor je založený na histogramu orientovaných gradientů (HOG) s rozhodovacími stromy. Ve své práci použil datovou sadu GTSRB 3.4, kterou rozdělil do tří skupin podle typu dopravních značek. Příkazové, zákazové a výstražné s výsledky vyhodnocení 96.98% , 100% a 100%.

3. Návrh řešení

3.1 Návrh řešení

Na základě existujících řešení navrhuji rozdělit řešení na detekci a klasifikaci. Pro detektor navrhuji použít kaskádový klasifikátor 3.2 společně s příznaky LBP. A pro klasifikaci navrhuji použít klasifikátor do více tříd pomocí SVM 3.3 společně s HOG příznaky.



Obrázek 1. Schématický popis kaskádového detektoru

3.2 Kaskádový klasifikátor

Kaskádový klasifikátor slouží pro rychlou detekci objektů v obraze. Myšlenkou kaskádového klasifikátoru je mít sekvenčně seřazené slabé klasifikátory do jedinného silného klasifikátoru. Nejčastěji pomocí algoritmu AdaBoost je sestavena soustava slabých klasifikátorů, kterým je nastavena nejvhodnější váha a výsledkem je pak kaskádový klasifikátor. Velká část výřezů je tak v každé úrovni kaskády zahozena a část výřezů, která je klasifikována kladně, projde do další úrovně zpracování. Výřez, který projde až na konec kaskády je s velkou pravděpodobností hledaný objekt.

Kaskádový klasifikátor byl použit v práci Viola & Jones [3] pro detekování obličejů s úspěšností 93.9%.

Tento typ klasifikátoru byl zvolen společně s obrazovými příznaky LBP (local binary patterns), které se vyznačují svou jednoduchostí a efektivitou. Pro každý pixel obrazu je provedeno prahování okolních bodů s hodnotou prahu středového bodu. Okolí je nejčastěji kruhového charakteru a je určeno počtem bodů a poloměrem. Výsledkem je binární číslo. Díky své jednoduché výpočetní složitosti jsou často používány v aplikacích, které analyzují snímky v reálném čase.

3.3 Klasifikátor do více tříd

Support Vector Machines (SVM) se často používá pro klasifikaci kvůli velké přesnosti a schopnosti pracovat s vícedimensionálními daty. Základní funkcí SVM je nalezení oddělovací roviny mezi dvěma třídami dat. K nalezení roviny pomáhají podpůrné vektory (support vectors), které leží na okraji prázdné oblasti a přímo ovlivňují řešení. Čím budou mít větší vzdálenost od oddělovací roviny tímlepší výsledný klasifikátor.

Vhodným typem obrazových příznaků pro klasifikátor SVM jsou HOG příznaky, které se často používají společně s SVM pro klasifikaci dopravních značek. Principem HOG příznaků je určení gradientu hrany v obraze na základě tvaru a vzledu hledaného objektu.

3.4 Pozitivní datová sada GTSRB

Datová sada GTSRB (German Traffic Sign Detection Benchmark) [4] je tvořena německými dopravními značkami z různých regionů Německa pořízených pomocí autokamery. Snímky byly pořízeny během dne,

ale také ve večerních hodinách. Jednotlivé snímky značek jsou realizovány pomocí výřezů o velikosti 15x15 až 250x250 pixelů.

Sada obsahuje celkem 39 209 výřezů pro trénování rozdělených do 43 tříd podle typu značky. Snímky lze rozdělit na čtyři skupiny podle typu značky: zákazové, příkazové, výstražné a upravující přednost.

Součástí sady je také testovací sada snímků o rozlišení 1360x800. Snímky jsou pořízeny pomocí autokamery v různou denní dobu. Sada obsahuje 300 snímků, které jsou anotovány.

3.5 Negativní datová sada

Ve své práci si vytvářím vlastní negativní datovou sadu. Jako zdroj snímků s okolím používám sadu snímků z datové sady [5], které jsou pořízeny z kamery ve vozidle. Snímky jsou pořízeny v Belgii za deního světla a dobrých světelných podmínek. A dále používám vlastní záznamy pořízené v okolí Zlínského kraje v různou denní dobu s vlivem podnební činnosti. Výsledná negativní datová sada je navíc rozšířená o falešně pozitivní snímky s přibližně 20h záznamu.

Sada obsahuje celkem 56 378 výřezů.

4. Realizace a vyhodnocení

4.1 Trénování modelů

Pro detekci dopravních značek jsem zvolil kaskádový klasifikátor knihovny OpenCV¹ a pro klasifikaci pomocí SVM jsem zvolil knihovnu LIBSVM [6]. Pro vyhodnocení natrénovaného modelu byla implementována metoda křížové validace s hodnotou $K = 3$, která rozdělí datovou sadu na trénovací a testovací. Jelikož detektor a klasifikátor vyžadají odlišný přístup k datové sadě a taky pro vyhodnocení testovací sady jsem vytvořil pomocné skripty pro práci s datovou sadou.


Pro trénování kaskádového klasifikátoru byla použita pozitivní sada o počtu snímků 26 139 a negativní datová sada s počtem snímků 37 585.

A pro trénování klasifikátoru do více tříd byla použita jenom pozitivní datová sada s použitím 26 139 snímků.


