


Odhad rozestupu automobilů z mobilního telefonu umístěného ve vozidle

Ondřej Zemánek*



Abstrakt

Cílem tohoto projektu je mobilní aplikace pro systém Android, která by pomohla s předvídáním rizika srážky při nebezpečném snižování rozestupu vozidel. Aplikace sleduje rozestup vozidel a při náhlé změně rozestupů upozorní řidiče zvukovým signálem. Predikce probíhá detekcí vozidel pomocí natrénovaného kaskádového klasifikátoru a následné kontrolou rozestupu vozidel z obrazu kamery mobilního telefonu. Odhad rozestupu je vyhodnocován na základě znalostí parametrů kamery, průměrných rozměrů vozidel, velikosti detekovaného vozidla a případně velikosti registrační značky, jejíž detekce probíhá v oblasti snímku, která je klasifikátorem nejlépe klasifikována jako vozidlo. Pro rozpoznávání vozidel pomocí kaskádového klasifikátoru byla vytvořena trénovací datová sada. Samotná práce se pak zaměřuje na pět hlavních problémů — vytvoření datové sady vozidel, trénování kaskádového klasifikátoru pro klasifikace vozidel v obraze, odhad rozestupu vozidel, sledování rozestupu vozidel a vyhodnocení odhadu rozestupu a klasifikace.

Klíčová slova: Odhad vzdálenosti z obrazu — Kaskádový klasifikátor — Rozpoznávání vozidel z obrazu — Kalibrace kamery

Příložené materiály: [Demonstrační video](#)

*xzeman53@fit.vutbr.cz, Faculty of Information Technology, Brno University of Technology

1. Úvod

V dnešní době najdeme v automobilech nespočet aktivních či pasivních jízdních asistentů, které přispívají k bezpečnější jízdě. Jedním z nich je adaptivní tempomat (Adaptive Cruise Control), který mimo jiné dokáže, měřit rozestup mezi vozidly. Většina těchto adaptivních tempomatů funguje na principu kombinace radarového měření vzdálenosti, měření pomocí infra kamery a ultrazvukových senzorů. Celý tento systém je velice přesný, ale je většinou drahý a složitý a je od začátku součástí automobilu.

Jako alternativním řešením může být odhadování rozestupu z obrazu kamery mobilního telefonu. Protože většina chytrých mobilních telefonů dnes disponuje

dostatečně kvalitním fotoaparátem pro snímání prostoru před automobilem a výpočetním výkonem, dovolujícím spuštění aplikace pro rozpoznávání vozidel s použitím metod pro detekci objektů v obraze, je možné využít tuto aplikaci mobilního telefonu, jako jednoduchý jízdní asistent. Jedná se také o dostupnější řešení pro širší skupinu lidí a zároveň tato metoda nevyžaduje zásah do vozidla instalací drahého zařízení, na rozdíl od měřících metod RADAR, LIDAR nebo ultrazvukových senzorů [8].

V této práci se snažím odhalit možnosti a nedostatky zmíněného řešení odhadu rozestupu z obrazu.

2. Existující řešení

Dálkové měření se v dnešní době provádí různými metodami. Nejčastěji jsou tyto metody postavené na základě výpočtu doby šíření vlnového impulsu prostorem odraženého od snímaného objektu.

První metodou dálkového měření je **RADAR** (Radio Detection and Ranging). K měření vzdálenosti se využívá elektromagnetických impulsů. Podobnou měřicí metodou vzdálenosti je **LIDAR** (Light Detection And Ranging), která funguje na podobném principu, jako radarové měření, ale místo elektromagnetických impulsů využívá šíření pulsu laserového paprsku.

Obě zmíněné metody dokáží měřit vzdálenost i na 150 metrů a proto se mohou použít pro odhad rozestupu vozidel i ve vysokých rychlostech, kdy je rozstup vozidel větší.