4.2 Aplikace pro vyhodnocení

Pro vyhodnocení úspěšnosti natrénovaných modelů je použita ROC křivka [7], která je zobrazena na obrázku 2. ROC křivka je užitečný vizuální nástroj pro porovnání a vyhodnocení natrénovaných modelů. Křivka dává do poměru správně klasifikované pozitivní vzorky a chybně klasifikované negativní vzorky jako pozitivní.

¹http://docs.opencv.org/2.4/modules/objdetect/doc/cascade_classification.html



Obrázek 2. Roc křivka detektoru na testovací sadě vytvořené pomocí křížové validace. Červený bod značí zvolenou prahovou hodnotu.



Obrázek 3. Roc křivka klasifikátoru

Pro vyhodnocení snímků z kamery byl vytvořen anotační program. Ve kterém se postupně zobrazují snímky a pomocí myši je vybírána oblast objektu. Aplikace je navržena tak, že vždy výsledné souřadnice jsou začínající v levém horním rohu.

4.3 Vyhodnocení

Pro vyhodnocení natrénovaného modelu byla použita metoda křížové validace, která rozdělí datovou sadu na testovací a trénovací části. Trénovací proces byl proveden třikrát a pokaždé bylo provedeno vyhodnocení na odpovídající testovací sadě. Na základě vyhodnocení byl vždy zvolen model s nejlepšími výsledky.

Vyhodnocení úspěšnosti probíhalo pomocí ROC křivky na testovací sadě určené zvlášť detektoru a klasifikátoru. A také pomocí metody F-Measure.

Pro vyhodnocení natrénovaného modelu detektoru byly použity počty snímků pozitivní sady 13070 a negativní sady 18793. Výsledná ROC křivka je znázorněna na obrázku 2. Zobrazený červený bod značí zvolení prahu při dosažení nejlepší hodnoty F-Measure, která činila 0.812.

Pro vyhodnocení klasifikátoru do více tříd byla použita testovací sada o počtu 13070 snímků.

Na obrázku 3 ROC křivka zobrazuje nejlepší a nejhorší průběh vyhodnocení tříd. Zobrazení všech 43 tříd bylo nepřehledné a pro lepší zobrazení průběhů je



Obrázek 4. Výstup z aplikace



Obrázek 5. Výstup z aplikace

křivka přiblížená. Výsledná přesnost je dána nejhorším průběhem, který dosahoval hodnoty 0.99. A hodnota F-Measure dosahovala 0.997.

Celkové vyhodnocení detektoru a klasifikátoru společně na testovací sadě dosahovala hodnoty 0.674. Horší výsledek je dán výstupem detektoru, který v občasných případech vrací souřadnice nalezného objektu, než je jeho původní velikost. A dochází k tomu, že není označena celá dopravní značka, ale jenom její část. A klasifikátor pak hůře klasifikuje značku do správné třídy.

Pro další vyhodnocení byla použita testovací sada, která je popsána v kapitole 3.4. Vyhodnocení bylo provedeno pomocí metody F-measure, která pro jenom detektor dosahovala 0.842 a v případě detektoru společně s klasifikátorem byla výsledná hodnota 0.784.

5. Pomocník do vozidla

Natrénované modely a připravené řešení jsem integroval do aplikace do vozidla, která detekuje a klasifikuje dopravní značky přímo z kamery. Pro videa v rozlišení 640x480 je rychlost zpracování 16 FPS.

Na obrázcích 4, 5 je zobrazen výstup z aplikace. V zelených rámečcích jsou zobrazeny objekty, které detektor považuje za značku. A na levo je zobrazená klasifikovaná třída dopravní značky.

6. Závěr

Cílem této práce bylo detekovat a klasifikovat dopravní značky. Tento úkol se mě podařilo splnit. A na test-

vací sadě vytvořené pomocí křížové validace a vyhodnocené pomocí metody F-measure dosahovala detekce přesnost 0.812, klasifikace do více tříd 0.99 a výsledná přesnost aplikace 0.674.

Aplikace umožňuje zpracovávat video nebo přímo vstup z kamery. Při rozlišení 640x480 je rychlost zpracování 16 FPS.

Součástí řešení je sada scriptů, která zpracovává datovou sadu, vytváří trénovací a vyhodnovací sady. A scripty pro vyhodnocení natrénovaných modelů.

Literatura

- [1] Ivan Filkovic. Traffic sign localization and classification methods: An overview.
- [2] M. Mathias, R. Timofte, R. Benenson, and L. Van Gool. Traffic sign recognition - how far are we from the solution? In *ICJNN*, 2013.
- [3] Paul Viola and Michael J. Jones. Robust real-time face detection, 2004.
- [4] Johannes Stallkamp, Marc Schlipsing, Jan Salmen, and Christian Igel. The German Traffic Sign Recognition Benchmark: A multi-class classification competition. In *IEEE International Joint Conference on Neural Networks*, pages 1453–1460, 2011.
- [5] Radu Timofte, Karel Zimmermann, and Luc Van Gool. Journal of machine Vision and Applications (mva 2011). In *Multi-view traffic sign detection, recognition and 3D localisation*, December 2011.
- [6] Chih-Chung Chang and Chih-Jen Lin. LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2:27:1–27:27, 2011. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [7] Tom Fawcett. An introduction to roc analysis. *Pattern Recognition Letters*, vol. 27(issue 8):861–874, 2006.