Další široce používanou metodou pro odhad vzdálenosti mezi vozidly je metoda měření pomocí **ultrazvuku**, odhadující vzdálenost výpočtem doby šíření ultrazvukových impulsů. Tato metoda se používá na velmi krátké vzdálenosti do 3 metrů a není proto příliš vhodná pro řešení této práce.

Zmíněné techniky sice dosahují velice dobrých výsledků, avšak ani jedna se příliš nehodí pro použití s mobilním telefonem. Dalšími důvody jsou vysoká cena těchto zařízení, nekompaktní rozměry a nutnost složité instalace celého zařízení do vozidla.

Další možnou metodou měření je odhad rozestupu s využitím **detekce vozidel z obrazu**. Princip této metody spočívá v rozpoznávání automobilů v obraze a následném výpočtu vzdálenosti se znalostí rozměrů vozidla v obraze, celkové velikosti obrazu a kalibrace kamery. Tuto metodu používá například firma MobilEye [5].

3. Trénování kaskádového klasifikátoru

3.1 Kaskádový klasifikátor

Kaskádový klasifikátor je v této práci využíván pro detekci vozidel v obraze. Principem kaskádového klasifikátoru je využití algoritmu **AdaBoost**¹ (Adaptive Boosting) pro vytvoření sériově seřazených slabých klasifikátorů.

Při průchodu snímku k detekci touto kaskádou slabých klasifikátorů jsou vyfiltrovány pouze oblasti v obraze, které jsou klasifikovány kladně, tedy ty které odpovídají detekovanému objektu [4].



Obrázek 1. Ukázka pozitivní sady vozidel

3.2 Vytvoření datové sady

Pro kvalitní výsledky detektoru objektů v obraze bylo potřeba vytvořit dostatečně velkou datovou sadu vozidel. Při vytvoření velké a rozmanité datové sady, docílíme přesnějšího a robustnějšího detekování.

Datová sada pro tuto práci byla vytvořena převážně z anotovaného video datasetu **TME Motorway Dataset** [1], který obsahuje přes 27 minut videa z kamery, umístěné za čelním sklem osobního vozidla, snímající provoz na dálnici. Při vytváření této video sady byl využit laserový scanner, pro detekci osobních a nákladních vozidel. Informace z detekce byly zaznamenány do anotačních souborů k jednotlivým snímkům videa a bylo tedy možné ze snímků získat mnoho vzorků vozidel, které se použily v datové sadě pro trénování kaskádového klasifikátoru.

Jako pozitivní vzorky, zachycující pouze samotná vozidla, byly použity vzorky automobilů z již zmíněného datasetu MotorwayDataset. Tyto vzorky byly získány vyříznutím z obrazu pomocí malé aplikace vytvořené v rámci této práce.

Negativní snímky neobsahující vozidla, byly získány převážně z foto databáze **www.image-net.org** [3].

Přesnost takového rozpoznávání klasifikátorem závisí především na popisované trénovací datové sadě, která se skládá ze dvou hlavních částí – **pozitivní sady** snímků požadovaného objektu k detekci a **negativní sady** obrázků neobsahující výskyt objektu k rozpoznání. Počet negativních snímků by měl být mnohonásobně větší, než pozitivních.

Pro rozpoznávání vozidel v obraze byl zvolen kaskádový klasifikátor s použitím funkcí open source knihovny **OpenCV**².

3.3 Pozitivní snímky

Pro trénovací datovou sadu se použily pozitivní vzorky zachycující různé druhy vozidel. Sada obsahuje zhruba

¹Explaining AdaBoost

²OpenCV

200 typů automobilů. Osobní automobily jsou zachyceny na 70 % pozitivních snímcích, zbytek je tvořen nákladními vozidly a také motorkami.

Při tvorbě pozitivních vzorcích byl kladen důraz na to, aby se ve vzorcích nevyskytovalo příliš pozadí nebo pokud možno v co nejmenší míře. Pokud by totiž při vytváření datové sady nebyl brán ohled konkrétnost pozitivních vzorků, docházelo by po natrénování k nepřesné klasifikaci.

Při sbírání pozitivních vzorků se vybíraly snímky zachycující zadní části vozidel. Důvodem pro toto rozhodnutí byl fakt, že při výsledné klasifikaci je důležitá především klasifikace vozidel jedoucích před kamerou, tzn. taková, která jsou zachycena kamerou zezadu. Kdybychom totiž při tvorbě zanesly do trénovací sady i ostatní části vozidel, nastal by problém s rozlišením hrozícího nebezpečí a pouze projíždějících automobilů.

Taktéž bylo důležité vybírat pro sadu automobily v různých odstínech. Na samotné barvě nezáleží, jelikož se před trénováním klasifikátoru všechny vzorky převádí do šedých odstínů, avšak různé barvy mohou být světlejší nebo tmavší.

K trénování detektoru byly použity snímky zadních částí vozidel pod různými úhly a v různých světelných podmínkách.

3.4 Negativní snímky

Negativní snímky byly vybrány na základě prostředí, pro kterou je klasifikátor určen. Datová sada je tvořena fotografiemi přírody (30 %), budov (30 %), ulicemi bez automobilů (15 %), silnicemi (15 %). Zbylou část tvoří také snímky oblohy a mraků, které jsou také vhodné pro použití jako negativní vzorky, jelikož se s velkou pravděpodobností budou objevovat na budoucích klasifikovaných snímcích.

Typ datové sady	počet vzorků
Pozitivní	2920
Negativní	8444

Tabulka 1. Snímky trénovací sady

3.5 Vylepšování klasifikátoru

Trénování klasifikátoru bylo během diplomové práce několikrát vylepšováno na základě experimentálního vyhodnocování ze záznamů reálném provozu a statických fotografií.


Problémy při samotné klasifikaci byli pozorovány především objektech, podobných nákladním vozidlům. Například zadní části velkých orientačních tabulí na dálnicích a silnicích první třídy, které se jim velmi podobají. Taktéž nastávaly falešné detekce u dělených

oken, které se svým tvarem také podobají nákladním vozidlům.

Při zjištění falešných detekcí byla negativní datová sada doplněna o 500 snímků cedulí a o více než 900 snímků oken.

4. Odhad rozestupu vozidel


4.1 Kalibrace kamery



Obrázek 2. Schéma popisující měření vzdálenosti objektu od senzoru kamery [7]

Protože aplikace pro odhad rozestupů používá kameru mobilního telefonu a každý mobilní telefon může disponovat jiným typem snímače a objektivem kamery, potřebuje zjistit parametry fotoaparátu abychom mohli provést kalibraci. Díky provedení kalibrace, budou výpočty rozestupu na všech mobilních telefonech stejné. Samotná kalibrace kamery se tedy odráží ve výpočtu vzdálenosti od vozidel detekovaných v obraze [2].

4.2 Výpočet vzdálenosti



Obrázek 3. Ukázka z aplikace - odhad vzdálenosti na základě velikosti automobilu a registrační značky

Výpočet rozestupu vozidel je popsán vzorcem 1, který vypočítává vzdálenost na základě velikosti boxu ohraničující nalezené vozidlo na snímku, jak je vyobrazeno červeným obdélníkem na obrázku 3, znalosti

o průměrné šířce automobilu³ a informacích o parametrech kamery.

Podobný výpočet se používá i pro výpočet vzdálenosti registrační značky automobilu, s tím rozdílem, že místo šířky vozidla se dosadí šířka registrační značky a průměrná šířka automobilu je nahrazena fyzickým rozměrem registrační značky.

Vzorec pro výpočet vzdálenosti z obrazu:

$$d = \frac{W_1 \cdot F_l}{\frac{W_2}{S_1} \cdot S_2} [mm] \quad (1)$$

kde:

W_1 ... průměrná šířka automobilu v milimetrech

F_l ... ohnisková vzdálenost v milimetrech

W_2 ... šířka vozidla v pixelech

S_1 ... šířka senzoru v pixelech

S_2 ... šířka senzoru v milimetrech

4.3 Sledování rozestupu vozidel

Nedílnou součástí aplikace, která dokáže předpovídat nebezpečné situace ze změn rozestupu mezi vozidly je sledování těchto změn v čase. Bez znalosti změny rozestupu by nebylo možné aplikaci rozpoznávat, zdali vozidlo jedoucí před námi náhle nezačalo brzdit. Z toho důvodu je nutné implementovat algoritmus, který by byl schopný porovnávat rozestup v čase a na základě toho odhadovat, zdali se nejedná o příliš rychlou a tím pádem nebezpečnou změnu rozestupu.

Pro samotné sledování rozestupu vozidel je potřeba znát hraniční rychlost přibližování, která závisí především na aktuální rychlosti vozidla. Tato hraniční rychlost udává jak moc se může rozestup snížit za jednotku času, aniž by to bylo nebezpečné, což může nastat například v situaci při zmíněném náhlém brzdění vozidla před námi. Proto je také důležitou součástí aplikace integrace měření rychlosti automobilu pomocí mobilního telefonu s využitím GPS dat.

Algoritmus sledování rozestupu vozidel tedy při odhadu rozestupu k vozidlu ukládá odhadnutou vzdálenost. Při další detekci sleduje oblast ve které se předchozí detekce objevila a pokud je znovu klasifikováno vozidlo ve stejné oblasti, tak zkontroluje odhadnuté vzdálenosti a čas, který od předchozího odhadu uběhl a porovná tento výsledek k hraniční rychlosti pro aktuální rychlost vozidla. Pokud se tedy při dalším měření vzdálenosti z obrazu nebezpečně sníží rozestup od vozidla, aplikace varuje uživatele krátkým zvukovým signálem.

³Reference.com - How wide is your car?



Obrázek 4. Příklad vyhodnocení na sadě referenčních fotek (Červený odhad je z detekovaného vozidla, bílý odhad je z detekované registrační značky a oranžovou barvou je znázorněna reálná vzdálenost)

5. Vyhodnocení

Vyhodnocení aplikace bylo prováděno ze dvou hlavních pohledů. První část se zaměřuje na přesnost odhadu vzdálenosti. Pro správné určení přesnosti odhadu rozestupů bylo zapotřebí vytvořit snímky s **vozidly z přesně naměřených vzdáleností**. Při vytváření této sady bylo použito padesáti metrové pásmo k přesnému měření vzdáleností. Druhou částí je ohodnocení spolehlivosti a přesnosti klasifikace vozidel na snímcích z reálného provozu. K tomuto vyhodnocení byly natočeny videa z různých dopravních situací a podmínkách.


5.1 Vyhodnocení odhadu vzdálenosti na statických snímcích

Pro vyhodnocení odhadu vzdálenosti pomocí mobilní aplikace bylo vytvořeno 9 sad statických fotografií vozidel a natočeno 25 minut videa z reálného provozu.


Referenční fotografie byly nafoceny čtyřmi různými mobilními telefony, abychom dokázali ověřit správnost výpočtu kalibrace a vzdálenosti vozidel, se zohledněním parametrů kamer a snímačů mobilních telefonů. Každá z devíti sad snímků obsahuje fotografie automobilu, zachyceného ze čtyř předem známých vzdáleností udaných v tabulce 2. Pro každé vozidlo bylo tedy vzniklo celkem šestnáct fotografií, pořízených čtyřmi telefony s odlišnými parametry.

Rychlost v [km/h]	Vzdálenost za 2 s [m]
30	16,7
50	27,8
90	50,0
130	72,2


Tabulka 2. Vzdálenosti ujeté během 2 sekund v běžných rychlostech v provozu



Obrázek 5. Graf vyhodnocení odhadu vzdálenosti při detekci vozidel



Obrázek 7. Graf vyhodnocení odhadu vzdálenosti při detekci registračních značek



Obrázek 6. Graf vyhodnocení odhadu vzdálenosti při detekci vozidel (s použitím regresní funkce)


typ detekce	průměrná odchylka [%]
vozidla	19,80
registrační značky	9,80

Tabulka 3. Vyhodnocení odhadu vzdálenosti bez použití regresní funkce

Vzdálenost ujetá za dvě sekundy byla zvolena na základě vyhlášky o bezpečné vzdálenosti [6].

Výsledky vyhodnocení odhadu vzdálenosti z obrazu byly získány pomocí algoritmu mobilní aplikace. Následující tabulka 3 ukazuje, že odhad rozestupu z detekce registrační značky je v průměru o více než polovinu přesnější nežli odhad z detekovaného automobilu. Avšak výsledky také ukázaly, že detekce registračních značek nastává jen při malých vzdálenostech od automobilu automobilu. Tuto vzdálenost nelze přesně určit, protože závisí především na rozlišení a ostrosti snímků.

Z vyhodnocení bylo též zjištěno, že u mobilních telefonů s vyšším rozlišením se úspěšnost klasifikace automobilů snižovala i při způsobu zmenšení snímku



Obrázek 8. Graf vyhodnocení odhadu vzdálenosti při detekci registračních značek (s použitím regresní funkce)

algoritmem na rozlišení maximálně 1280x720. Jako řešení tohoto problému nejlépe vyšlo použití bilaterální filtr, který sice zjemní snímek, ale jen v jasově podobných oblastech, tím pádem nepřijde o ostrost hran a přechodů, ale jen se zbavíme zbytečně ostrého a zašumělého obrazu. Díky tomu bylo možné vylepšit klasifikaci vozidel a registračních značek.

Výstupní grafy vyhodnocení na statických fotografiích ukázaly, že klasifikátor detekuje v průměru 80 %-tní část vozidla a tedy nadhodnocuje vzdálenost v průměru o 20 % reálné vzdálenosti. Naopak v případě detekce registračních značek bylo zjištěno z grafů opačné chování, kdy detektor klasifikoval i část okolí registrační značky. Průměr podhodnocování reálných rozestupů byl 6 %. Obě tato zjištění opět vedla k možnosti vylepšení výpočtu vzdálenosti.

Pro odhad nejlepší regresní funkce, která by minimalizovala chybu a zanesla by se do výpočtu rozestupu aplikace, byla zvolena lineární regrese. Při experimentování bylo zjištěno, že funkce $y = k \cdot x + q$

Před použitím regresní funkce	
typ detekce	průměrná odchylka [%]
vozidla	19,96
registrační značky	9,00
Po použití regresní funkce	
typ detekce	průměrná odchylka [%]
vozidla	11,32
registrační značky	7,50

Tabulka 4. Vyhodnocení odhadu vzdálenosti na polovině vyhodnocovací sady s **použitím regresní funkce**

s vypočítáním koeficientů k a q na základě poloviny vyhodnocovacích dat, sice přinese zlepšení v klasifikaci automobilů, avšak zhorší odhad s klasifikací registračních značek. Po dalších experimentech nejlépe vyšla funkce $y = k \cdot x$ s odlišným koeficientem k pro odhad s klasifikací vozidel a registračních značek. Důvodem pro odlišnost koeficientů je opačné chování při odhadech s klasifikací vozidel a registračních značek. Grafy vyhodnocení průměrné odchylky vzdálenosti, po zanesení regresní funkce do algoritmu výpočtu vzdálenosti, jsou zobrazeny na obrázcích 7 a 5.


5.2 Vyhodnocení úspěšnosti klasifikace

Vytvořené záznamy z reálného provozu se použily na vyhodnocení přesnosti natrénovaného klasifikátoru vozidel. Samotné vyhodnocení přesnosti lze rozdělit na dvě hlavní části — Pozitivní klasifikace a negativní klasifikace.


Při zkoumání pozitivní klasifikace sledujeme části snímku, které klasifikátor detekoval jako vozidla. Pokud tato klasifikovaná část snímku zachycuje automobil, do vyhodnocení zaznamenáme tuto klasifikaci jako **True positive**, což označuje správnou detekci. Pokud ale klasifikovaná část snímku vozidlo neobsahuje, hodnotíme tuto detekci, jako **False positive**, označující nesprávnou detekci.

Druhou částí vyhodnocení je hodnocení negativní klasifikace. V této části hodnotíme segmenty snímku, které klasifikátor neohodnotil jako vozidlo. V tomto případě **True negative** označuje správné vynechání částí snímku, které neobsahují automobil. V opačném případě, kdy mezi klasifikovanými částmi snímku chybí ty, která obsahují vozidla, označujeme tento případ termínem **False negative**.

Pro tuto práci nedává smysl v hodnocení negativní klasifikace kontrolovat **False negative** situace, jelikož nemáme možnost ohodnotit na snímcích počet možných částí, které neobsahují vozidlo. Proto vyhodnocení úspěšnosti klasifikátoru probíhá pouze pro výše



Obrázek 9. Graf vyhodnocení klasifikace vozidel v poměrech vůči celé vyhodnocovací sadě snímků



Obrázek 10. Graf vyhodnocení klasifikace registračních značek v poměrech vůči celé vyhodnocovací sadě snímků

popsané zbylé tři situace.

Vyhodnocení zmíněných situací pro klasifikátor vozidel je vyobrazen na grafu 9 a vyhodnocení pro použitý klasifikátor registračních značek ukazuje graf 10.

Při vytváření záznamů z reálného provozu byl brán ohled na různorodost okolí a typu komunikací. Pořízené záznamy zaznamenávají jízdu po dálnici, ulicích města a silnicích druhé a třetí třídy.

6. Závěr

Trend v automobilovém průmyslu jasně ukazuje rostoucí důležitost pomocných a bezpečnostních asistentů v automobilech. Automobilky začínají postupně nabízet zákazníkům stále více asistenčních prvků. Chybí zde ale dostupnější alternativa asistentů i pro zákazníky s vozidly, která postrádají tyto asistenty. Výsledná aplikace této práce by mohla zaplnit tuto mezeru a nabídnout jednoduché řešení, bez nutnosti instalace drahých senzorů, s rozšířenými možnostmi, jako záznam nebezpečných situací, grafické zobrazení rozestupu od automobilů a zvukové upozornění při detekovaném riziku srážky.

7. Poděkování

Rád bych tímto poděkoval vedoucímu mé bakalářské práce Ing. Jakubu Sochorovi za cenné rady a užitečné připomínky.

Literatura

- [1] Claudio Caraffi, Tomas Vojir, Jura Trefny, Jan Sochman, and Jiri Matas. A System for Real-time Detection and Tracking of Vehicles from a Single Car-mounted Camera. In *ITS Conference*, pages 975–982, Sep. 2012.
- [2] Richard Hartley and Andrew Zisserman. *Multiple View Geometry in computer vision*. Cambridge University Press, The address, 2 edition, 2003.
- [3] Stanford Vision Lab, Stanford University, and Princeton University. Image-net.org. <http://image-net.org/>.
- [4] Jiri Matas and Jan Sochman. Adaboost. http://www.robots.ox.ac.uk/~az/lectures/cv/adaboost_matas.pdf.
- [5] MobileEye. Mobileye - advanced driver assistance systems. <http://www.mobileye.com/our-technology/>.
- [6] Centrum služeb pro silniční dopravu s.p.o. Vzdálenost mezi vozidly. http://www.cspsd.cz/storage/files/vzdalenost_mezi_vozidly.pdf.
- [7] HyperPhysics Georgia State University. Image formation by lenses and the eye. <http://hyperphysics.phy-astr.gsu.edu/hbase/Class/PhSciLab/image.html>.
- [8] Ing. Jan Vavřík. Adaptive cruise control. blog-post (czech), March 2010. http://home.zcu.cz/~rcermak/opvk_cm/M_05.pdf.